



Research Article

Evaluation and Prediction of Sedimentary Delta Dynamics in the Makoran Tidal Inlets

Saeid Roodbari Shahmiri, Mehdi Adjami* and Saeid GhareChelou Ahmadi

Faculty of Civil Engineering, Shahrood University of Technology, Iran.

* corresponding author: (adjami@shahroodut.ac.ir)

Article Info

Article history:

Received: 3 July 2024

Revised: 11 February 2025

Accepted: 16 February 2025

Keywords:

Tidal inlets,
mixed energy inlets,
machine learning,
sediment delta,
satellite images.

Abstract

Estuaries and tidal inlets are valuable environments for marine ecosystems and have strong socio-economic importance for coastal communities (maritime, fishing, aquaculture, tourism, recreational activities, etc.). Estuaries are connected to the sea by inlets. Various models of changes in the area of the sedimentary delta of inlets with different behaviors have been identified. In this paper, an evaluation of the parameters affecting sedimentary delta changes and a prediction of changes in the sedimentary delta area of mixed energy-dominated estuaries (simultaneously dominated by waves and tides) on a 20-year scale has been carried out on the Makoran coast. This assessment was carried out using machine learning models such as decision trees, support vector machines, multilayer neural networks, and satellite image analysis. Factors affecting changes in inlets have been evaluated in 5 main groups, including 34 components, 2100 data points over a period of 20 years. The data evaluated in the research were obtained by analyzing satellite images, extracting and classifying data from the European Weather Database (ECWMF) from the era-intrins data series, and data from the Chabahar and Jad field stations. The results showed that machine learning models, with the appropriate data bank and selection of appropriate features, can predict and evaluate changes in the sedimentary delta of the Makoran inlets dominated by mixed energy. Among the three models evaluated, the decision tree model provided the best performance with an error of less than 8% for these openings. Among the 34 selected components, the most influential characteristics affecting these inlets in the long term are global-scale data such as sea level rise, global warming, and barostatics. In the second order of importance of data, there are meteorological data, such as the number of rainy days per year and precipitation. The enhanced Wilmot index and the MAE and MSE indices have selected the decision tree model as the best model for predicting changes in the delta of the Makoran mixed energy inlets.

Funding: This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflicts of Interest: The authors declare no conflict of interest.

Author Contributions: All authors contributed to the reported work for conceptualization, methodology, validation, writing-review and editing, and supervision.

To Cite this article:

Roodbari Shahmiri, S., Adjami, M. and GhareChelou, S. 2025. Evaluation and prediction of sedimentary delta dynamics in the makoran tidal inlets, Sharif Civil Engineering Journal, 41(3), 59-75. <https://doi.org/10.24200/j30.2025.64746.3339>

E-ISSN: 2676-4776 © 2025 The Author(s). Sharif Civil Engineering Journal, Published by Sharif University of Technology

This is an open access article under the [CC-BY 4.0 license](https://creativecommons.org/licenses/by/4.0/).



ارزیابی و پیش‌بینی تغییرات دلتای رسوبی دهانه‌ی خورهای مکران

سعید رودباری شه‌میری، مهدی عجمی* و سعید قره‌چلو

دانشکده‌ی مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران.

*نویسنده مسئول (adjami@shahroodut.ac.ir)

چکیده

ارزیابی پارامترهای مؤثر در تغییرات دلتای رسوبی و پیش‌بینی تغییرات مساحت آن‌ها در مقیاس ۲۰ ساله در سواحل مکران توسط مدل‌های یادگیری ماشین، مانند: درخت تصمیم، ماشین بردار پشتیبان، شبکه‌ی عصبی چندلایه، و آنالیز تصاویر ماهواره‌ای انجام شده است. عوامل مؤثر در تغییرات دهانه در ۵ گروه، شامل ۳۴ مؤلفه و ۲۱۰۰ داده در طی ۲۰ سال بررسی شده‌اند. داده‌ها توسط آنالیز تصاویر ماهواره‌ای از پایگاه ECWMF سری era-intrim و از پایگاه‌های چاپهار و جد به‌دست آمده‌اند. مدل‌های یادگیری ماشین می‌توانند پیش‌بینی و ارزیابی خوبی از تغییرات دلتای رسوبی دهانه‌ی خورهای مکران انجام دهند. مدل درخت تصمیم، بهترین عملکرد را با خطای کمتر از ۸٪ داشته است. از میان ۳۴ مؤلفه‌ی انتخابی، مؤثرترین مشخصه‌های اثرگذار در دهانه‌های خورهای مکران در بلندمدت، داده‌هایی با مقیاس جهانی، مانند: بالاروی سطح دریا، گرمایش جهانی، و باریاستاتیک بوده و سپس داده‌های هواشناسی مانند تعداد روزهای بارش در مرتبه‌ی بعدی قرار گرفته‌اند. شاخص ارتقاء یافته‌ی ویلموت و شاخص‌های MAE و MSE، مدل درخت تصمیم را به‌عنوان بهترین مدل برای پیش‌بینی تغییرات دلتای دهانه‌ی خورهای مکران معرفی کرده‌اند.

اطلاعات مقاله

تاریخ دریافت: ۱۴۰۳/۰۴/۱۳

تاریخ اصلاحیه: ۱۴۰۳/۱۱/۲۳

تاریخ پذیرش: ۱۴۰۳/۱۱/۲۸

واژگان کلیدی:

دهانه‌های جزر و مدی،
تحت سلطه‌ی انرژی مختلط،
یادگیری ماشین،
دلتای رسوبی دهانه،
تصاویر ماهواره‌ای.

۱. مقدمه

خورها و دهانه‌های جزر و مدی، محیط ارزشمندی برای اکوسیستم‌های دریایی هستند و از لحاظ اجتماعی-اقتصادی برای جوامع ساحلی (دریانوردی، ماهیگیری، آبی‌پروری، گردشگری، فعالیت‌های تفریحی، و غیره)، که به‌طور کلی با تغییرات مورفولوژیکی پیچیده و قابل‌توجهی مشخص می‌شوند، حائز اهمیت بسیار هستند.^[۱-۳] پدیده‌هایی همچون فرسایش و انباشت رسوب‌ها در سواحل طبیعی و خورها، افزایش تراز آب دریا، و زیر آب‌رفتن اراضی و تأسیسات ساحلی و آلودگی‌های زیست‌محیطی نوار ساحلی از مسائل چالش‌برانگیز در حوزه‌ی اخیر بوده است.^[۴] هیس و فیتزجرالد^[۱] (۲۰۱۳)،^[۵] اظهار کرده‌اند که دهانه‌های جزر و مدی به‌صورت یک ورودی درون خط ساحل نفوذ می‌کنند و یک ارتباط بین دریا و خلیج فراهم می‌سازند (شکل ۱).

دهانه‌های جزر و مدی^۲، عموماً با نفوذ در بدنه‌ی جزایر سدی^۳، ورودی‌های رودخانه‌ای، یا در بین ساختارهای زمین‌شناسی ساحلی با پیشروی آب در ساحل شکل می‌گیرند و تبادل آب اقیانوس و خلیج با استفاده از آن‌ها صورت می‌پذیرد. اگرچه دهانه‌ها در تبادل آب تازه بین خلیج و اقیانوس مشارکت

می‌کنند، ولی قطع جریان جزر و مدی به وسیله‌ی انباشت رسوب ساحلی در دهانه‌ها (دلتای رسوبی دهانه)، یکی از مشکلات آن‌هاست (شکل ۱). رسوب ساحلی نه فقط موجب قطع جریان، بلکه موجب به دام انداخته‌شدن رسوب به درون خور یا خلیج نیز می‌شود. به منظور اینکه خلیج‌ها و خورها استفاده شوند و کارایی خود را داشته باشند، باید دهانه‌های آن‌ها و الگوهای فرسایش و انباشت رسوبی در دهانه‌ها، بررسی و مطالعه شود. تیپ‌های متفاوتی از عملکرد دهانه‌های جزر و مدی وجود دارد، که هر کدام رفتار و الگوی فرسایش و انباشت رسوبی مختص به‌خود را دارند. به عقیده‌ی هیس (۱۹۷۵)،^[۶] سواحل از نظر رژیم هیدرودینامیک به ۳ دسته تقسیم می‌شوند. از آنجا که پارامترهای بازه‌ی جزر و مد و انرژی موج در سیستم دهانه‌ها تأثیرگذار هستند، هیس (۱۹۷۹) و هیس و داویس (۱۹۸۴)،^[۵] از اطلاعات اخیر برای دسته‌بندی براساس تسلط قدرت موج^۴، تسلط قدرت جزر و مد^۵، و تحت سلطه‌ی هم موج و هم جزر و مد^۶ (تحت سلطه‌ی انرژی مختلط) استفاده کرده‌اند. هر کلاس از دهانه‌ها، خصوصیت مورفولوژیکی و رسوبی مختص به‌خود را دارد. اندازه‌ی نسبی دلتای جزر یا دلتای مد و مکانیزم انتقال رسوب از دهانه، به اندازه‌ی تحت سلطه‌بودن قدرت موج یا قدرت جزر و مد در منطقه بستگی دارد؛ یعنی

⁴ wave domain

⁵ tide domain

⁶ mixed energy

¹ Hayes & FitzGerald

² tidal inlets


³ Barrier island

به دلیل توانمندی‌های رایانه‌ها در پردازش بیشتر با فرآیند به مراتب سریع‌تری انجام می‌شود. یادگیری ماشین، شاخه‌ای از هوش مصنوعی است؛ که بنابر تعریف، دانشی در حوزه علوم رایانه است و از طریق آن می‌توان با پردازش داده‌ها به اطلاعات ارزشمند نوینی دست یافت.^[۱۹ و ۲۰]

در مجموعه فرآیندهای تحلیل و ارزیابی ریخت‌شناسی ساحلی، سه گروه مطالعات: میدانی، آزمایشگاهی، و عددی قرار می‌گیرند، که به جهت تصدیق ارزیابی‌های انجام‌شده، دست‌کم دو مورد از آن‌ها باید در مطالعات ایفاء نقش کنند. دو گروه مطالعات میدانی و آزمایشگاهی، با توجه به در اختیار قرار دادن داده‌های اولیه، پایه مطالعات مهندسی سواحل به‌شمار می‌آیند و بخش محاسبات عددی نیز تکمیل‌کننده دو گروه دیگر است، که نقش تحلیل، نتیجه‌گیری، و پیش‌بینی از داده‌ها را بر عهده دارد. دو روش توسعه نرم‌افزاری و یادگیری ماشینی، زیرمجموعه محاسبات عددی هستند، که در روش توسعه نرم‌افزاری با افزودن ریزفرآیندهایی در نرم‌افزارهای کد باز موجب بهبود عملکرد و تحلیل آن می‌شود و خروجی‌های مطلوب‌تری به‌وجود می‌آورد. روش یادگیری ماشین، با استفاده از توابع خاصی جهت شناخت پدیده‌های محیطی حاکم و توصیف تغییرات ریخت‌شناسی ساحلی، الگوهای یادگیری را دنبال می‌کند و با بهبود توابع، نزدیک‌ترین نتایج را ارائه می‌کند. مدل‌های یادگیری ماشین، همچنین براساس الگوهای یادگیری توانایی پیش‌بینی تغییرات در آینده را نیز دارند. در سال‌های اخیر، به مطالعات ریخت‌شناسی به روش یادگیری ماشینی و ترکیب آن با داده‌های تصاویر ماهواره‌ای توجه شده است. آنالیز تصاویر ماهواره‌ای می‌تواند داده‌های مستمر و با کیفیت و ارزان در اختیار مدل‌های یادگیری ماشین قرار دهد. در واقع، روش‌های سنجش از راه دور، هر روزه در جمع‌آوری داده‌ها اهمیت بیشتری پیدا می‌کنند. شرکت‌های فناوری اطلاعات برای بروزرسانی خدمات مبتنی بر مکان خود به داده‌های تصاویر ماهواره‌ای وابسته هستند.^[۲۱ و ۲۲] نرم‌افزار گوگل ارث از آنالیز تصاویر ماهواره‌ای با کیفیت بالا برای ارائه تصاویر واضح از سطح زمین استفاده می‌کند. دولت‌ها از سنجش از راه دور برای انواع خدمات عمومی از گزارش آب و هوا گرفته تا نظارت بر ترافیک استفاده می‌کنند. انبارهای داده‌های تصاویر ماهواره‌ای، از جمله تصاویر با وضوح طیفی و فضایی مختلف، روزانه در حال افزایش هستند.^[۲۳ و ۲۴]

در مقایسه با روش‌های تحلیلی، تجربی، و عددی، که در آن‌ها عوامل کنترل‌کننده ثابت هستند؛ روش‌های آماری می‌توانند زمانی که مشاهده‌ها در دسترس باشند، عوامل بالایی را به مدل اضافه کنند. روش آماری همچنین زمان محاسباتی کوتاه‌تری را می‌طلبد، اما به یک مجموعه داده‌ی تاریخی گسترده برای ساخت مدل‌های قابل‌اعتماد نیاز دارد. در مهندسی و علوم ساحلی، یادگیری ماشین در حال تبدیل شدن به ابزاری محبوب برای بهبود بهره‌برداری از مجموعه‌ی اطلاعات رو به رشد است، که با استفاده از روش‌های سنجش از راه دور و سایر بانک‌های اطلاعاتی در دسترس هستند.

