

Assessment of Mangrove Forest Degradation in Coastal Watersheds Using Satellite Data

Laleh Sharifipour¹, Marzieh Rezai^{2*}, Mohammad Kazemi³, Ali Reza Nafarzadegan⁴, Rasool Mahdavi Najafabadi⁵

Received: 16-06-2025, Revised: 24-07-2025, Accepted: 29-07-2025, Published: 29-07-2025

<https://doi.org/10.22034/19.68.7>

Extended Abstract

Introduction

Mangrove forests, consisting of evergreen trees that grow along the coasts of adjacent sea watersheds, estuaries, are one of the most productive ecosystems in the world. They provide food for humans and wildlife and also play a major role in protecting and stabilizing coastlines, preventing soil erosion and sequestering carbon. Mangroves are suitable habitats for the reproduction of a variety of fish, crabs, amphibians, mammals, birds and arthropods. Due to the increasing pressure and stress caused by human activities, the destruction of mangrove forests has been accelerated. Therefore, monitoring the process and estimating the extent of destruction of these ecosystems provides a comprehensive view for their restoration and protection. While field monitoring of mangrove forests is difficult and costly, recent advances in access to remote sensing data, image processing, information technology and computing, as well as advancements in human technology, have provided an opportunity for continuous and systematic monitoring of mangrove forests. Platforms such as Google Earth Engine (GEE) provide access to satellite imagery and the ability to analyze spatiotemporal changes. These platforms can be used to calculate and analyze vegetation indices. In this study, vegetation indices were classified using ground-based reference data and matched with satellite data, and the accuracy of each index in the classification was estimated.

Materials and Methods

In the present study, by comparing ground reference data and satellite data in 2019 and 2024, an attempt has been made to provide a reliable classification to show the ecological status and health status of mangrove trees in the Tyab and Kolahi regions with an area of 126.31 square kilometers. In this regard, Sentinel-2 satellite images with a spatial resolution of 10 meters were

1. Ph.D. Student in Desert Management and Control, Department of Natural Resources Engineering, University of Hormozgan, Bandarabaas, Iran, l.sharifipour.phd@hormozgan.ac.ir

2. Corresponding Author and Associate Professor, Department of Natural Resources Engineering, University of Hormozgan, Bandarabaas, Iran, m.rezai@hormozgan.ac.ir

3. Associate Professor, Department of Hormoz Studies and Research Center, University of Hormozgan, Bandarabaas, Iran, mohamad.kazemi86@gmail.com

4. Associate Professor, Department of Natural Resources Engineering, University of Hormozgan, Bandarabaas, Iran, a.r.nafarzadegan@hormozgan.ac.ir

5. Associate Professor, Department of Natural Resources Engineering, University of Hormozgan, Bandarabaas, Iran, ra_mahdavi2000@hormozgan.ac.ir

used through the Google Earth Engine platform and three widely used vegetation indices in previous research in the field of vegetation analysis and assessment were used, including NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), and MVI (Mangrove Vegetation Index). Ground reference data were obtained via field surveys to the area. Image preprocessing steps, including atmospheric correction and removal of cloud and shadow effects, were performed using the Sen2Cor algorithm in the GEE environment. The extracted data were matched with the field data, thus providing a valid and reliable set of training samples for image classification. Using field data and connecting them to the spectral ranges of the indicators significantly improved the classification accuracy and increased the ability to distinguish different land covers. However, various factors such as measurement error, atmospheric conditions, solar zenith angle variations, and computational errors during index calculation the indices can affect the accuracy of satellite data. Therefore, uncertainty was investigated using Monte Carlo simulation and IQR methods.

Results and Discussion

The classification was designed based on the field observations and using ground control points, in the ArcMap environment in such a way that it can identify and differentiate between water, soil, and stressed vs. healthy mangroves. The results of the analysis of the indicators indicate significant changes in the amount of vegetation cover in the study area during the years 2019 and 2024. The results obtained from the classification of mangrove tree cover in ArcMap environment showed that in 2024, compared to 2019, there was an increase of 0.98% (NDVI), 0.74% (EVI) and 1.39% (MVI) of fresh trees. In addition, the cover of non-fresh mangrove trees increased by 0.6% (NDVI), 0.03% (EVI) and 0.85% (MVI) during the same period. The MVI index detected the highest coverage of fresh and non-fresh cover, which can be attributed to its high sensitivity to specific mangrove covers. Both Monte Carlo and IQR simulation methods were used to assess classification uncertainty. Monte Carlo results showed a decrease in overall model accuracy from 71.4% in 2019 to 62.5% in 2024, likely attributable to environmental variability or spectral class overlap. IQR analysis showed strong performance of NDVI and high uncertainty associated with MVI. However, EVI showed superior performance in identifying mangrove forests due to its stability and high sensitivity to dense vegetation.

Conclusion

In this study, using satellite data and ground reference data, an attempt was made to quantify ecological changes in mangrove forests. Three indices, MVI, EVI, and NDVI, were selected, and by comparing the results obtained from these three indices with ground reality, the best index for examining ecological changes was introduced. Monte Carlo and IQR uncertainty methods were used to examine the accuracy of the classifications, and the findings showed that EVI is more suitable for continuous monitoring, while NDVI is preferable for baseline assessments. MVI can serve as a complementary indicator in certain situations. All three indicators show a decrease in vegetation cover from 2019 to 2024, indicating heightened anthropogenic pressure. To improve the obtained results, more advanced algorithms such as Random Forest, SVM or Deep Learning networks can be used to increase the accuracy of the model. Supplementary data from higher resolution sensors could improve the separation of classes with high overlap. Sensitivity analysis and assessment of sources of uncertainty should be expanded to select appropriate indicators in specific regional conditions. By providing a detailed analysis of the process of mangrove destruction, this study emphasizes the need for continuous monitoring and the use of selected indicators appropriate to regional characteristics, and establishes a framework for conservation policies in estuarine areas in coastal watersheds.

Keywords: *Mangrove ecosystem, vegetation indices, Monte Carlo Simulation, IQR method, Sentinel-2, Google Earth Engine.*

Article Type : Research Article

Acknowledgement

The authors sincerely thank the Vice-Chancellor for Research at the University of Hormozgan for the financial and research supports. We are also grateful to the Faculty of Natural Resources for facilitating transportation to the Tiab and Kolahi regions.

Special appreciation is extended to the Kalang Tourism Cooperative Company in Tiab Port, Minab, Hormozgan, for providing boats used in the marine sampling activities.

Conflicts of interest

The authors declare that they have no conflict of interest regarding the authorship or publication of the findings presented in this study.

Data Availability Statement

The data and results used in this study are available upon reasonable request from the corresponding author.

Authors' contribution

Laleh Sharifipour: Methodology, Writing – original draft, Software

Marzieh Rezai: Data analysis, Field sampling

Mohammad Kazemi: Software, Data validation, Manuscript review

Ali Reza Nafarzadegan: Manuscript editing and revision

Rasool Mahdavi Najafabadi: Manuscript updating and revision

Citation: Sharifipour L, Rezai M, Kazemi M, Nafarzadegan A. R, Mahdavi Najafabadi R. Assessment of Mangrove Forest Degradation in Coastal Watersheds Using Satellite Data. jwmseir 2025; 19 (68): 93-93-111

Iran-Watershed Management Science & Engineering, Year 2025, Vol 19, No 68, PP 93-111

Publisher: Watershed Management Society of Iran

© Author(s)



سنجش تخریب جنگل‌های مانگرو در حوزه‌های آبخیز ساحلی با استفاده از داده‌های ماهواره‌ای

لاله شریفی پور^۱، مرضیه رضایی^{۲*}، محمد کاظمی^۳، علیرضا نفرزادگان^۴، رسول مهدوی نجف‌آبادی^۵

تاریخ دریافت: ۱۴۰۴/۰۳/۲۶، تاریخ داوری: ۱۴۰۴/۰۵/۰۲، تاریخ پذیرش: ۱۴۰۴/۰۵/۰۷، تاریخ انتشار: ۱۴۰۴/۰۵/۰۷

<https://doi.org/10.22034/19.68.7>


چکیده

جنگل‌های مانگرو، مجموعه‌ای از درختان همیشه‌سبزی هستند که در سواحل حوزه‌های آبخیز، به‌ویژه در مصب‌ها و خورهای مجاور دریا رشد می‌کنند. این بوم‌سازگان ارزشمند به دلیل اهمیت بالای زیستی و حساسیت زیاد نسبت به آسیب‌های محیطی، نیازمند حفاظت و مدیریت مؤثر می‌باشند. در این پژوهش، جنگل‌های مانگرو تیاب و کلاهی، واقع در شهرستان میناب از توابع استان هرمزگان با مساحت تقریبی ۱۲۶/۳۱ کیلومترمربع، به منظور بررسی وضعیت تخریب این بوم‌سازگان‌های ارزشمند انتخاب شدند. تصاویر ماهواره‌ای سنتینل-۲ مربوط به سال‌های ۲۰۱۹ و ۲۰۲۴ از طریق سامانه Google Earth Engine استخراج و با استفاده از شاخص‌های پوشش گیاهی NDVI، EVI و MVI مورد تحلیل قرار گرفتند. نتایج حاصل از تحلیل شاخص‌های پوشش گیاهی نشان داد که در سال ۲۰۲۴، مساحت جنگل‌های مانگروی با طراوت براساس شاخص‌های NDVI، EVI و MVI به ترتیب ۴/۰۷، ۲/۳۱ و ۴/۵۹ درصد برآورد شده است. این مقادیر در مقایسه با سال ۲۰۱۹ به ترتیب افزایش ۰/۹۸، ۰/۷۴ و ۱/۳۹ درصدی را نشان می‌دهند. همچنین در همین بازه زمانی، مساحت مانگروهای بدون طراوت نیز بر اساس شاخص‌های مذکور به ترتیب ۰/۶ درصد (NDVI)، ۰/۰۳ درصد (EVI) و ۰/۸۵ درصد (MVI) افزایش یافته است. به منظور بررسی عدم قطعیت طبقه‌بندی از شبیه‌سازی مونت-کارلو و روش IQR استفاده شد. نتایج مونت-کارلو افزایش دقت کلی مدل از ۰/۶۷ درصد در سال ۲۰۱۹ به ۰/۷۳ درصد در سال ۲۰۲۴ را نشان داد. نتایج IQR عملکرد خوب NDVI و ثبات MVI را نشان داد. با وجود این، شاخص EVI به دلیل پایداری و حساسیت بالا نسبت به پوشش متراکم، عملکرد بهتری در شناسایی جنگل‌های مانگرو دارد. این مطالعه بر اهمیت انتخاب شاخص مناسب و استفاده از عدم قطعیت در تحلیل صحت و دقت کلاس‌های مختلف حاصل از طبقه‌بندی آن‌ها در پایش بوم‌سازگان‌های ساحلی تأکید دارد.