با افزایش روزافزون داده‌ها، اهمیت راهبردی و کاربردی محیط ساحلی پیچیده دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط، فقدان مطالعه با رویکردهای متنوع و نبود مطالعه‌ی کافی بر روی منطقه‌ی مکران، پژوهش حاضر انجام شده است؛ که هدف آن، ارزیابی پارامترهای مؤثر در تغییرات دلتای رسوبی دهانه‌ی خورها و همچنین پیش‌بینی تکامل بلندمدت مورفودینامیکی تغییرات دلتای رسوبی دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط در منطقه‌ی ساحلی مکران بوده است. داده‌ها برای مطالعه‌ی حاضر، از تصاویر



شکل ۱. مدل ترسیم‌شده از دهانه‌ی ورودی خورها و دلتاهای رسوبی انباشته‌شده در دهانه توسط داوینس و فیتزجرالد (۱۹۸۴).^[۲۱]

نیروی غالب بر شکل‌دهی سواحل، قدرت موج یا قدرت جزر و مد یا ترکیب دو مورد اخیر باشد. بیشترین مهاجرت رسوبی و بسته‌شدن دهانه‌ها، عموماً در سواحل با جزر و مد پایین و تحت سلطه‌ی موج اتفاق می‌افتد. بزرگ‌ترین عرض دهانه‌ها و پایدارترین دهانه‌ها مربوط به سواحل تحت سلطه‌ی جزر و مد هستند. متغیرترین سیستم عملکرد رسوبی در تغییرات دلتای رسوبی دهانه‌ها مربوط به سواحل تحت سلطه‌ی هم موج و هم جزر و مد (تحت سلطه‌ی انرژی مختلط) است.^[۱۵] پدیده‌ی فرسایش و رسوب‌گذاری در دهانه‌های تحت سلطه‌ی انرژی مختلط به عواملی، نظیر: منابع رسوبی، عملکرد موج، و جزر و مد تغییرات تراز آب، منشور جزر و مدی، جهت حرکت رسوبی،^[۸ و ۹] و صدها عامل بزرگ و کوچک دیگر بستگی دارد. پژوهشگران ساحلی به‌علت اهمیت حفظ ارتباط آب خلیج با اقیانوس، به مسئله‌ی تکامل مورفولوژیکی و رسوبی در دلتای دهانه‌ها و نیروهای محرک بر تکامل صورت‌گرفته به ویژه در دهانه‌های خورها توجه ویژه‌ی داشته‌اند.^[۱۵-۱۰] اگرچه عوامل فیزیکی اصلی حاکم بر تغییرات مورفولوژیکی دلتای دهانه (مانند: باد، موج، جزر و مد، دبی رودخانه، و منشور جزر و مدی) به‌خوبی شناخته شده‌اند،^[۱۶-۱۸] اما کمی‌سازی آثار ترکیبی آن‌ها، چالش‌برانگیز است.

ارزیابی و پیش‌بینی تغییرات مساحت دلتای رسوبی دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط، با توجه به حجم بالایی از تعاملات بین نیروهای هیدرودینامیکی و ساختارهای مورفولوژیکی، بسیار پیچیده و مشکل است. گسترش روزافزون فناوری موجب شده است که داده‌های فراوانی در تمام زمینه‌ها در دسترس پژوهشگران قرار گیرد. با افزایش روزافزون داده‌ها، نیاز به مطالعه‌ی دقیق‌تر و همین‌طور ترکیب پارامترهای جدید بر سیستم‌های ساحلی احساس می‌شود. پرسش اصلی این است: چگونه می‌توان اطلاعات ارزشمندی را استخراج کرد که در انبوهی از داده‌های خام نهفته است؟

در حال حاضر انسان در تأثیرگذارترین دوره از حیات خود قرار گرفته است؛ دورانی که در آن، تصمیم‌گیری از ذهن‌ها به رایانه‌ها منتقل شده‌اند. یادگیری ماشین، حوزه‌ای از هوش مصنوعی است، که کاربردهای متنوعی در سایر علوم دارد. یادگیری، مهم‌ترین ویژگی بشری است که به‌عنوان روشی بنیادی برای کشف دانش شناخته می‌شود. یادگیری ماشین، دانشی است که با الهام از فرآیند یادگیری در انسان، به کسب دانش و مهارت‌های جدید می‌پردازد؛ کاری که

ماهورهای و بانک‌های میدانی و جهانی استخراج شده‌اند. مدل‌های یادگیری ماشین برای ارزیابی و پیش‌بینی تغییرات مساحت دلتای رسوبی دهانه‌ی خورهای سواحل مکران (خورهای تنگ، گالک، و میدانی) ایران استفاده شده است.

در سال‌های اخیر، مطالعات زیادی در حوضه‌های ساحلی از طریق الگوریتم‌های یادگیری ماشین انجام شده است. در پژوهش حاضر با در نظر گرفتن کاربرد مدل‌ها در محیط ساحلی، طیف داده‌ها، و مطالعات پیشین، از سه مدل یادگیری ماشین، درخت تصمیم، شبکه‌ی بردار پشتیبان و شبکه‌ی عصبی چندلایه استفاده شده است. عوامل مؤثر در تغییرات دلتای رسوبی در طول مدت پژوهش (۱۹۹۹ تا ۲۰۱۹)، انتخاب و وزن‌دهی شده‌اند و سپس پیش‌بینی تغییرات دلتاهای رسوبی در دهانه‌ها صورت پذیرفته است.

حتی کسانی که با یادگیری ماشین آشنا نیستند، احتمالاً قبلاً در مورد شبکه‌های عصبی مصنوعی^۱ شنیده‌اند. تا حد زیادی شبکه‌ی عصبی چندلایه^۲، پیش‌تاز مدل‌های یادگیری ماشین طی ۲ دهه‌ی گذشته بوده است؛ به‌ویژه در برنامه‌های طبقه‌بندی تصویر و بینایی رایانه،^[۲۵] سیستم‌های توصیه،^[۲۶] و شبکه‌های عصبی چندلایه از رفتار مغز انسان مدل می‌شوند. از نظر مفهومی، شبکه‌های عصبی چندلایه از واحدهای محاسباتی به هم پیوسته برای الگوبرداری از فرآیندها، شناسایی الگوهای موجود در داده‌ها، و پیش‌بینی استفاده می‌کنند. ساده‌ترین شکل یک شبکه‌ی عصبی چندلایه با یک سری لایه نشان داده می‌شود، که شامل یک لایه‌ی ورودی، یک یا چند لایه‌ی پنهان، و یک لایه‌ی خروجی است. هر لایه از تعدادی گره تشکیل شده است، که در آن لایه‌ی ورودی و خروجی معمولاً برای متغیر ورودی و خروجی یک گره دارد و لایه‌های پنهان، حاوی تعداد دلخواهی گره هستند، که معمولاً براساس تجربه، ابتکارها، و تجزیه و تحلیل سینماتیک هستند. گره‌های مذکور از نظر ریاضی به هم متصل هستند و داده‌های ورودی را رصد می‌کنند؛ سپس در لایه‌های پنهان وزن‌بندی و تحلیل غیرخطی داده‌ها را انجام می‌دهند؛ و در نهایت، فایلهای خروجی را ارائه می‌کنند. شبکه‌های عصبی چندلایه، الگوریتم‌های همه‌کاره و قدرتمندی هستند که در طیف گسترده‌ای از برنامه‌ها برای مشکلات ساحلی استفاده می‌شوند. مطالعات: شبکه‌ی عصبی چندلایه، شامل پیش‌بینی فرسایش در خط ساحل،^[۲۷] مدل‌سازی از فرآیندهای ساحلی،^[۲۸ و ۲۹] پیش‌بینی تغییرات خط ساحلی،^[۳۰] پیش‌بینی انتقال رسوب در ساحل،^[۳۱ و ۳۲] پیش‌بینی رسوب‌های معلق در ناحیه‌ی نزدیک به ساحل،^[۳۳] پیش‌بینی کدورت سطح آب،^[۳۴] تغییرات طولانی‌مدت در ساحل خور،^[۳۵] پیش‌بینی سطح آب،^[۳۶] همبستگی مورفولوژیکی پشته‌های ماسه‌ای،^[۳۷] پیش‌بینی خطرهای در محیط ساحلی،^[۳۸] از انواع مطالعات انجام‌شده هستند. بر طبق پژوهش گلدستین و همکاران (۲۰۱۹)،^[۳۹] شبکه‌ی عصبی چندلایه، بهترین مدل متناسب با بیشترین مقدار داده‌ی آموزش دیده است.

ماشین‌های بردار پشتیبان (SVM)، روش‌های پیچیده‌ای از یادگیری ماشین هستند، که ایده‌ی کلی آن‌ها، شناسایی و ترسیم ابرنقشه‌ای است که داده‌ها را از مقادیر خروجی همگن جدا می‌کند. یک ابرنقشه به سادگی N بُعد فضایی را

جدا می‌کند، که در آن N تعداد متغیرهای ورودی در مدل است. مدل ماشین بردار پشتیبان، همواره خط بهینه را جستجو می‌کند؛ که عبارت از خطی است که فاصله‌ی نزدیک‌ترین نقطه‌ی داده از هر مقدار پاسخ را به میزان کمینه برساند، و به آن، هایپرپلین با بیشینه‌ی حاشیه^۴ گفته می‌شود. بسیار نادر است که داده‌های سیستم‌های ساحلی به راحتی شناسایی شوند و معمولاً داده‌ها به‌صورت خطی قابل تفکیک نیستند. یکی از ویژگی‌های ماشین بردار پشتیبان، کلید شناسایی نقشه‌برداری غیرخطی هسته (Kernal) است، که برای تبدیل داده‌های غیرخطی قابل تفکیک به گونه‌ای تعریف می‌شود که به‌صورت خطی قابل تفکیک باشد. در ماشین بردار پشتیبان، ایده‌ی اصلی آن است که داده‌ها به یک فضای بُعد بالاتر تبدیل شوند، که در آن جدایی خطی مابین داده‌ها به‌طور بالقوه امکان‌پذیر باشد. ماشین بردار پشتیبان، محبوب‌ترین روش‌های نظارت در جامعه‌ی گسترده‌ی یادگیری ماشین هستند. ماشین بردار پشتیبان اغلب با شبکه‌های عصبی مقایسه می‌شود و عملکرد خوبی در طیف وسیعی از مشکلات پیچیده و مجموعه‌ی داده‌ها دارد؛ اما از نظر فرآیندهای فیزیکی به راحتی بیوزن نتورک‌ها و درختان تصمیم، قابل تفسیر نیستند. ماشین بردار پشتیبان، علی‌رغم استفاده‌ی گسترده از آن‌ها در جامعه‌ی گسترده‌ی مدل‌های یادگیری ماشین، فقط چند استفاده‌ی محدود در برنامه‌های ساحلی تا به امروز داشته‌اند؛ مانند: پیش‌بینی طوفان،^[۴۰] نقشه‌برداری از اندازه‌گیری آب‌های کم‌عمق،^[۴۱] پیش‌بینی شرایط موج،^[۴۲] پیش‌بینی خطرهای در محیط ساحلی،^[۴۳] و پیش‌بینی فرآیندهای فیزیکی ساحلی،^[۴۸] به احتمال زیاد، عدم استفاده‌ی فراوان از ماشین بردار، نتیجه‌ی عدم آشنایی با الگوریتم‌های مذکور است و انتظار می‌رود با استانداردتر شدن یادگیری ماشین در ادبیات ساحلی، در آینده استفاده از آن‌ها افزایش یابد.^[۴۳]

درخت تصمیم^۵، روشی در یادگیری ماشین برای ساختاربندی (یا شکل‌دهی یا سازماندهی) به الگوریتم است. یک الگوریتم درخت تصمیم برای تقسیم ویژگی‌های مجموعه‌ی داده از طریق تابع هزینه^۶ استفاده می‌شود و قبل از انجام بهینه‌سازی و حذف شاخه‌های اضافه، به گونه‌ای رشد می‌کند که ویژگی‌های نامرتب با مسئله دارد. به همین دلیل، عملیات هرس کردن^۷، برای حذف شاخه‌های اضافی مذکور در آن انجام می‌شود. در الگوریتم درخت تصمیم، پارامترهایی، از جمله عمق درخت تصمیم را نیز می‌توان تنظیم کرد تا از بیش‌پردازش یا پیچیدگی بیش از حد درخت^۸ تا حد امکان جلوگیری شود.