واژگان کلیدی: بوم‌سازگان ماندابی، روش مونت-کارلو، Sentinel-2، شاخص‌های پوشش گیاهی، Google Earth Engine، IQR

نوع مقاله: پژوهشی

استناد: شریفی‌پور لاله، رضایی مرضیه، کاظمی محمد، نفرزادگان علیرضا، مهدوی نجف‌آبادی رسول. سنجش تخریب جنگل‌های مانگرو در حوزه‌های آبخیز ساحلی با استفاده از داده‌های ماهواره‌ای. علوم و مهندسی آبخیزداری ایران. ۱۴۰۴؛ ۱۹(۶۸): ۹۳-۱۱۱
علوم و مهندسی آبخیزداری ایران، سال ۱۴۰۴، دوره ۱۹، شماره ۶۸، صفحه ۹۳-۱۱۱



© نویسندگان

ناشر: انجمن آبخیزداری ایران

- ۱- دانشجوی دکتری تخصصی مدیریت و کنترل بیابان، گروه مهندسی منابع طبیعی، دانشگاه هرمزگان، هرمزگان، ایران، l.sharifipour.phd@hormozgan.ac.ir
- ۲- نویسنده مسئول و دانشیار، گروه مهندسی منابع طبیعی، دانشگاه هرمزگان، هرمزگان، ایران، m.rezai@hormozgan.ac.ir
- ۳- دانشیار، مطالعات زیست‌محیطی پژوهشکده هرمز، دانشگاه هرمزگان، هرمزگان، ایران، mohamad.kazemi86@gmail.com
- ۴- دانشیار، گروه مهندسی منابع طبیعی، دانشگاه هرمزگان، هرمزگان، ایران، a.r.nafarzadegan@hormozgan.ac.ir
- ۵- دانشیار، گروه مهندسی منابع طبیعی، دانشگاه هرمزگان، هرمزگان، ایران، ra_mahdavi2000@hormozgan.ac.ir

جنگل‌های مانگرو از منابع بسیار مهم در نواحی ساحلی به شمار می‌روند و نقش حیاتی در پایداری محیط‌زیست و توسعه اجتماعی و اقتصادی جوامع ساحلی ایفا می‌کنند [۱۲]. این جنگل‌ها با ایفای نقش کمر بند سبز ساحلی، از سواحل در برابر امواج و بلایای طبیعی مانند سیل و طوفان حفاظت می‌کنند. با این حال، فعالیت‌های انسانی مانند چرای دام، توسعه آبی‌پروری و آلودگی‌های مختلف، منجر به تغییرات قابل توجه در ساختار و عملکرد بوم‌سازگان‌های مانگرو شده‌اند [۱۰]. جنگل‌های مانگرو ایران در سواحل جنوب کشور در حاشیه خلیج فارس و دریای عمان در حد فاصل عرض‌های شمالی مدارهای ۲۵ درجه و ۱۰ دقیقه تا ۲۷ درجه و طول‌های شرقی ۵۵ دقیقه و ۱۰ دقیقه تا ۶۵ درجه گسترده‌اند و در عرض جغرافیای ۲۸ درجه قطع می‌شوند [۲۶]. مساحت کل جنگل‌های مانگرو ایران در امتداد چهار استان ساحلی سیستان و بلوچستان، هرمزگان، بوشهر و خوزستان ۱۳۲ کیلومترمربع است، که ۹۲ درصد آن در امتداد سواحل استان هرمزگان جای گرفته‌اند [۹]. این بوم‌سازگان‌ها در ایران به دلیل ویژگی‌های حساس بیوفیزیکی، اهمیت بالایی زیستگاهی، وجود گونه‌های در معرض خطر و کمیاب، حساسیت به آلاینده‌ها و کندی ترمیم زیست‌بوم‌هایی بسیار آسیب‌پذیر در برابر تهدیدات طبیعی و انسانی هستند [۲۳].

پایش و تحلیل تغییرات مرزهای جنگل‌های مانگرو در بازه‌های زمانی مختلف، می‌تواند زمینه‌ساز برنامه‌ریزی‌های هدفمندتر و اجرای اقدامات حفاظتی کارآمدتر باشد و در نهایت، از میزان آسیب‌پذیری این بوم‌سازگان‌ها در برابر تهدیدات طبیعی و انسانی بکاهد [۱۹]. پیشرفت‌های اخیر در دسترسی به داده‌های سنجنش‌ازدور، پردازش تصویر، فناوری اطلاعات و محاسبات و همچنین توسعه انسانی فرصت مناسبی را برای پایش و نظارت مستمر و منظم بر جنگل‌های حرا از مقیاس محلی تا جهانی را فراهم کرده است [۷]. در طول چهار دهه، سنجنش‌ازدور سودمندی خود را در نظارت بر بوم‌سازگان‌های حرا در مقیاس وسیع در طول زمان و با هزینه‌ای کمتر از مشاهدات میدانی اثبات کرده است [۲۷]. همچنین، استفاده از روش‌های سنجنش‌ازدور در تحلیل جنگل‌های مانگرو به همراه بهره‌گیری از روش‌های یادگیری ماشین امکان تفکیک گونه‌های مانگرو، شناسایی پارامترهای بیوفیزیکی (از جمله ارتفاع درخت، رنگدانه‌های برگ و ضریب سطح برگ) و برآورد زی‌توده این بوم‌سازگان‌ها را فراهم کرده است [۲۰]. تصاویر ماهواره سنتینل-۲ با دارا بودن ۱۳ باند طیفی با وضوح مکانی ۱۰ متر، یکی از منابع پرکاربرد برای تهیه نقشه‌های پوشش گیاهی جنگل‌های مانگرو با استفاده از شاخص‌های پوشش گیاهی به شمار می‌رود [۲۹]. در این میان، استفاده از شاخص‌های گیاهی مانند $NDVI^1$ ، EVI^2 و MVI^3 در محیط GEE^4 با قابلیت

1. Normalized Difference Vegetation Index
2. Enhanced Vegetation Index
3. Mangrove Vegetation Index
4. Google Earth Engine

تحلیل مکانی-زمانی دقیق، مقیاس‌پذیری بالا و امکان پایش بلند مدت ابزار مناسبی برای بررسی تغییرات و تحلیل پوشش گیاهی این بوم‌سازگان‌ها را فراهم می‌کند. شاخص‌های پوشش گیاهی مختلف، دقت‌های متفاوتی در برآورد تراکم جنگل‌های مانگرو دارند [۲۱]. در همین راستا، عرفانی‌فرد و همکاران [۳]، در مطالعه‌ای پویایی جنگل‌های حرای ایران طی سه دهه (۱۹۹۰ تا ۲۰۲۰) با استفاده از تصاویر سری زمانی ماهواره لندست بررسی کردند. در این پژوهش از چهار شاخص عمومی پوشش گیاهی، هشت شاخص ویژه جنگل حرا و شش معیار ساختار منظر به کار بردند. نتایج نشان داد شاخص SMRI (شناساگر جنگل‌های غوطه‌ور) با امتیاز $F1$ معادل ۰/۸۹ بالاترین دقت را در تفکیک پوشش حرا داشته است و مساحت جنگل‌های مانگرو در جنوب ایران در سال ۲۰۲۰ حدود ۱۳۰۰۰ هکتار برآورد کرد که افزایش ۲۳۱۳ هکتاری نسبت به سال ۱۹۹۰ را نشان می‌داد. پورنومو و همکاران [۲۲] نیز، نقشه‌برداری گونه‌های حرا از طریق تجزیه و تحلیل فنولوژیکی با استفاده از الگوریتم جنگل تصادفی در محیط GEE مورد بررسی قرار دادند. شاخص‌های $NDVI$ ، EVI و $SAVI$ از تصاویر چندزمانه سنتینل-۲ مربوط به بازه زمانی ۲۰۱۸ تا ۲۰۲۰ در منطقه حفاظت‌شده مانگرو واقع در مالانگ، اندونزی استخراج و تحلیل کردند. نتایج آن‌ها نشان داد که شاخص $NDVI$ نسبت به دو شاخص دیگر عملکرد دقیق‌تری در طبقه‌بندی گونه‌های مانگرو داشته است. ژو و همکاران [۳۱]، به ترکیب سری‌های زمانی و داده‌های پوشش زمین حاصل از تصاویر لندست و سنتینل برای تجزیه و تحلیل تغییرات مکانی-زمانی جنگل‌های مانگرو در منطقه حفاظت‌شده چینگ‌لانگ‌گانگ در چین پرداختند. برای تحلیل سری‌های زمانی از روش‌های آماری شامل تحلیل روند تایل-سن، آزمون من-کندال و نمایه هرست را انتخاب کردند. بر اساس نتایج که به دست آوردند شاخص‌های نوری نسبت به داده‌های راداری عملکرد بهتری دارند و در میان آن‌ها، شاخص EVI در پایش تغییرات جنگل‌های مانگرو دقت بالاتری نسبت به $NDVI$ دارد. همچنین نری و همکاران [۱۸]، به بررسی محدودیت‌ها و بهبود روند نقشه‌برداری مبتنی بر شاخص پوشش گیاهی مانگرو با استفاده از تصاویر سنتینل-۲ پرداختند. چالش‌های مربوط به روش‌های خودکار، از جمله الگوریتم اتسو (Otsu method) مورد ارزیابی قرار دادند و راهکارهایی نظیر تقویت کنتراست تصویر، حذف پیکسل‌های آبی، استفاده از تصاویر در زمان جزر و اعمال ماسک‌گذاری شیب به منظور بهبود فرآیند استخراج پوشش مانگرو را پیشنهاد کردند. از طرفی، میانج و همکاران [۱۷]، به ارزیابی تصاویر سنجنش‌ازدور و محصولات موجود در نقشه‌برداری جنگل‌های حرای ایران (سواحل شمالی خلیج فارس و دریای عمان) پرداختند. در این پژوهش، با استفاده از داده‌های ماهواره‌ای سنتینل-۲ و لندست-۹ عملکرد شاخص پوشش گیاهی با بهره‌گیری از الگوریتم طبقه‌بندی جنگل تصادفی مقایسه کردند. در نتیجه دقت بالاتر استفاده از شاخص پوشش گیاهی از داده‌های سنتینل-۲ را در