درخت تصمیم از گره‌های^۹ مختلفی تشکیل شده است: گره‌ی ریشه^{۱۰}، محل شروع درخت تصمیم به حساب می‌آید، که معمولاً تمام مجموعه‌ی داده‌ی مسئله را شامل می‌شود. گره‌های برگ^{۱۱}، نقطه‌ی پایانی هر شاخه‌ی درخت یا خروجی نهایی مجموعه‌ای از تصمیم‌ها هستند. هر شاخه‌ی درخت تصمیم در یادگیری ماشین فقط یک گره‌ی برگ دارد. در مدل درخت تصمیم، ویژگی داده‌ها در گره‌های داخلی شاخه‌ها و نتیجه‌ی آن‌ها در برگ هر شاخه نشان داده می‌شود. به‌دلیل اینکه درخت تصمیم در یادگیری ماشین، ساختار ساده‌ای در نشان‌دادن یک مدل دارد، در حوزه‌ی یادگیری ماشین بسیار محبوب شده است. ساختار درخت مانند الگوریتم مذکور باعث ساده‌شدن در درک فرآیند

⁷ pruning

⁸ Overly complex tree

⁹ Node

¹⁰ Root Node

¹¹ Leaf Node

¹ Artificial neural networks

² Multilayer neural network

³ Surfzone

⁴ Maximum-margin hyperplane

⁵ Decision tree

⁶ Cost Function

جدول ۱. مراحل اجرای مدل‌های یادگیری ماشین به صورت خلاصه.

Step	Description
1	Data Collection: This crucial step affects results significantly, as data quality and quantity matter.
2	Model Preparation: Filter data using selected methods and then utilize them for random training.
3	Model Selection: Choose the best-performing model in similar fields.
4	Model Training: Use random variable values, compare outputs to expected responses, and iterate to improve learning.
5	Model Evaluation: Compare outputs from learned models with previously set aside validation data.
6	Parameter Tuning: Adjust hyperparameters like learning rates and initial values to enhance performance.
7	Model Output: The stage where the value of machine learning becomes evident by providing expected results.

تصمیم‌گیری و پردازش‌ها می‌شود. آماده‌سازی مدل‌های یادگیری ماشین، شامل ۷ مرحله اصلی هستند (مطابق جدول ۱).

سه معیار توان دوم خطاها (MSE)، میانگین خطای مطلق (MAE)، و شاخص ارتقاء یافته‌ی ویلموت برای ارزیابی اندازه‌ی خطا و مقایسه‌ی مدل‌ها با یکدیگر استفاده شده‌اند. معیار MSE در ریاضیات و آمار، میانگین توان دوم خطاها،^{۱۲} روشی برای برآورد میزان خطاست، که در واقع تفاوت بین آنچه تخمین زده شده و مقادیر تخمینی است. میانگین خطای مطلق یا MAE، یک معیار معروف برای مسائل رگرسیون است و واحدهای خطا با واحدهای متغیر هدف مطابق هستند. میانگین خطای مطلق، قدرمطلق تفاوت را بین مقادیر پیش‌بینی شده و واقعی اندازه‌گیری می‌کند. دو معیار اخیر از پراستفاده‌ترین معیارها برای مقایسه‌ی عملکرد مدل‌های یادگیری با یکدیگر هستند (معادله‌های ۱ و ۲):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (1)$$

$$MAE = \sum_{i=1}^n |y_i - \bar{y}_i| \quad (2)$$


که در آن‌ها، n تعداد نمونه‌ها، y_i اندازه‌ی مقدار حقیقی از نمونه‌ی i ام، و $\bar{y}_i$ اندازه‌ی مقدار پیش‌بینی از نمونه‌ی i ام هستند.

شاخص توافق ویلموت، معیاری برای اندازه‌گیری میزان توافق بین پیش‌بینی‌ها و مشاهده‌های واقعی است. شاخص ویلموت، به‌طور خاص برای ارزیابی دقت پیش‌بینی‌های عددی استفاده می‌شود. شاخص توافق ارتقاء یافته‌ی استفاده شده در پژوهش حاضر، نسخه‌ای از شاخص اصلی است که برای جلوگیری از برخی مشکلات مرتبط با حساسیت بالا به خطاهای بزرگ بازطراحی شده است (معادله‌ی ۳).

$$\frac{\sum_{i=1}^n |ip_i - O|}{\sum_{i=1}^n (|\bar{O} - ip_i - \bar{O}| + |O|)} - 1 = 1d \quad (3)$$

که در آن، $1d$ شاخص توافق ویلموت ارتقاء یافته است. p_i مقدار پیش‌بینی شده، O مقدار واقعی، $\bar{O}$ میانگین مقادیر واقعی، و n تعداد داده‌ها هستند.

در شاخص ارتقاء یافته‌ی ویلموت، اگر نتیجه نزدیک به ۱ باشد، یعنی پیش‌بینی انجام شده، دقت بالاتری دارد و اگر نتیجه به صفر نزدیک باشد، یعنی نتایج



شکل ۲. خورهای منطقه‌ی مطالعاتی واقع در سواحل مکران، ایران (۳) خور مطالعه شده: تنگ، گالک، و میدانی).

پیش‌بینی مناسب نیست. شاخص ویلموت معمولاً برای سنجش مدل‌های پیش‌بینی کننده استفاده می‌شود.

۲. مواد، روش‌ها، و منطقه‌ی مطالعاتی


به منظور درکی بلندمدت از تغییرات رسوبی دلتای دهانه‌ها، بازه‌ی مطالعاتی ۲۰ ساله از سال‌های ۱۹۹۹ تا ۲۰۱۹ انتخاب شده است، تا بیشترین مقدار از تغییرات مورفولوژیکی دلتای رسوبی دهانه، قابل رؤیت و داده‌های هیدرودینامیکی و ماهواره‌ای از منطقه موجود باشد (بانک داده‌ای جامعی تشکیل شود). در مطالعه‌ی حاضر، ۳ خور (تنگ^{۱۳}، میدانی^{۱۴} (ریچ)، و گالک^{۱۵}) در قسمت شرقی تنگه‌ی هرمز در سواحل مکران در دریای عمان انتخاب شده‌اند (شکل ۲)؛ که به علت عملکرد طبیعی امواج و جزر و مد، در دسته‌ی خورهای تحت سلطه‌ی انرژی مختلط قرار دارند. ارتفاع مؤثر امواج در دهانه‌ی

^{۱۴} Meydani

^{۱۵} Galek

^{۱۲} Mean Squared Error


^{۱۳} Tang



شکل ۴. مشخصه‌های مورفولوژیکی اصلی و همچنین مراکز جمعیتی در امتداد سواحل مکران: [۴۷] (a) نقشه‌ی هوایی از سواحل مکران؛ (b) محیط‌های تفکیک‌شده به بخش‌های سواحل ماسه‌ای، صخره‌ها، بوت‌زارها، مراکز انسانی، تپه‌های ماسه‌ای، و خورها.

خلیج عمان به واسطه‌ی سیستم موسمی اقیانوس هند، باعث بهره‌وری فصلی و تنوع در ورودی رسوب می‌شود. در سواحل ایران، بادهای موسمی زمستانی (NE) با بادهای معتدل از مهرماه آغاز و در آذر و دی ماه به بیشینه‌ی شدت خود می‌رسند. بادهای موسمی تابستانی (SW)، طولانی‌تر و شدیدتر هستند و از اردیبهشت‌ماه شروع می‌شوند و از تیر تا مهر به بیشینه‌ی قدرت خود می‌رسند. طوفان‌های گرمسیری و طوفان‌های استوایی در طول ماه‌های خرداد تا تیر، گاهی در دریای عرب شکل می‌گیرند، اما بندرت به سواحل مکران می‌رسند.

طوفان گونو (رده‌ی ۵) در ژوئن ۲۰۰۷ رخ داده و شدیدترین طوفان استوایی ثبت‌شده در خلیج عمان بوده است. سواحل مکران، شامل عارضه‌های مورفودینامیک ساحلی، مانند: سواحل ماسه‌ای و کم شیب، دلتا، خور و دهانه، تالاب، زبانه^{۱۸}، جزایر ماسه‌ای^{۱۹}، و همچنین تپه‌های ماسه‌ای^{۲۰} هستند. [۴۶] جنس پهنه‌بندی بافت ژئومورفولوژی منطقه، شامل سواحل ماسه‌ای، جزایر سدی، و پادانه‌های ساحلی^{۲۱} است (شکل ۴). در منطقه‌ی اخیر، دو طوفان اصلی در سال رخ می‌دهد، که به ترتیب طوفان‌های اقیانوسی و طوفان مونسونی هستند. طوفان‌های مونسونی، جریان‌های هوایی برخاسته بر روی شیب قاره‌ی هند هستند، که عمدتاً دارای ارتفاع امواج ۱/۵ تا ۲/۷۵ متر و دوره‌ی تناوب ۱۰ تا ۱۳ ثانیه هستند. طوفان‌های اقیانوسی، از قطب جنوب و در مسیر اقیانوس هند آغاز می‌شوند و با رسیدن به سواحل مکران، شرایط امواج بلند را پیدا



شکل ۳. محاسبه‌ی دسته‌بندی خورها براساس مدل هایس (۱۹۷۵). [۷]

خورهای مذکور بین ۰/۷ تا ۱/۳ متر و بازه‌ی بیشینه‌ی جزر و مدی منطقه، حدود ۱/۷ تا ۲/۵ متر است (به استناد داده‌های جمع‌آوری‌شده توسط پژوهش حاضر، داده‌های موج از مرکز پژوهش‌های جوی اروپایی، و جزر و مد از ترازسنج چابهار).

با توجه به مدل ترسیمی هایس (۱۹۷۵)، [۷] خورهای ذکرشده تحت کلاس خورهای تحت سلطه‌ی انرژی مختلط قرار گرفته و عملکرد آن‌ها تحت اثر هم‌زمان موج و جزر و مد بوده است (شکل ۳). حرکت رانه‌ی ساحلی^{۱۶} در منطقه از سمت شرق به غرب بوده و نرخ نسبی انتقال رسوب در منطقه بین ۱۰۰ تا ۳۵۰ هزار مترمکعب در سال تخمین زده شده است. [۴۵ و ۴۴] مکران نام تاریخی ساحل شرقی خلیج عمان در شمال غربی اقیانوس هند است؛ که به طول ۱۰۰۰ کیلومتر، از تنگه‌ی هرمز در جنوب ایران تا نزدیک کراچی در پاکستان امتداد دارد (شکل ۲). بخش غربی ساحل، در ایران و قسمت شرقی آن در پاکستان است. چابهار در ایران، بندر اصلی و مرکز جمعیت آن در حدود ۱۲۰۰۰۰ نفر است. مشخصه‌های اصلی مورفودینامیکی و همچنین مراکز جمعیتی در شکل ۴ مشاهده می‌شود. کراچی با بیش از ۱۶ میلیون نفر جمعیت، اصلی‌ترین شهر ساحلی پاکستان است و در زمان مطالعه‌ی حاضر، یک برنامه‌ی توسعه در بندر چابهار در حال انجام بوده است؛ که هدف آن، ارتقاء کراچی به یک هاب^{۱۷} بین‌المللی برای حمل‌ونقل دریایی بین آسیای مرکزی و اقیانوس هند بوده است. منطقه‌ی مکران به دلیل قرارداشتن در شرقی‌ترین بخش مرز آبی کشور ایران، و وجود عوامل ساختاری مانند خلیج‌های امگاشکل و خورهای متعدد و همچنین دسترسی بسیار مناسب به آب‌های جهانی، می‌تواند به‌عنوان یکی از اصلی‌ترین بخش‌های اقتصادی در زمینه‌ی ساخت و سازهای دریایی عمل کند. خلیج‌های امگاشکل و کمانی، مانند: تنگ، پوزم، چابهار، و گوادر تا حدی از طوفان‌ها و امواج بزرگ با تپه‌های صخره‌ای کناری محافظت می‌شوند. فضای داخلی خورها و خلیج‌ها عمدتاً از سواحل شنی تشکیل شده است. سواحل مکران، منطقه‌ای نیمه‌گرمسیری و خشک است.

میانگین بارندگی سالانه کمتر از ۱۰۰ میلی‌متر و بسیار متغیر است. آب‌وهوا در

^{۱۹} Barrier island

^{۲۰} Dune

^{۲۱} Marine terrace

^{۱۶} Long shore current

^{۱۷} Hub

^{۱۸} Spit

جدول ۲. بانک‌های داده‌ای جمع‌آوری شده.


Data Type	Collection Source	Period	Collection Method
Meteorological	Tang inlet: Chabahar station, Galak and Meidani inlets: Jad station	1999-2019	Annual
Global	AVISO International Weather Center for all three inlets	1980-2020	Annual
Hydrodynamic	ECMWF Center, ERA-Interim dataset for all three inlets	1999-2020	Monthly
Geomorphological	Satellite image analysis: Landsat 7 and 8, Sentinel for all three inlets	1999-2014 (Landsat), 2015-2019 (Sentinel)	Annual
Computational Parameters	Calculated based on critical parameters from study records	1999-2020	Annual

است. داده‌های مؤثر در تغییرات دهانه در جدول ۳، دسته‌بندی و کدگذاری شده‌اند؛ که در آن، ۳۵ داده قرار داشته است، که در این بین تغییرات دلتای رسوبی دهانه، پارامتر وابسته‌ی پژوهش و مابقی، پارامترهای مستقل پژوهش را تشکیل داده‌اند. در مطالعه‌ی حاضر، به‌منظور بررسی و پیش‌بینی تغییرات دلتای رسوبی دهانه‌ی خورهای منطقه‌ی ساحلی مکران از روش یادگیری ماشین استفاده شده است.

با توجه به هدف پژوهش حاضر و همچنین گستره‌ی داده‌های موردنیاز و تشکیل مدل یادگیری ماشین، همبستگی زمانی و مکانی بین داده‌ها به شدت اهمیت پیدا می‌کند. لذا، داده‌های تصاویر ماهواره‌ای نیز باید در همین گستره‌ی زمانی و مکانی باشند.

داده‌های مربوط به مشخصه‌های ژئومورفولوژیکی خورها و داده‌های مرتبط با سؤال اصلی پژوهش حاضر، که تغییرات دلتای رسوبی دهانه هستند، از طریق آنالیز تصاویر ماهواره‌ای، موتور جستجوگر گوگل ارث^{۲۴} فراهم شده‌اند؛ که ابزاری برای پردازش مکانی با یک بستر ابری برای مطالعه و تفسیر محیط گسترده شده است. سامانه‌ی مذکور، یک رابط کاربری گرافیکی (GUI)^{۲۵} مبتنی بر وب است، که دسترسی به یک مجموعه‌ای از تصاویر ماهواره‌ای و سایر مجموعه‌های داده را از طریق زیرساخت‌های محاسباتی گوگل فراهم می‌کند. برای زبان برنامه‌نویسی معروف، مانند جاوا^{۲۶} و پایتون و مجموعه‌ای از رابط‌های برنامه نویسی (API)^{۲۷}، محیط‌های توسعه در دسترس هستند. این ویژگی‌های کلیدی در صورت ترکیب، کاربران را قادر می‌سازد داده‌های بزرگ جغرافیایی در بازه‌ی زمانی طولانی را با روش‌های قدرتمند، کشف، تفسیر، و شبیه‌سازی کنند.

داده‌های استفاده‌شده، شامل آنالیز تصاویر ماهواره‌های لندست ۷ و ۸ و سنتینل ۲-۱ در بازه‌ی زمانی پژوهش حاضر (۱۹۹۹-۲۰۱۹) در منطقه‌ی ساحلی مکران بوده‌اند. سه خور تنگ، گالک، و میدانی مطابق پلیگون (شکل ۶)، با هدف تفکیک محیط آبی و خاکی خور و همچنین تفکیک محیط آب و خاکی دهانه و تفکیک محیط‌های گلی درون خور انتخاب شده‌اند. از شاخص اصلاح‌شده‌ی تفاضل نرمال‌شده‌ی آب^{۲۸} به‌منظور تفکیک محیط‌های آبی از سایر محیط‌ها برای تفکیک محیط گلی (محیط تر و خشک) و تفکیک نواحی کاملاً خشک



شکل ۵. فلوچارت فرایند پژوهش - که روش‌شناسی پژوهش را برای ارزیابی و پیش‌بینی تغییرات دلتای رسوبی دهانه‌ی خورهای مکران توسط داده‌های جمع‌آوری شده و مدل‌های یادگیری ماشین به تصویر کشیده است.

می‌کنند.^[۴۸] همچنین، مسیر انجام پژوهش حاضر با رسم فلوچارت در شکل ۵ مشخص شده است.

بانک‌های اطلاعاتی استفاده‌شده در پژوهش حاضر عبارت از داده‌های جهانی مرکز داده‌ی آویسو^{۲۲}، داده‌های هیدرودینامیکی از مرکز اروپایی جوی^{۲۳}، سری داده‌های ERA-INTRIM، و داده‌های هواشناسی از داده‌های ایستگاه‌های سینوپتیک منطقه‌ی جد و چابهار بوده‌اند. برای داده‌های مورفولوژیکی منطقه نیز از داده‌های استخراج‌شده از تصاویر ماهواره‌ای استفاده شده است. در جدول ۲، در مجموع ۲۱۰۰ داده در ۲۰ سال برای ۲۰ خور مطالعه‌شده ارائه شده

²⁶ Java script

²⁷ Application Programming Interface

²⁸ Modified Normalized Difference Vegetation Index

²² Aviso


²³ ECWMF

²⁴ Google earth engine

²⁵ Graphical User Interface

جدول ۳. داده‌ها و پارامترهای مؤثر در دهانه‌ی خور.

Category/Code	Description
Hydrodynamic	
X0	Wave height
X1	Calm wave height
X2	Storm wave height
X3	Wave direction
X4	Calm wave direction
X5	Storm wave direction
X6	Wave period
X7	Calm wave period
X8	Storm wave period
X9	Water surface pressure
X10	Calm water surface pressure
X11	Storm water surface pressure
X12	Wind speed (U component)
X13	Wind speed (V component)
X14	Tidal range
Synoptic Data	
X15	Temperature
X16	Average high temperature
X17	Average low temperature
X18	Absolute maximum temperature
X19	Absolute minimum temperature
X20	Precipitation
X21	Number of stormy days
X22	Number of rainy days (>1mm)
X23	Number of rainy days (>0.1 mm)
Global	
X24	Sea level rise
X25	Global warming
X26	Earth energy imbalance
X27	Barystatic pressure
Satellite Image Analysis	
X28	Area with no data available
X29	Dry area
X30	Mudflat area
X31	Water area
Dependent Parameters	
	Area of water at the inlet
	Area of mudflat at the inlet
Effective Parameters	
X32	Sedimentation rate
X33	Tidal prism
X34	P/M ratio



شکل ۶. پولیگون‌های رسم‌شده برای انجام محاسبات در محیط موتور جستجوگر گوگل ارث.

مادون قرمز میانی، مقدار بازتاب آب معمولاً نزدیک به صفر است، که این موضوع اساس شاخص MNDWI را فراهم می‌سازد. به این ترتیب، مقادیر به‌دست‌آمده از سطوح خور به‌دلیل انعکاس بالاتر آن‌ها در باند سبز، نسبت به مادون قرمز کوتاه مقادیر مثبتی دارند و سطوح غیرآب، مقادیر منفی دارند. یک مقدار حد آستانه برای MNDWI (به‌عنوان مثال، مقدار صفر) را می‌توان تنظیم کرد تا نتایج MNDWI را در دو کلاس آب و غیرآب تقسیم کند. شاخص MNDWI به‌صورت معادله‌ی ۴ توصیف می‌شود، که در آن $SWIR1$ باند موج کوتاه مادون قرمز و G باند سبز است.

$$MNDWI = \frac{SWIR1 - G}{SWIR1 + G} \quad (4)$$

واحدهای تغییرات ژئومورفولوژیکی تحلیل‌شده‌ی پژوهش حاضر در جدول ۴ ارائه شده‌اند.

برای تحلیل مناطق آبی و خشک با استفاده از موتور جستجوگر گوگل ارث و تصاویر ماهواره‌ی لندست، می‌توان کد NDWI (شاخص تطابق آب) را از تصاویر لندست استخراج کرد، تا مناطق آبی و خشک را تشخیص دهد. باید توجه داشت که مقدار ۰/۱ در تابع classifyWater برای تشخیص مناطق آبی و خشک استفاده شده است. همچنین باید به این موضوع اشاره کرد و توجه داشت که مقدار ۰/۱ در متغیر حد آستانه^{۳۰} برای تشخیص مناطق آبی تنظیم شده است، تا بهترین نتایج برای شرایط محیطی به‌دست آید. بسیاری از مطالعات علمی از مقدار ۰ تا ۰/۲ به‌عنوان آستانه‌ی تفکیک آب و خشکی استفاده کرده‌اند. مقدار ۰/۲ معمولاً به‌عنوان میانه به‌کار می‌رود، که آب‌های واضح (رودخانه، دریاچه، و دریا) را شامل می‌شود و مناطق مرزی یا نویز را به میزان کمینه می‌رساند.

انتخاب ۰/۱ نتیجه‌ی مناسبی برای حذف نواحی غیرآبی با مقادیر پایین شاخص (مانند سایه‌ها یا خاک‌های مرطوب) دارد. همچنین شاخص ۰/۱ توسط بسیاری از پژوهش‌ها برای جداسازی مناطق خشکی و آبی به‌عنوان یک استاندارد توصیه شده است. انتخاب حد آستانه به ماهواره‌هایی که استفاده می‌شوند نیز بستگی دارد. تجربیات قبلی نشان می‌دهند که ۰/۱ برای NDWI در شناسایی دقیق سطح آب بسیار کاربردی است. در پژوهش حاضر، برای حساسیت‌سنجی با اعداد ۰/۰۵، ۰/۱، ۰/۱۵، ۰/۲، و ۰/۲۵ تغییر مساحت آبی

استفاده شده است. مساحت دلتاهای رسوبی در دهانه براساس تفکیک محیط آبی خاکی و محیط گلی مشخص شده‌اند.

شاخص MNDWI به‌عنوان یک شاخص قدرتمند در شناسایی پیکسل‌های آب ارائه و به صورت گسترده استفاده شده است. مطابق رابطه‌ی ۴، در باند

³⁰ WaterThreshold

²⁹ Short Wave Infrared Radiation


جدول ۴. واحدهای ژئومورفولوژیکی بررسی شده در مطالعه حاضر.

Parameter	Unit	Satellite	Resolution	Period
Water/Dry area	Square meter	Landsat 7 and 8	15-30 (m/pixel)	1999-2019
Muddy area	Square meter	Landsat 7 and 8	15-30 (m/pixel)	1999-2019
Inlets delta	Square meter	Landsat 7 and 8	15-30 (m/pixel)	1999-2019


جهانی و محاسباتی به طور کامل و دقیق انجام شده‌اند. یافته‌های ارائه شده در فصل جاری، شامل ۴ بخش است: بخش اول، شامل تغییرات دلتای رسوبی در دهانه‌ی خورها در طی مدت پژوهش حاضر (به عنوان پارامتر وابسته) و بخش دوم، شامل استخراج داده‌ها از مشخصه‌های مورفولوژیکی درون خور است. در بخش سوم، دسته‌بندی و وزن‌دهی به بانک اطلاعاتی با مقایسه‌ی تغییرات دلتای دهانه و در بخش چهارم، پیش‌بینی مدل‌ها و مقایسه‌ی مدل‌ها صورت پذیرفته است.

– بخش اول. تغییرات دلتای رسوبی دهانه‌ی خورها

در بخش کنونی، الگوی مهاجرت تغییرات دلتای رسوبی و تغییرات مساحت دلتای رسوبی دهانه‌ها از طریق آنالیز تصاویر ماهواره‌ای در طول ۲۰ ساله‌ی پژوهش حاضر به انجام رسیده است. در شکل‌های ۸ الی ۱۰، مطالعه‌ی تغییرات دلتای رسوبی در دهانه‌ی سه خور و همچنین، الگوی فرسایش و انباشت رسوبی و تغییرات دلتای رسوبی دهانه‌ها مشاهده می‌شوند. رنگ‌های آبی و قرمز



شکل ۸. تغییرات دلتای رسوبی در دهانه‌ی خور میدانی، نشانگر تغییر دلتای رسوبی آن در طول زمان (رنگ آبی نشانگر رسوب‌گذاری و رنگ قرمز، نشانگر رسوب‌برداری).