شناسایی جنگل‌های حرا نشان دادند. همچنین، یافته‌های این مطالعه برتری داده‌های سنتینل-۲ نسبت به لندست-۹ و نیز توانمندی بالای روش‌های پیشنهادی نسبت به محصولات جهانی موجود را در تهیه نقشه‌های دقیق‌تر جنگل‌های حرای ایران نشان می‌دهد. کاظمی و جعفرپور [۱۳] نیز، طبقه‌بندی سری زمانی کاربری اراضی با استفاده از شاخص‌های طیفی، تصاویر سنتینل-۲ و نمونه‌های آموزشی متغیر در بستر گوگل ارث انجین در منطقه مانگرو خوران انجام دادند. از تصاویر ماهواره‌ای سنتینل-۲ پوشش‌دهنده منطقه مورد مطالعه برای سال‌های هدف ۲۰۲۲ و ۲۰۲۴ و سال مرجع ۲۰۱۹ در GEE استفاده کردند. داده‌های حقیقت زمینی از سال مرجع (۲۰۱۹) به عنوان نمونه‌های آموزشی به تصاویر سال هدف با الگوریتم فاصله زاویه طیفی منتقل شدند. همچنین الگوریتم‌های طبقه‌بندی RF^1 ، GBT^2 و $CART^3$ برای طبقه‌بندی تصاویر سال هدف با استفاده از نمونه‌های آموزشی متغیر به کار گرفته شدند. بر اساس نتایج، روش‌های مختلف طبقه‌بندی در سال‌های مختلف و اهمیت نسبی باندها و شاخص‌ها نشان دادند که شاخص‌های EMVI و mNDWI به دلیل فراگیری پدیده‌های جنگل‌های مانگرو و نیز پهنه‌های آبی در محدوده مورد مطالعه بهترین عملکرد داشتند. همچنین آروین و همکاران [۱]، روند تغییرات کاربری و پوشش اراضی تالاب بین‌المللی خلیج گواتر و خور باهو با استفاده از سری زمانی تصاویر ماهواره‌ای بررسی کردند. برای ارزیابی تأثیر حفاظت بر منطقه مورد مطالعه تصاویر ماهواره‌ای لندست استفاده کردند. نمونه‌های تعلیمی با بازدید میدانی، بررسی تصاویر گوگل ارث و تفسیر بصری تصاویر ماهواره‌ای انجام دادند. طبقه‌بندی تصاویر، با استفاده از ترکیب روش‌های نظارت نشده و نظارت شده انجام شد و نقشه کاربری و پوشش اراضی برای منطقه مورد مطالعه تهیه کردند. نتایج حاصل از تحلیل نقشه‌های پوشش اراضی نشان داد که وسعت جنگل‌های مانگرو از ۶۸۵ هکتار در سال ۱۳۷۷ به ۲۵۳۴ هکتار در سال ۱۴۰۲ افزایش یافته است. در پژوهشی دیگر تیان و همکاران [۲۸]، به ارزیابی میزان هماهنگی میان سامانه‌های خشکی و دریایی در منطقه ساحلی تایژو چین و بررسی تغییرات زمانی-مکانی آن از سال ۱۹۹۰ تا ۲۰۲۱ پرداختند. با استفاده از داده‌های مربوط به خط ساحلی، کاربری اراضی و شاخص‌های اجتماعی-اقتصادی، شدت توسعه منطقه ساحلی را در هفت دوره زمانی مختلف تحلیل کردند. همچنین، یک مدل ارزیابی جامع برای سنجش سطح هماهنگی خشکی-دریا طراحی و روند تکاملی این هماهنگی را بررسی کردند. نتایج نشان داد که توسعه منطقه ساحلی طی این بازه زمانی به‌طور قابل توجهی افزایش یافته و با تغییرات چشمگیری در ساختار خط ساحلی همراه بوده است. مارتینز و همکاران [۱۶]، به بررسی تأثیر یک رویداد سرمای شدید (فوریه ۲۰۲۱) بر پوشش گیاهی مانگرو سیاه *Avicennia germinans* در