شکل ۹. تغییرات دلتای رسوبی در دهانه‌ی خور تنگ، که نشانگر تغییر دلتای رسوبی دهانه‌های مذکور در طول زمان است (رنگ آبی، نشانگر رسوب‌گذاری و رنگ قرمز، نشانگر رسوب‌برداری).

حساسیت‌سنجی شده است، که به صورت نمودار در شکل ۷ مشخص شده است.


با افزایش حد آستانه، درصد مناطق آبی کاهش داشته است؛ که نشان می‌دهد با افزایش مقدار آستانه، فقط پیکسل‌های با مقدار بالا باقی مانده‌اند. در نمودار اخیر، با افزایش آستانه‌ی مساحت آبی به سرعت کاهش داشته است، که نشان می‌دهد که مقدار ۰/۱ کاملاً منطقی است؛ که اگر تغییر زیادی ایجاد نشود، یعنی نتایج نسبت به مقدار آستانه حساسیت کمتری دارند.

مناطق نیمه‌خشک با استفاده از مقادیر باندهای NIR و SWIR تشخیص یافته و با استفاده از detectSemiDry تعریف شده‌اند و سپس نقشه‌های خط ساحل و مناطق نیمه‌خشک به نمایش درآمده‌اند. مانند قسمت قبل، مقادیر مرزی برای تشخیص مناطق نیمه‌خشک تنظیم شده است، تا بهترین نتایج برای شرایط محیطی به دست آید. برای شناسایی نواحی که طی ۱ سال اصلاً آب نداشته باشند، می‌توان از شاخص‌هایی مانند NDVI (شاخص نسبت تطابق گیاهی) و MNDWI (شاخص نسبت تطابق آبی) استفاده کرد. مناطقی که هیچ نقطه‌ای در طی یک سال دیگر به آب نمی‌رسد، ممکن است NDVI و MNDWI منفی داشته باشند.


مناطق نیمه‌خشک با استفاده از مقادیر باندهای NIR و SWIR تشخیص یافته و با استفاده از detectSemiDry تعریف شده‌اند. سپس نقشه‌های خط ساحل و مناطق نیمه‌خشک به نمایش درآمده‌اند. NDVI و MNDWI محاسبه شده و مناطقی که همزمان NDVI کمتر از مقدار معین و MNDWI کمتر از مقدار معینی داشته‌اند، به عنوان مناطق بدون آب تشخیص داده شده‌اند. مقادیر ۰/۱ برای NDVI و -۰/۱ برای MNDWI به عنوان مقادیر شاخص تعیین شده‌اند.

۳. یافته‌ها


دسته‌بندی و استخراج داده‌های هواشناسی، داده‌های هیدروپنوماتیک، داده‌های




شکل ۷. تحلیل حساسیت برای انتخاب حد آستانه.



شکل ۱۱. تغییرات مساحت دلتای رسوبی دهانه (زبان‌های ماسه‌ای) در خور میدانی (ریچ) در دوره‌ی ۲۰ ساله.




شکل ۱۲. تغییرات مساحت دلتای رسوبی دهانه (زبان‌های ماسه‌ای) در خور تنگ در دوره‌ی ۲۰ ساله (BR: زمان شکست و تغییر موقعیت دلتای رسوبی).



شکل ۱۳. تغییرات مساحت دلتای رسوبی دهانه (زبان‌های ماسه‌ای) در خور گالک در دوره‌ی ۲۰ ساله (BR: زمان شکست و تغییر موقعیت دلتای رسوبی).

زمان‌هایی که تغییرات آنی در دلتای رسوبی دهانه ایجاد شده است، با BR (BREAK) در شکل‌های مذکور مشخص شده است. در خور تنگ، به دلیل وجود تومبلو و اتصال دلتای ماسه‌ای به تومبلو، تغییر شدید دلتای رسوبی در سال‌های ۲۰۰۶ الی ۲۰۱۴ ایجاد شده است. نتایج نشان می‌دهند که دلتاهای رسوبی در دهانه‌های خورهای منطقه‌ی مطالعاتی با یک سرعت و جهت در دوره‌ی تناوب یک زمان بلندمدت عمل می‌کنند (جدول ۵). شکسته شدن و جابجایی زبان‌های رسوبی در خورهای گالک و تنگ موجب پایین‌تر نشان دادن اعداد رگرسیون شده است، ولی در مقیاس تغییرات بلندمدت، رفتاری همانند رفتار خور میدانی از خود نشان داده‌اند. روند پایدار در تغییرات دلتای رسوبی خور میدانی می‌تواند به واسطه‌ی اندازه‌ی بزرگ خورهای مذکور نسبت به خور تنگ باشد. در جدول ۵، معادله‌ی رگرسیون برای تغییر دلتای رسوبی در هر دهانه در دوره تناوب در سال‌های ۱۹۹۹ تا ۲۰۱۹ ارائه شده است.



شکل ۱۰. تغییرات دلتای رسوبی در دهانه‌ی خور گالک، که نشانگر تغییر دلتای رسوبی دهانه‌های ذکر شده در طول زمان است (رنگ آبی، نشانگر رسوب‌گذاری و رنگ قرمز، نشانگر رسوب‌برداری).

به ترتیب نشانگر رسوب‌گذاری و رسوب‌برداری هستند. در ادامه، مساحت دلتای رسوبی در مدت زمان پژوهش از سال ۱۹۹۹ تا ۲۰۱۹ اندازه‌گیری شده است، که در شکل‌های ۱۱ الی ۱۳ ملاحظه می‌شوند.

تغییرات دلتاهای رسوبی در دهانه‌ی خور میدانی (شکل ۸) در دوره‌ی زمانی ۱۹۹۹ تا ۲۰۲۰ بوده است، که رنگ آبی نشانه‌ی نواحی رسوب‌گذاری و رنگ قرمز نشانه‌ی نواحی رسوب‌برداری است. همان‌طور که مشخص است، دهانه تمایل به ایجاد دلتای جزر داشته و به علت باریک بودن دهانه، دلتای جزر به وسیله‌ی اندرکنش موج و جزر و مد به بدنه‌ی پایین دست و بالادست دهانه چسبیده است. دهانه‌ی مذکور تحت سلطه‌ی انرژی مختلط و شکل‌گیری دهانه و دلتای رسوبی آن، تحت تعامل هم‌زمان موج و جزر و مد بوده است (مطابق شکل ۳).

تغییرات دلتاهای رسوبی در دهانه‌ی خور تنگ (شکل ۹) مربوط به دوره‌ی زمانی ۱۹۹۹ تا ۲۰۱۸ بوده است. همان‌گونه که مشخص است، رسوب‌برداری بیشتر از درون بدنه‌ی رسوبی چسبیده به تومبلو انجام شده و فرآیند غالب بر رسوب‌برداری، جزر و مد بوده است. همچنین، با افزایش سطح دلتای جزر در بیرون دهانه و حرکت رسوب ساحلی از شرق به غرب، رسوب‌گذاری در سمت بالادست دهانه مشاهده می‌شود.

تغییرات دلتاهای رسوبی در دهانه‌ی خور گالک (شکل ۱۰) مربوط به دوره‌ی زمانی ۱۹۹۹ تا ۲۰۲۴ بوده است. همان‌طور که ملاحظه می‌شود، دهانه هم به بالادست و هم به پایین دست مهاجرت کرده و تمایل به ایجاد دلتای جزر در دهانه وجود داشته است. به علت عرض باریک دهانه، دلتای جزر و زبان‌های ماسه‌ای به هم چسبیده‌اند تا دوباره به تعادل برسند.



نتایج تحلیل از رشد و قطع و تغییرات مساحت دلتای رسوبی در دهانه‌ی ۳ خور منطقه‌ی مطالعاتی در شکل‌های ۱۱ الی ۱۳ ملاحظه می‌شود؛ که مطابق آن‌ها، تغییر مورفولوژی دلتای رسوبی در ۳ خور از یک الگوی بلندمدت یکسانی پیروی می‌کند، اما الگوی کوتاه‌مدت متفاوتی نسبت به هم دارند، که در شکل‌های ۱۱ و ۱۲ کاملاً مشهود است. دلتای رسوبی خورهای تنگ و گالک در چند مورد، تغییرات آنی را به واسطه‌ی مورفولوژی ساختاری از خود نشان داده‌اند.

جدول ۵. معادله رگرسیون گسترش دلتای رسوبی در دهانه‌های خورهای میدانی گالک و تنگ.

Tidal inlet	Period	Regression equations	Correlation coefficient
Meydani	1999-2019	$y = -11318x + 2 \times 10^7$	$R^2 = 0.8881$
Galek	1999-2019	$y = -9206.8x + 2 \times 10^7$	$R^2 = 0.4478$
Tang	1999-2019	$y = -1435x + 2 \times 10^6$	$R^2 = 0.6128$


جدول ۶. متوسط تغییرات عرض دهانه‌ها و مساحت خورها در طی مدت پژوهش.

Khowr (Bay)	Average Inlet Width	Period	Average Khowr (Bay) Area
Meydani	1000-1300 m	1999-2019	62966576 m ²
Galek	600-800 m	1999-2019	6689731 m ²
Tang	200-250 m	1999-2019	6076130 m ²




شکل ۱۴. تفکیک محیط‌های خور میدانی (بنفش: فاقد دیتا؛ سبز: دائم خشک؛ آبی: گاهی آب (ناحیه ی گلی)؛ نارنجی: دائم آب (۲۰۱۵-۲۰۱۶).


شکل ۱۶. تفکیک محیط‌های خور تنگ (بنفش: فاقد دیتا، سبز: دائم خشک، آبی: گاهی آب (ناحیه ی گلی)؛ نارنجی: دائم آب (۲۰۱۵-۲۰۱۶).



شکل ۱۷. تغییرات محیط‌های آبی-گلی-خشکی در خور تنگ بین سال‌های ۱۹۹۹ تا ۲۰۱۹ بر حسب مترمربع.



شکل ۱۸. تغییرات محیط‌های آبی، گلی، و خشکی در خور گالک بین سال‌های ۱۹۹۹ تا ۲۰۱۹ بر حسب مترمربع.




شکل ۱۵. تفکیک محیط‌های خور گالک (بنفش: فاقد دیتا، سبز: دائم خشک)، آبی: گاهی آب (ناحیه ی گلی)؛ نارنجی: دائم آب (۲۰۱۵-۲۰۱۶).


– بخش دوم: نرخ تغییر بافت‌های مورفولوژیکی درون خورها

آنالیز تصاویر ماهواره‌ای به منظور استخراج داده‌های مورفولوژیکی درون خورها و تکمیل بانک اطلاعاتی، در شکل‌های ۱۴ الی ۱۶ مشاهده می‌شوند، که شامل ساختارهای مهمی از قبیل رصد تغییرات مساحت‌های آبی و خاکی در دهانه‌ی خور و همچنین رصد تغییرات مساحت آبی، خاکی، و گلی درون خور در سال‌های ۱۹۹۹ تا ۲۰۱۹ است. مشخصات ظاهری هر یک از خورها در جدول ۶ ارائه داده شده است.

نتایج تغییرات بافت‌های مورفولوژیکی درون خورها در شکل‌های ۱۷ الی ۱۹ مشاهده می‌شوند. شکل‌ها شامل تفکیک ۳ محیط همیشه آبی، همیشه خشک، و ناحیه‌ی گلی در درون خور هستند.



شکل ۲۱. نقاط، مشخص‌کننده‌ی درصد اثرگذاری هر مؤلفه در تغییرات دلتای رسوبی دهانه‌ی میدانی.




شکل ۲۲. نقاط مشخص‌کننده‌ی درصد اثرگذاری هر مؤلفه در تغییرات دلتای رسوبی دهانه‌ی تنگ.

بوده‌اند. در پارامترهای جهانی، همه‌ی داده‌ها در یک سطح قرار داشته‌اند. در داده‌های ژئومورفولوژیکی مساحت ناحیه‌هایی خشک و گلی مؤثرتر بوده است. در انتها، نیز برای داده‌های محاسباتی، داده‌ی LSTR و منشور جزر و مدی جزء پارامترهای اثرگذار و پارمتر P/M جزء کم‌تأثیرترین پارامترها در تغییرات دلتای رسوبی دهانه بوده‌اند.


– بخش چهارم: پیش‌بینی و مقایسه‌ی مدل‌ها

۳ مدل الگوریتم یادگیری ماشین در پژوهش حاضر استفاده شده است. با توجه به اینکه ۲۰٪ داده‌ها برای آزمون مدل و ۸۰٪ بقیه، برای آموزش مدل قرار داده شده‌اند، اندازه‌ی دهانه‌ی واقعی خورها با اندازه‌ی دهانه‌ی پیش‌بینی‌شده‌ی خورها برای ۵ سال به‌صورت تصادفی توسط ۳ مدل مذکور مقایسه شده است، که در جدول‌های ۷ الی ۹ ارائه شده‌اند. کم‌خطاترین پیش‌بینی توسط الگوریتم درخت تصمیم مدل‌سازی شده است، در جدول ۷ و در مرحله‌ی بعد، الگوریتم‌های ماشین بردار پشتیبان و شبکه‌ی چندلایه قرار گرفته‌اند. در الگوریتم درخت تصمیم، بهترین پیش‌بینی با کمترین درصد خطا برای خور میدانی صورت پذیرفته است، که می‌توان علت آن را اندازه‌ی اثرگذاری ۲ پارامتر اصلی مؤثر در خور میدانی دانست همچنین خور میدانی از لحاظ وسعت طبق جدول ۶، چند برابر خورهای گالک و تنگ بوده است. پیش‌بینی اخیر، در مدل ماشین بردار پشتیبان نیز صدق می‌کند.

در مدل ماشین بردار پشتیبان، کمترین خطای پیش‌بینی برای دهانه‌های خورهای میدانی و گالک و بیشترین خطای پیش‌بینی برای خور تنگ بوده است (جدول ۹). در مدل شبکه‌ی عصبی چندلایه، کم‌خطاترین پیش‌بینی مربوط به دهانه‌ی خور گالک و سپس دهانه‌ی خور تنگ بوده و بیشترین اندازه‌ی خطا برای دهانه‌ی خور میدانی ثبت شده است (جدول ۸).



شکل ۱۹. تغییرات محیط‌های آبی، گلی، و خشکی در خور میدانی بین سال‌های ۱۹۹۹ تا ۲۰۱۹ (مترمربع).



شکل ۲۰. نقاط مشخص‌کننده‌ی درصد اثرگذاری هر مؤلفه در تغییرات دلتای رسوبی دهانه‌ی گالک.

– بخش سوم: وزن‌دهی به پارامترهای مؤثر در تغییرات دلتای دهانه

۳ مدل ماشین بردار پشتیبان، درخت تصمیم، و شبکه‌ی چندلایه برای ارزیابی و پیش‌بینی تغییرات دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط در سواحل مکران استفاده شده‌اند. ۳۴ مؤلفه‌ی اثرگذار در پارامتر وابسته، که همان تغییرات دلتای رسوبی دهانه‌ی خور است، در جدول ۳ دسته‌بندی و کدگذاری شده‌اند. در مرحله‌ی فیچر سلکشن برای ۳ خور تنگ، گالک، و میدانی، مؤلفه‌های اثرگذار براساس مقدار اثرگذاریشان در پارامتر وابسته در شکل‌های ۲۰ الی ۲۲ دسته‌بندی شده‌اند؛ که مطابق نتایج آن‌ها، در بازه‌ی طولانی‌مدت منطقه‌ی مورد مطالعه در پژوهش حاضر، داده‌های جهانی که شامل بالاروی سطح دریاها، گرمایش جهانی، بارش‌های ابر، و انرژی اتمی‌بالانس کروی زمین هستند، مؤثرترین پارامترها در تغییرات دهانه در هر سه خور مذکور بوده‌اند. در مرتبه‌ی بعد، داده‌های سینوپتیکی مانند بارش، دما، تعداد روزهای بارانی، و تعداد روزهای طوفانی و داده‌های هیدرودینامیکی و داده‌های ژئومورفولوژی در مرحله‌ی بعدی اثرگذاری قرار گرفته‌اند.

پارامترهای اخیر برای هر خور به‌صورت مجزا می‌توانند متفاوت باشند. مطابق شکل ۲۲ مشخص است که برای مثال، خورهای تنگ و میدانی به شدت تحت تأثیر پارامترهای جهانی و پارامترهای سینوپتیکی قرار دارند در مقابل خور گالک (شکل ۱۹)، تحت تأثیر هم‌زمان هر ۴ مؤلفه قرار دارد.

نتایج شکل‌های ۲۰ الی ۲۲ همچنین نشان می‌دهند که در پارامترهای سینوپتیکی داده‌های بارش- تعداد روزهای بارانی و تعداد روزهای طوفانی، مؤثرترین پارامترها بوده‌اند. در پارامترهای هیدرودینامیکی، داده‌های جهت امواج، اندازه‌ی ارتفاع امواج، و دوره‌ی تناوب امواج مؤثرتر از مابقی پارامترها

جدول ۷. درصد خطای الگوریتم درخت تصمیم در پیش‌بینی تغییرات دهانه‌ی خور (برای ۳ خور مطالعه‌شده).

	Actual Inlet Width (Tang)	Predicted Width	Error %
1	36738	40330	9.7
2	35177	37539	6.7
3	59865	61846	3.3
4	44155	40330	5.6
5	39955	37539	6
	Actual Inlet Width (Meydani)	Predicted Width	Error %
1	1378458	1392048	0.9
2	1162961	1278613	9.9
3	1196174	1204185	0.6
4	1375454	1319233	4
5	1171891	1175579	0.3
	Actual Inlet Width (Galak)	Predicted Width	Error %
1	693218	653391	5.7
2	446192	470013	5.3
3	596182	496802	16
4	524150	676746	29
5	590394	473756	19

جدول ۸. درصد خطای الگوریتم شبکه‌ی عصبی چندلایه در پیش‌بینی تغییرات دهانه‌ی خور، برای ۳ خور مطالعه‌شده.

	Actual Inlet Width (Tang)	Predicted Width	Error (%)
1	36738	21572	41
2	35177	63168	79
3	59865	59588	0.4
4	44155	47881	8.4
5	39955	48841	22
	Actual Inlet Width (Meydani)	Predicted Width	Error %
1	1378458	1455560	5.5
2	1162961	1581069	35
3	1196174	1594523	33
4	1375454	924316	32
5	1171891	2408803	100
	Actual Inlet Width (Galak)	Predicted Width	Error %
1	693218	701779	1.2
2	446192	619834	38
3	596182	686445	15
4	524150	881653	68
5	590394	698208	18

سه معیار MSE و MAE و شاخص ویلموت برای ۳ مدل مذکور اجرا شده‌اند. شاخص MSE در ریاضیات و آمار، میانگین توان دوم خطاها، روشی برای برآورد میزان خطاست، که در واقع تفاوت بین مقادیر تخمین زده‌شده و تخمینی است. میانگین خطای مطلق یا MAE، یک معیار معروف برای مسائل رگرسیون است، که واحدهای خطا با واحدهای متغیر هدف مطابق هستند. میانگین خطای مطلق، قدرمطلق تفاوت بین مقادیر پیش‌بینی‌شده و واقعی را اندازه‌گیری می‌کند. ۳ معیار اخیر برای مقایسه‌ی عملکرد ۳ مدل الگوریتم یادگیری ماشین با یکدیگر مناسب هستند؛ که طبق نتایج به‌دست‌آمده‌ی آن‌ها،

جدول ۹. درصد خطای الگوریتم ماشین بردار پشتیبان در پیش‌بینی تغییرات دهانه‌ی خور برای ۳ خور مطالعه‌شده.

	Actual Inlet Width (Tang)	Predicted Width	Error %
1	36738	59598	62
2	35177	59660	69
3	59865	59649	0.3
4	44155	59594	35
5	39955	59622	49
	Actual Inlet Width (Meydani)	Predicted Width	Error %
1	1378458	1313533	4.7
2	1162961	1313529	12
3	1196174	1313529	9.8
4	1375454	1313543	4.5
5	1171891	1313519	12
	Actual Inlet Width (Galak)	Predicted Width	Error %
1	693218	652962	5
2	446192	652928	50
3	596182	652931	9.5
3	524150	652955	24
5	590394	652992	10

جدول ۱۰. مقایسه‌ی ۳ مدل الگوریتمی پژوهش حاضر با خطای مطلق و میانگین مربع خطا و ویلموت ارتقاء یافته در پیش‌بینی تغییرات دهانه‌ی خور گالک.

Galak	Wilmot	MSE	MAE
SVM	0.27	189971628	12865
MLP	0.31	1139827619	28407
Decision Tree	0.36	4953270	1469.92

جدول ۱۱. مقایسه‌ی ۳ مدل الگوریتمی پژوهش حاضر با خطای مطلق و میانگین مربع خطا و ویلموت ارتقاء یافته در پیش‌بینی تغییرات دهانه‌ی خور میدانی.

Meydani	Wilmot	MSE	MAE
SVM	0.44	2895937844	48953.09
MLP	0.086	9504305500	73317.14
Decision Tree	0.795	294548789.1	13818.4

جدول ۱۲. مقایسه‌ی ۳ مدل الگوریتمی پژوهش حاضر با خطای مطلق و میانگین مربع خطا و ویلموت ارتقاء یافته در پیش‌بینی تغییرات دهانه‌ی خور تنگ.

Tang	Wilmot	MSE	MAE
SVM	0.40	189971628.3	12865.02
MLP	0.46	1139827619	28407.22
Decision Tree	0.799	4953270.014	1469.92

در خور گالک برای پیش‌بینی تغییرات دلتای دهانه، بهترین مدل، درخت تصمیم و ضعیف‌ترین مدل، ماشین بردار پشتیبان بوده است. شاخص ارتقاء یافته‌ی ویلموت هم برای ارزیابی پیش‌بینی‌شده‌ی مدل با واقعیت استفاده شده است؛ که مطابق آن، مدل درخت تصمیم، مناسب‌ترین مدل برای پیش‌بینی تغییرات دلتای دهانه‌ی خورهای سواحل مکران بوده است (جدول‌های ۱۰ الی ۱۲).

در خور میدانی، بهترین پیش‌بینی مربوط به درخت تصمیم و ضعیف‌ترین

در پژوهش حاضر، به‌منظور شناخت و وزن‌دهی به پارامترهای مؤثر در تغییرات دلتای رسوبی دهانه (پارامتر وابسته)، ۳۴ پارامتر از ۵ بانک داده‌ای مطابق جدول ۵ استفاده شده‌اند. برای اینکه از ازدیاد داده‌ها جلوگیری شود، داده‌هایی که براساس سابقه‌ی مطالعاتی اثرگذارتر بوده‌اند، انتخاب شده و برای اینکه وزن‌دهی به‌درستی انجام شود، هیچ‌گونه فرضی به داده‌ها نسبت داده نشده است. پس از وزن‌دهی به ۳۴ پارامتر به‌عنوان پارامترهای مستقل پژوهش مشخص شده است که برخی پارامترها، در دلتای هر ۳ دهانه قوی و اثرگذار ظاهر شده‌اند. با توجه به گراف‌های شکل‌های ۲۰ الی ۲۲ مشخص شده است که کدهای ۲۰ تا ۲۷، مربوط به داده‌های هواشناسی (بارش، تعداد روزهای طوفانی سال، و تعداد روزهای بارانی) و داده‌های مقیاس جهانی (گرمایش جهانی، بالاروی سطح دریا، باریاستاتیک، و انرژی ایمبالانس کوهی زمین)، جزء پارامترهای به‌شدت مؤثر در تغییرات دلتای رسوبی دهانه‌های خورهای تحت سلطه‌ی انرژی مختلط مکران هستند. اینکه اثرگذاریشان در دلتای دهانه به چه صورتی می‌تواند باشد، مورد مطالعه و ارزیابی پژوهش حاضر نبوده و فقط شناخت اندازه‌ی اثرگذاری پارامترهای ذکرشده، مهم بوده است؛ لذا می‌توان نحوه‌ی اثرگذاری هر کدام از پارامترهای مذکور را جدا از هم یا به‌صورت ترکیبی در پژوهش‌های آتی ارزیابی کرد.