1. Random Forest
2. Gradient boosted tree
3. Classification and regression tree

منطقه خلیج شمالی مکزیک پرداختند. با هدف کمی‌سازی آسیب‌های ناشی از این رویداد در مقیاس منظر، داده‌های سنجش‌ازدور تصاویر سنتینل-۲ با مشاهدات میدانی ترکیب کردند. این پژوهش اهمیت ترکیب داده‌های ماهواره‌ای و زمینی را برای پایش تأثیر رویدادهای حادی بر بوم‌سازگان‌های حساس مانند مانگروها را برجسته می‌کند. در پژوهش بالولوی و همکاران [۲]، شاخص جدیدی تحت عنوان شاخص پوشش گیاهی مانگرو، با هدف استخراج سریع و دقیق نقشه گستره جنگل‌های مانگرو با استفاده از تصاویر ماهواره‌ای پیشنهاد کردند. این شاخص در جنگل‌های مانگرو تایلند، ویتنام، اندونزی، کامبوج اجرا شد و توانست پوشش‌های مانگرو و غیرمانگرو را به‌خوبی از یکدیگر تفکیک کند. شاخص MVI به دلیل نیاز نداشتن به داده‌های پیچیده، محاسبه ساده، دقت بالای اولیه، قابلیت تعمیم‌پذیری به دیگر داده‌های ماهواره‌ای و همچنین وجود ابزارهای خودکار، می‌تواند برای نقشه‌برداری سریع و دقیق جنگل‌های مانگرو مورد استفاده قرار گیرد.

مطالعات گذشته در زمینه بررسی بوم‌سازگان‌های ماندابی، توجه ویژه‌ای به استفاده از داده‌های سنجش‌ازدور و شاخص‌های مختلف پوشش گیاهی داشته‌اند. براساس نتایج این مطالعات تصاویر ماهواره‌ای سنتینل-۲ در مقایسه با لندست از کیفیت و دقت بالاتری در شناسایی جنگل‌های مانگرو برخوردار هستند. همچنین دقت شاخص‌های پوشش گیاهی در شناسایی جنگل‌های مانگرو متفاوت گزارش شده است، که در میان شاخص‌های پوشش گیاهی به کار برده شده شاخص NDVI پرکاربردترین شاخص جهت شناسایی بوده است.

با وجود تلاش‌های گذشته، در سواحل جنوبی ایران اطلاعات بروزی از روند تخریب یا احیای جنگل‌های مانگرو وجود ندارد و بیشتر تحقیقاتی که بر پایه سنجش‌ازدور انجام شده‌اند تمرکز آن‌ها بروی شاخص‌های پوشش گیاهی و استفاده از روش‌های یادگیری ماشین است و در بخش دیگر تحقیقات که به‌صورت میدانی در جنگل‌های مانگرو انجام می‌شود در زمینه ساختار، پارامترهای زیستی و بیماری‌های درختان مانگروها است، در این میان ضرورت استفاده هم‌زمان از داده‌های میدانی و داده‌های سنجش‌ازدور احساس می‌شود، تا با بهره‌گیری از توانایی‌های ترکیبی این دو منبع، طبقه‌بندی دقیق‌تری انجام شده و داده‌هایی حاصل شوند که به واقعیت‌های زمینی نزدیک‌تر باشند. هدف پژوهش حاضر، بررسی میزان طراوت پوشش جنگلی مانگرو در دو بازه زمانی ۲۰۱۹ و ۲۰۲۴ است. به‌منظور تهیه داده‌های مرجع زمینی^۴، عملیات میدانی نمونه‌برداری از مناطق دارای طراوت‌های مختلف جنگل‌های مانگرو (محدوده‌های باطراوت و باطراوت کمتر و...) و همچنین از مناطق آب و خاک انجام شد و موقعیت جغرافیایی هر نقطه با استفاده از GPS ثبت شد. سپس، برای استخراج شاخص‌های طیفی پوشش گیاهی، تصاویر ماهواره‌ای سنتینل-۲ با قدرت تفکیک مکانی ۱۰ متر، از طریق سامانه GEE پردازش شدند و مقادیر شاخص‌های NDVI، EVI و MVI


4. Ground Truth

به دست آمد. در ادامه، با بهره‌گیری از داده‌های نمونه‌برداری میدانی و تطبیق دقیق آن‌ها با مقادیر شاخص‌های مذکور، طبقه‌بندی پوشش اراضی و ارزیابی وضعیت جنگل‌های مانگرو انجام گرفت. همچنین به منظور بررسی دقت و قطعیت طبقه‌بندی شاخص‌های پوشش گیاهی، روش‌های آماری مونت کارلو و Interquartile (IQR) Range مورد استفاده قرار گرفتند تا میزان عدم قطعیت در نتایج طبقه‌بندی مشخص شود.

مواد و روش‌ها

محدوده مورد مطالعه

مرز اکولوژیکی مورد بررسی در این پژوهش، جنگل‌های مانگرو تیاب و کلاهی واقع در عرض‌های جغرافیایی ۲۶/۷۷ درجه شمالی و ۵۷/۰۷ درجه شرقی قرار دارد، موقعیت قرارگیری این محدوده در شکل (۱) نشان داده شده است. این جنگل‌ها با مساحت تقریبی ۱۲۶/۳۱ کیلومتر مربع در شهرستان میناب واقع، در جنوب ایران و در مجاورت سواحل خلیج فارس قرار گرفته‌اند. منطقه مورد مطالعه بخشی از جنگل‌های حفاظت شده تیاب و میناب است که از سال ۱۳۸۰ تحت مدیریت سازمان حفاظت محیط‌زیست قرار دارد [۲۳]. به دلیل پوشش گیاهی خاص و بوم‌سازگان حساس، این منطقه از اهمیت ویژه‌ای برخوردار است و به عنوان زیستگاه بسیاری از گونه‌های جانوری و گیاهی منطقه شناخته می‌شود.