در راستای هدف چهارم پژوهش حاضر، سه مدل الگوریتم یادگیری ماشین، یعنی الگوریتم‌های ماشین بردار پشتیبان، درخت تصمیم، و شبکه‌ی عصبی چندلایه براساس سابقه‌ی پژوهش و استفاده در محیط‌های ساحلی ساخته شده‌اند. ۲۰٪ داده‌ها برای آزمون مدل و ۸۰٪ داده‌ها برای راه‌اندازی و آموزش مدل استفاده شده‌اند. بهترین پیش‌بینی از تغییرات دلتای رسوبی در دهانه‌ها مربوط به مدل درخت تصمیم و ضعیف‌ترین پیش‌بینی مربوط به مدل شبکه‌ی عصبی چندلایه بوده است (جدول‌های ۷ الی ۹). با توجه به جدول ۷، کم‌خطا‌ترین پیش‌بینی توسط مدل درخت تصمیم مربوط به پیش‌بینی تغییرات دلتای دهانه‌ی میدانی با میانگین خطای ۳/۱۴٪ و دلتای رسوبی دهانه‌ی خور تنگ با میانگین خطای ۵٪ بوده است. بیشترین خطا مربوط به پیش‌بینی تغییرات دلتای رسوبی دهانه‌ی خور گالک با میانگین خطای ۱۵٪ بوده است. نتایج مشخص کرده است که مدل درخت تصمیم برای پیش‌بینی و ارزیابی دلتای رسوبی دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط مکران بسیار کارآمد و قابل اتکاست. با توجه به جدول ۸ مشخص است که مدل ماشین بردار نیز برای ارزیابی و پیش‌بینی تغییرات دلتای رسوبی دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط مکران کفایت لازم را دارد. علت پیش‌بینی دقیق‌تر دلتای رسوبی دهانه‌ی میدانی را می‌توان به ۲ عامل نسبت داد: ۱) دلتای دهانه‌ی میدانی مطابق شکل ۱۰، کم‌نوسان‌ترین دلتای رسوبی در بین دهانه‌های مذکور به‌علت نداشتن عارضه‌ی خاص در دهانه (مانند عارضه‌ی تومبولو در دهانه‌ی خور تنگ) بوده است. ۲) با توجه به شکل ۲۰ مشخص است که داده‌های اثرگذار در تغییرات دلتای رسوبی دهانه در طی ۲۰ سال مطالعه‌ی انجام‌شده، محدودتر از دلتای دهانه‌ی خورهای تنگ و گالک بوده است. پس نتیجه می‌شود که هر چه دلتای دهانه تحت تعاملات کمتری از عارضه‌های خاص و همچنین اثرگیری از پارامترهای محدودتری باشد، پیش‌بینی بهتری توسط مدل یادگیری ماشین انجام می‌شود. از طرفی مشخص شده است که هر چه دلتای رسوبی دهانه، نوسان‌های بالاتری را تجربه کند و پارامترهای مؤثر در تغییرات مذکور بیشتر باشد، پیش‌بینی مدل مشکل‌تر می‌شود (نتایج ذکرشده مربوط به دلتای دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط سواحل مکران است). در مدل ماشین بردار (مطابق جدول ۸)، کمترین خطا مربوط به دلتای رسوبی دهانه‌ی

پیش‌بینی، مربوط به شبکه‌ی چندلایه بوده است (جدول ۱۱). در خور تنگ نیز بهترین پیش‌بینی، الگوریتم درخت تصمیم و ضعیف‌ترین پیش‌بینی مربوط به شبکه‌ی عصبی چندلایه بوده است (جدول‌های ۱۰ و ۱۲).

۴. جمع‌بندی، بحث، و نتیجه‌گیری

با توجه به ضرورت‌های مطرح‌شده در مقدمه، در مطالعه‌ی حاضر، ۴ هدف اصلی دنبال شده است:

- هدف اول، محاسبه‌ی تغییرات دلتای رسوبی دهانه‌ها (به‌عنوان پارامتر وابسته)؛

- هدف دوم، وزن‌دهی به پارامترهای اثرگذار در تغییرات دلتای رسوبی دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط مکران (به‌عنوان پارامترهای مستقل)؛

- هدف سوم، پیش‌بینی تغییرات دلتاهای رسوبی ذکرشده به وسیله‌ی مدل‌های یادگیری ماشین، شامل: ماشین بردار پشتیبان، درخت تصمیم، و شبکه‌ی عصبی چندلایه؛

- هدف چهارم، مقایسه‌ی مدل‌های ذکرشده با یکدیگر.

دلتای رسوبی دهانه‌ی خورهای سواحل مکران مطابق شکل ۳ و مدل هیدرودینامیکی هایس، جزء خورهای تحت سلطه‌ی انرژی مختلط هستند و تغییرات دلتای رسوبی دهانه تحت عملکرد مؤثر و همزمان موج و جزر و مد و دیگر پارامترها قرار دارد. به گفته‌ی هایس و فیتزجرالد (۲۰۱۳)، این تیپ از دهانه‌ها جزء متغیرترین و پیچیده‌ترین مناطق ساحلی به حساب می‌آیند و درک تعاملات ذکرشده، نیاز به طیف وسیع از داده‌ها در بُعد زمانی دارد.

شکل‌های ۸ الی ۱۰ و همچنین شکل‌های ۱۱ الی ۱۴، تغییرات مساحت دلتای رسوبی دهانه‌ها و همچنین مسیر و الگوی تغییرات فرسایشی و رسوب‌گذاری را نشان می‌دهند. مدل فرسایش و رسوب‌گذاری در دهانه، گویای این است که خورهای تحت سلطه‌ی انرژی مختلط در سواحل مکران تمایل به ایجاد دلتای حاصل از جزر در دهانه‌ی خود دارند و دلتای جزر مذکور، رفتار دوره‌ای از خود نشان می‌دهد. پس از هر کاهش مساحت دلتای رسوبی در دهانه، رسوب‌گذاری در دلتای جزر و پس از هر رسوب‌گذاری، فرسایش بدنه‌ی رسوبی دلتای جزر و بدنه‌ی دو سمت بیرونی دهانه‌ی رو به دریا مشاهده می‌شود. دهانه در هر دوره با اعمال هر نیروی خارجی، دوباره تمایل به ایجاد تعادل دارد. در بلندمدت، کاهش مساحت دلتای رسوبی در دهانه‌ها مشاهده می‌شود. شکل‌های ۱۱ الی ۱۴ گویای این مطلب هستند که در طول مدت ۲۰ سال مطالعه در پژوهش حاضر، دلتای رسوبی به‌طورپیوسته کاهش داشته و دهانه‌ی آن وسیع‌تر شده است. در بازه‌های زمانی کوتاه‌مدت، نوسان‌هایی در مساحت دلتای رسوبی در دهانه‌های خورهای تنگ و گالک مشاهده می‌شود. این در حالی است که در دهانه‌ی خور میدانی به واسطه‌ی عریض‌تر بودن دهانه و وسیع‌تر بودن مساحت خور (مطابق جدول ۶)، کمترین نوسان‌های دوره‌ای مشاهده شده است. در بلندمدت، دهانه‌ها در هر ۳ دلتای رسوبی، مشابه یکدیگر رفتار کرده و کمترین نوسان‌های دوره‌ای در تغییرات دلتای رسوبی برای دهانه‌ی میدانی و بیشترین نوسان‌ها مربوط به دهانه‌ی گالک بوده است (جدول ۵). محاسبه‌ی تغییرات المان‌های مورفولوژیکی درون خور مانند مساحت ناحیه‌ی آبی، خشکی، و گلی مشخص کرده است که رفتار المان‌های اخیر نیز دوره‌ای است و با یک چرخه‌ی تقریباً ۴ ساله نوسان می‌کنند (شکل‌های ۱۷ الی ۱۹).

۵) ترتیب اثرگذاری پارامترها در تغییرات دهانه به ترتیب عبارت بوده اند از سلطه‌ی پارامترهای: جهانی، هواشناسی، ژئومورفولوژی، و هیدرودینامیکی.

۶) در پارامترهای هواشناسی، پارامترهای بارش، تعداد روزهای بارانی سال، و تعداد روزهای طوفانی سال مؤثرترین پارامترها در تغییرات دلتای رسوبی دهانه‌ها بوده‌اند.

۷) در پارامترهای هیدرودینامیکی، پارامترهای ارتفاع، جهت، و دوره‌ی تناوب متوسط امواج، مؤثرترین پارامترها در تغییرات دلتای رسوبی دهانه‌ها بوده‌اند.

۸) در پارامترهای ژئومورفولوژیکی، پارامترهای تغییرات ناحیه‌ی خشک و گلی خور، مؤثرترین پارامترها در تغییرات دلتای رسوبی دهانه‌ها بوده‌اند.

۹) کمترین خطای پیش‌بینی مدل‌های یادگیری ماشین مربوط به درخت تصمیم بوده است، که برای خور میدانی: دقت ۹۷٪، برای خور تنگ: دقت ۹۴٪، و برای خور گالک: دقت ۸۵٪ را ثبت کرده است.

۱۰) بیشترین خطای پیش‌بینی مدل‌های یادگیری ماشین مربوط به شبکه‌ی چندلایه بوده است، که برای خور میدانی: دقت ۵۹٪، برای خور تنگ: دقت ۷۰٪، و برای خور گالک: دقت ۷۲٪ را ثبت کرده است.

۱۱) مدل ماشین بردار پشتیبان هم تقریباً نتایج معقولی ارائه کرده است، که برای خور میدانی: دقت ۹۱٪، برای خور تنگ: دقت ۵۷٪، و برای خور گالک: دقت ۸۱٪ را ثبت کرده است.

۱۲) کمترین خطای پیش‌بینی درخت تصمیم مربوط به خور میدانی بوده است، که به دلیل تأثیرپذیری بیشتر آن از عوامل جهانی مانند بالاروی بوده است، که سبب ثبت نتایج با دقت بالاتری شده است.

۱۳) ارزیابی پیش‌بینی مدل‌ها با ۳ شاخص MSE و MAE و شاخص ارتقاء یافته‌ی ویلموت نشان داد که مدل مناسب در پیش‌بینی تغییرات دهانه‌ی خورهای تحت سلطه‌ی انرژی مختلط در دریای مکران، مدل درخت تصمیم و ضعیف‌ترین عملکرد، مربوط به شبکه‌ی چندلایه بوده است.

خورهای میدانی و گالک و بیشترین خطا برای دلتای خور تنگ بوده است، که رفتاری مشابه با مدل درخت تصمیم داشته است.

در یک جمع‌بندی کلی از پژوهش حاضر می‌توان اظهار کرد هر خور، کلاس هیدرودینامیکی و پیکربندی مختص به خود را دارد و با توجه به ساحلی که در آن واقع شده و نیروهای هیدرودینامیکی که بر آن مؤثر بوده است، باید ارزیابی مستقلی صورت گیرد. دهانه‌های خورهای سواحل مکران تمایل به فرسایش و رسوب‌گذاری در دلتای جزر و بدنه‌ی بیرونی دهانه‌ی خور را دارند. دلتای رسوبی جزر در دهانه‌های اخیر، رفتار چرخه‌ای از رسوب‌گذاری و فرسایش و تعادل دوباره را داشته است. همچنین مشخص شده است که داده‌های سینوپتیکی و داده‌های جهانی به شدت در عملکرد دلتاهای موردنظر مؤثر بوده‌اند. مدل‌های یادگیری ماشین برای پیش‌بینی و ارزیابی تغییرات دلتای دهانه‌ی خورها کارآمد هستند. همچنین، بهترین مدل برای پیش‌بینی تغییرات دلتاهای رسوبی مذکور، درخت تصمیم بوده است.

با توجه به مطالعه‌ی صورت‌گرفته، این نتایج به‌دست آمده‌اند:

۱) الگوی بلندمدت تغییرات دهانه‌ی هر ۳ خور مشابه یکدیگر بوده است، اما الگوی کوتاه‌مدت متفاوتی داشته‌اند.

۲) دهانه تمایل به ایجاد دلتای رسوبی جزر داشته و الگوی فرسایش و رسوب‌گذاری در دهانه به‌صورت چرخه‌ای با دوره‌ی ۴ ساله بوده است.

۳) نتایج نشان داده است الگوی بلندمدت تغییرات دهانه‌ی خورهای مذکور، تحت سلطه‌ی پارامترهای جهانی (گلوبال) مانند بالاروی سطح دریاها بوده است، اما الگوی کوتاه‌مدت تحت تأثیر عوامل ساختاری مانند مساحت یا اندازه‌ی دهانه و وجود عارضه‌های خاص تغییر کرده است.

۴) اثرگذارترین پارامترها در تغییرات دهانه، پارامترهای جهانی مانند بالاروی سطح دریاها، گرمایش جهانی، باریاستاتیک، و انرژی ایملانس کوهی زمین بوده‌اند.