شکل ۱- موقعیت منطقه مورد مطالعه، جنگل‌های تیاب و کلاهی
Fig 1. Location of the Study Area: Tiab and Kolahi Mangrove Forests

مراحل پیش‌پردازش تصاویر، شامل تصحیح اتمسفری و حذف اثرات ابر و سایه، با استفاده از الگوریتم Sen2Cor در محیط GEE صورت گرفت. داده‌های استخراج شده با داده‌های میدانی انطباق داده شدند و بدین ترتیب، مجموعه‌ای معتبر و قابل اتکا از نمونه‌های تعلیمی برای طبقه‌بندی تصاویر فراهم شد.

شاخص‌های مورد استفاده

شاخص‌های پوشش گیاهی NDVI و EVI شاخص‌های عمومی و پرکاربرد برای بررسی پوشش گیاهی هستند، به همراه شاخص پوشش گیاهی MVI که شاخص تخصصی برای شناسایی مانگرو محسوب می‌شود، در این پژوهش برای بررسی میزان تغییرات پوشش گیاهی جنگل‌های مانگرو مورد استفاده قرار گرفتند.

شاخص تفاوت نرمال شده گیاهی (NDVI)

شاخص گیاهی تفاوت نرمال شده یک معیار پرکاربرد برای تعیین کمیت سلامت و تراکم پوشش گیاهی با استفاده از داده‌های ماهواره‌ای است. این شاخص همبستگی بالایی با وضعیت واقعی پوشش گیاهی روی زمین دارد. NDVI مقداری بین ۱- و ۱ دارد. در منطقه‌ای با پوشش گیاهی متراکم و سالم دارای NDVI یک خواهد بود [۸]. شاخص گیاهی تفاوت نرمال شده (NDVI) با استفاده از معادله (۱) محاسبه شده است [۲۴].

$$NDVI = (NIR - R) / (NIR + R) \quad (1)$$

شاخص پوشش گیاهی پیشرفته (EVI)

شاخص پوشش گیاهی پیشرفته نسبت به تغییرات ساختاری تاج پوشش از جمله نوع تاج پوشش و فیزیولوژی گیاه حساس است. EVI به دلیل توانایی حذف نویزهای پس‌زمینه و جو محبوبیت زیادی دارد [۲۳]. دامنه این شاخص از ۱- تا ۱ است. شاخص پوشش گیاهی پیشرفته با استفاده از معادله (۲) محاسبه می‌شود.

$$EVI = 2.5(NIR - R) / (NIR + c_1R - c_2B + L) \quad (2)$$

که L، فاکتور تعدیل‌کننده خاک، C_1 و C_2 ضرایب استفاده شده جهت تصحیح پراکندگی آتروسول در باند قرمز با استفاده از باند آبی، P_{NIR} ، P_{RED} ، P_{BLUE} به ترتیب انعکاس در طول موج‌های آبی، قرمز و مادون قرمز نزدیک است. به طور معمول، $C_1=6$ ، $C_2=7.5$ و $L=1$ است [۵].

شاخص پوشش گیاهی حرا (MVI)

شاخص پوشش گیاهی حرا برای ترسیم وسعت حرا از تصاویر سنجش از دور به طور دقیق و سریع ایجاد شد. MVI با استخراج اطلاعات سبزی و رطوبت از باندهای سبز، NIR و SWIR (مادون قرمز کوتاه موج)، احتمال "حرا" بودن یک پیکسل را اندازه‌گیری می‌کند [۲]. برای محاسبه شاخص پوشش گیاهی حرا (MVI) از معادله (۳) استفاده شده است. دامنه این شاخص از ۱- تا ۱ است.

$$MVI = (NIR - Green) / (SWIR1 - Green) \quad (3)$$

توزیع احتمالی نتایج را تخمین زد و ویژگی‌های آماری سیستم را بررسی کرد [۶].

ارزیابی دقت روش مونت کارلو

جهت ارزیابی روش مونت کارلو در طبقه‌بندی، از معیارهای دقت کلی، ضریب کاپا و امتیاز F1 مطابق با روابط (۷) تا (۹) استفاده شده است.

$$\text{Accuracy}(\%) = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \quad (۷)$$

TP (مثبت صحیح): نتایج مثبتی‌اند که به درستی پیش‌بینی شده‌اند و TN (منفی صحیح): نتایجی منفی‌اند که مدل به درستی آن‌ها را پیش‌بینی کرده است. FP (مثبت کاذب): نتایج مثبتی است که مدل به اشتباه پیش‌بینی کرده و با عنوان خطای نوع اول شناخته می‌شوند. FN (منفی کاذب) نیز نتایجی منفی است که مدل به اشتباه پیش‌بینی کرده است [۳۰].

$$\text{Kaapa} = P_o - P_c / 1 - P_c \quad (۸)$$

در این رابطه P_o درستی پیکسل‌های مشاهده شده و P_c درستی مورد انتظار هستند و هرچه مقدار آن‌ها به سمت یک تمایل داشته باشد، دقت طبقه‌بندی بیشتر است [۱۴].

$$\text{F1}(\%) = \left(2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \times 100\% \quad (۹)$$

Precision نشان‌دهنده میزان پیکسل‌هایی است که برای هر دسته به درستی پیش‌بینی شده‌اند. recall مشخص می‌کند چند پیکسل واقعی در هر دسته شناسایی شده است [۳۰].