References- منابع

1. Fitzgerald, D.M., 1984. Interactions between the ebb-tidal delta and landward shoreline; Price Inlet, South Carolina. *Journal of Sedimentary Research*, 54(4), pp.1303-1318. <https://doi.org/10.1306/212F85C6-2B24-11D7-8648000102C1865D>
2. Elias, E.P. and van der Spek, A.J., 2006. Long-term morphodynamic evolution of Texel Inlet and its ebb-tidal delta (The Netherlands). *Marine Geology*, 225(1-4), pp.5-21. <https://doi.org/10.1016/j.margeo.2005.09.008>
3. Hein, C.J., Fallon, A.R., Rosen, P., Hoagland, P., Georgiou, I.Y., FitzGerald, D.M., Morris, M., Baker, S., Marino, G.B. and Fitzsimons, G., 2019. Shoreline dynamics along a developed river mouth barrier island: Multi-decadal cycles of erosion and event-driven mitigation. *Frontiers in Earth Science*, 7, p.103. <https://doi.org/10.3389/feart.2019.00103>
4. Maleki, S., Adjami, M. and Ahmadi, A., 2024. Numerical Modeling of Swash Zone Morphological Processes in Coarse-Grained Beaches with Xbeach Open-Source Model. *Sharif Journal of Civil Engineering (SJCE)*, 40(3), pp.117-137. <https://doi.org/10.24200/j30.2024.63280.366>
5. Hayes, M.O. and FitzGerald, D.M., 2013. Origin, evolution, and classification of tidal inlets. *Journal of Coastal Research*, 69, pp.14-33. https://doi.org/10.2112/SI_69_3
6. Davis Jr, R.A. and Hayes, M.O., 1984. What is a wave-dominated coast?. In: *Developments in sedimentology*, 39, pp.313-329. Elsevier. <https://doi.org/10.1016/S0070->

4571(08)70152-3

7. Hayes, M., 1975. Morphology of sand accumulations in estuaries, in: L.E. Cronin (ed.), *Estuarine Research*. Academic Press, New York, 2, pp.3-22. <https://doi.org/10.1016/B978-0-12-197502-9.50006-X>
8. Georgiou, I.Y., FitzGerald, D.M. and Hanegan, K.C., 2024. Storm and tidal interactions control sediment exchange in mixed-energy coastal systems. *PNAS Nexus*, 3(2), p.pgac042. doi.org/10.1093/pnasnexus/pgac042
9. Herrling, G. and Winter, C., 2018. Tidal inlet sediment bypassing at mixed-energy barrier islands. *Coastal Engineering*, 140, pp.342-354. doi.org/10.1016/j.coastaleng.2018.08.008
10. Karunarathna, H., Reeve, D. and Spivack, M., 2008. Long-term morphodynamic evolution of estuaries: an inverse problem. *Estuarine, Coastal and Shelf Science*, 77(3), pp.385-395. <https://doi.org/10.1016/j.ecss.2007.09.029>
11. Wang, Z.B., Van Maren, D.S., Ding, P.X., Yang, S.L., Van Prooijen, B.C., De Vet, P.L.M., Winterwerp, J.C., De Vriend, H.J., Stive, M.J.F., and He, Q., 2015. Human impacts on morphodynamic thresholds in estuarine systems. *Continental Shelf Research*, 111, pp.174-183. <https://doi.org/10.1016/j.csr.2015.08.009>
12. Dam, G., Van der Wegen, M., Labeur, R.J., and Roelvink, D., 2016. Modeling centuries of estuarine morphodynamics in the Western Scheldt estuary. *Geophysical Research Letters*, 43(8), pp.3839-3847. <https://doi.org/10.1002/2015GL066725>
13. Luan HuaLong, L.H., Ding PingXing, D.P., Wang ZhengBing, W.Z., and Ge JianZhong, G.J., 2017. Process-based morphodynamic modeling of the Yangtze Estuary at a decadal timescale: controls on estuarine evolution and future trends. *Geomorphology*. <https://doi.org/10.1016/j.geomorph.2017.04.016>
14. Xie, D., Gao, S., Wang, Z.B., Pan, C., Wu, X., and Wang, Q., 2017. Morphodynamic modeling of a large inside sandbar and its dextral morphology in a convergent estuary: Qiantang Estuary, China. *Journal of Geophysical Research: Earth Surface*, 122(8), pp.1553-1572. <https://doi.org/10.1002/2017JF004293>
15. Yuan, B., Sun, J., Lin, B. and Zhang, F., 2020. Long-term morphodynamics of a large estuary subject to decreasing sediment supply and SLR. *Global and Planetary Change*, 191, p.103. doi.org/10.1016/j.gloplacha.2020.103212
16. Wang, Z.B., Hoekstra, P., Burchard, H., Ridderinkhof, H., De Swart, H.E. and Stive, M.J.F., 2012. Morphodynamics of the Wadden Sea and its barrier island system. *Ocean & Coastal Management*, 68, pp.39 <https://doi.org/10.1016/j.ocecoaman.2011.12.022>
17. Hibma, A., Stive, M.J.F. and Wang, Z.B., 2004. Estuarine morphodynamics. *Coastal Engineering*, pp.765-778. doi.org/10.1016/j.coastaleng.2004.07.008
18. Fagherazzi, S., Edmonds, D.A., Nardin, W., Leonardi, N., Canestrelli, A., Falcini, F., Jerolmack, D.J., Mariotti, G., Rowland, J.C. and Slingerland, R.L., 2015. Dynamics of river mouth deposits. *Reviews of Geophysics*, 53(3), pp.642-672. <https://doi.org/10.1002/2014RG000451>
19. Roscher, R., Bohn, B., Duarte, M.F. and Garcke, J., 2020. Explainable machine learning for scientific insights and discoveries. *IEEE Access*, 8, pp.42200-42216. <https://doi.org/10.1109/ACCESS.2020.2976199>
20. Zhang, X.D., 2020. *A matrix algebra approach to artificial intelligence*. [book]
21. Benz, U.C., Hofmann, P., Willhauck, G., Lingenfelder, I. and Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), pp.239-258. <https://doi.org/10.1016/j.isprsjprs.2003.10.02>
22. Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), pp.2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
23. Aiazzi, B., Alparone, L., Baronti, S. and Garzelli, A., 2002. Context-driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 40(10), pp.2300-2312. <https://doi.org/10.1109/TGRS.2002.803623>
24. Liu, J., Li, J., Li, W. and Wu, J., 2016. Rethinking big data: A review on the data quality and usage issues. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, pp.134-142. <https://doi.org/10.1016/j.isprsjprs.2015.11.06>
25. LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *Nature*, 521(7553), pp.436-444. <https://doi.org/10.1038/nature14539>
26. Park, D.H., Kim, H.K., Choi, I.Y. and Kim, J.K., 2012. A literature review and classification of recommender systems research. *Expert Systems with Applications*, 39(11), pp.10059-10072. <https://doi.org/10.1016/j.eswa.2012.02.038>
27. Peponi, A., Morgado, P. and Trindade, J., 2019. Combining artificial neural networks and GIS fundamentals for coastal erosion prediction modeling. *Sustainability*, 11(4), p.975. <https://doi.org/10.3390/su11040975>
28. Abouhalima, M., das Neves, L., Taveira-Pinto, F. and Rosa-Santos, P., 2024. Machine Learning in Coastal Engineering: Applications, Challenges, and Perspectives. *Journal of Marine Science and Engineering*, 12(4), p.638. <https://doi.org/10.3390/jmse12040638>
29. Juan, N.P. and Valdecantos, V.N., 2022. Review of the application of Artificial Neural Networks in ocean engineering. *Ocean Engineering*, 259, p.111947. <https://doi.org/10.1016/j.oceaneng.2022.111947>

30. Kumar, L., Afzal, M.S. and Afzal, M.M., 2020. Mapping shoreline change using machine learning: a case study from the eastern Indian coast. *Acta Geophysica*, 68(4), pp.1127-1143. <https://doi.org/10.1007/s11600-020-00454-9>
31. van Maanen, B., Coco, G., Bryan, K.R. and Ruessink, B.G., 2010. The use of artificial neural networks to analyze and predict alongshore sediment transport. *Nonlinear Processes in Geophysics*, 17(5), pp.395-404. <https://doi.org/10.5194>
32. Kabiri-Samani, A.R., Aghaee-Tarazjani, J., Borghei, S.M. and Jeng, D.S., 2011. Application of neural networks and fuzzy logic models to long-shore sediment transport. *Applied Soft Computing*, 11(2), pp.2880-2887. <https://doi.org/10.1016/j.asoc.2010.11.021>
33. Yoon, H.D., Cox, D.T. and Kim, M., 2013. Prediction of time-dependent sediment suspension in the surf zone using artificial neural network. *Coastal engineering*, 71, pp.78-86. <https://doi.org/10.1016/j.coastaleng.2012.08.005>
34. Wang, Y., Chen, J., Cai, H., Yu, Q. and Zhou, Z., 2021. Predicting water turbidity in a macro-tidal coastal bay using machine learning approaches. *Estuarine, Coastal and Shelf Science*, 252, p.107276. <https://doi.org/10.1016/j.ecss.2021.107276>
35. Salcedo, F., Harter, C. and Fenical, S., 2019, September. Predicting Long-Term Coastal Conditions in San Francisco Bay and Other Estuaries with the Use of Supervised Neural Networks. In *15th Triennial International Conference* (pp. 101-111). Reston, VA: American Society of Civil Engineers. <https://ascelibrary.org/doi/abs/10.1061/9780784482629.010>
36. Guillou, N. and Chapalain, G., 2021. Machine learning methods applied to sea level predictions in the upper part of a tidal estuary. *Oceanologia*, 63(4), pp.531-544. <https://doi.org/10.1016/j.oceano.2021.07.003>
37. Múnera, S., Osorio, A.F. and Velásquez, J.D., 2014. Data-based methods and algorithms for the analysis of sandbar behavior with exogenous variables. *Computers & geosciences*, 72, pp.134-146. <https://doi.org/10.1016/j.cageo.2014.07.009>
38. Fannassi, Y., Ennouali, Z., Hakkou, M., Benmohammadi, A., Al-Mutiry, M., Elbisy, M.S. and Masria, A., 2023. Prediction of coastal vulnerability with machine learning techniques, Mediterranean coast of Tangier-Tetouan, Morocco. *Estuarine, Coastal and Shelf Science*, 291, p.108422. <https://doi.org/10.1016/j.ecss.2023.108422>
39. 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>
40. Rajasekaran, S., Gayathri, S. and Lee, T.L., 2008. Support vector regression methodology for storm surge predictions. *Ocean Engineering*, 35(16), pp.1578-1587. <https://doi.org/10.1016/j.oceaneng.2008.08.004>
41. Misra, A., Vojinovic, Z., Ramakrishnan, B., Luijendijk, A. and Ranasinghe, R., 2018. Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imagery. *International Journal of Remote Sensing*, 39(13), pp.4431-4450. <https://doi.org/10.1080/01431161.2017.1421796>
42. James, S.C., Zhang, Y. and O'Donncha, F., 2018. A machine learning framework to forecast wave conditions. *Coastal Engineering*, 137, pp.1-10. <https://doi.org/10.1016/j.coastaleng.2018.03.004>
43. Beuzen, T. and Splinter, K., 2020. Machine learning and coastal processes. In *Sandy beach morphodynamics* (pp. 689-710). Elsevier. <https://doi.org/10.1016/B978-0-08-102927-5.00028-X>
44. Iran Ports and Maritime Organization, 2013. Monitoring and simulation studies of the coasts of Hormozgan province, *report on sedimentation studies*. [in Persian].
45. Iran Ports and Maritime Organization, 2016. ICZM inspection plan of the coasts of Hormozgan province, sedimentary reports.
46. Ghanavati, E., Shah-Hosseini, M. and Marriner, N., 2021. Analysis of the Makoran coastline of Iran's vulnerability to global sea-level rise. *Journal of Marine Science and Engineering*, 9(8), p.891. Available at: <https://doi.org/10.3390/jmse9080891>
47. Dadashzadeh, Z., Shayan, S., et al., 2019. Analysis of coastal morphodynamics with the aim of determining the boundary of sediment cells (case study: Hormozgan province). *Quantitative Geomorphology Research*, 9(2), pp.20. <https://doi.org/10.22113/jmst.2018.126521.2144>
48. Zakeri, E., Jabari, A., Adjami, M. and Rezaei, A., 2019. Effects of environmental parameters on the morphology of the beach cu sps of Roddic Port. *Sharif Journal of Civil Engineering (SJCE)*, 35(2), pp.35-50. <https://doi.org/10.24200/j30.2018.2261.2152>