نتایج

در این پژوهش، به منظور بررسی تغییرات پوشش جنگل‌های مانگرو در سال‌های ۲۰۱۹ و ۲۰۲۴، وضعیت طراوت درختان مانگرو به همراه سایر پوشش‌های زمین طی بازدید میدانی شناسایی و موقعیت جغرافیایی آن‌ها ثبت شد. شاخص‌های پوشش گیاهی EVI، NDVI و MVI با استفاده از تصاویر ماهواره‌ای سنتینل-۲ از طریق پلتفرم GEE محاسبه و استخراج شدند. جهت نشان دادن وضعیت پوشش جنگلی مانگرو، مقادیر پیکسلی شاخص‌ها در نقاط ثبت شده استخراج شد و بر اساس میزان طراوت درختان مانگرو ثبت شده یک طبقه‌بندی هفت کلاسه که شامل درختان مانگروهای باطراوت، بدون طراوت، آب، خاک و سایر پوشش‌ها صورت گرفت و در نهایت به منظور ارزیابی پایداری و میزان حساسیت این کلاس‌بندی‌ها، از دو روش مونت-کارلو و IQR با رویکردهای متفاوت جهت بررسی عدم قطعیت کلاس‌بندی‌ها استفاده شد، کلاس‌های ۵، ۶ و ۷ به دلیل همپوشانی زیاد و نزدیک بودن مقادیر عددی آن‌ها با کلاس‌های دیگر ادغام شدند، کلاس‌بندی

این روش به پژوهشگران و کارشناسان اجازه می‌دهد تا بوم‌سازگان‌های حراً را از طریق مشاهده دقیق و تحلیل تصاویر هوایی ثبت‌شده بررسی و درک کنند. این روش متکی به تجربه انسانی برای شناسایی ویژگی‌ها و طبقه‌بندی عناصر موجود در تصاویر است [۲۷].

عدم قطعیت شاخص‌ها با دامنه بین چارکی (IQR²)

IQR یکی از روش‌های رایج برای تشخیص داده‌های پرت است. داده پرت به معنای چیزی است که به طور معناداری با دیگر داده‌ها متفاوت باشد. شناسایی داده‌های پرت به طور گسترده‌ای برای تشخیص ناهنجاری‌ها استفاده می‌شود. روش‌های مختلفی برای شناسایی داده‌های پرت وجود دارد از جمله خوشه‌بندی بر پایه چگالی، تشخیص داده پرت بر اساس فاصله و جنگل ایزوله، با این حال IQR یکی از رایج‌ترین و پرکاربردترین روش‌های تشخیص داده پرت به شمار می‌رود. این روش یک روش تک متغیره در مدل‌سازی آماری است که با تقسیم مجموعه داده‌ها به چارک‌های مختلف محاسبه می‌شود. این تقسیم‌بندی با استفاده از سه مقدار Q_1 (چارک اول)، Q_2 (میان) و Q_3 (چارک سوم) محاسبه می‌شود. به طور ساده می‌توان گفت که ۵۰ درصد میانی داده‌های مرتب شده به صورت صعودی، دامنه IQR را تشکیل می‌دهند. محاسبه IQR با استفاده از معادله (۴) صورت گرفت.

$$\text{IQR} = Q_3 - Q_1 \quad (۴)$$

برای شناسایی داده‌های پرت مرزهایی بر اساس مقدار $1 \times IQR$ تا $5 \times IQR$ تعیین شده است که به عنوان اصل IQR برای شناسایی داده‌های پرت به کار می‌رود. بر طبق این اصل دو حد پایین و حد بالا برای داده‌ها بر اساس رابطه‌های (۵) و (۶) محاسبه شد و داده‌هایی که کمتر از حد پایین یا بیشتر از حد بالا مشخص شده باشند، به عنوان داده پرت علامت‌گذاری می‌شوند [۲۵].

$$\text{حد پایین} = Q_1 - 1.5 \times \text{IQR} \quad (۵)$$

$$\text{حد بالا} = Q_3 + 1.5 \times \text{IQR} \quad (۶)$$

عدم قطعیت شاخص‌ها با روش مونت-کارلو^۳

روش شبیه‌سازی مونت-کارلو یک روش محاسباتی است که برای مدل‌سازی و شبیه‌سازی سیستم‌های پیچیده استفاده می‌شود، به‌ویژه سیستم‌هایی که نمی‌توان آن‌ها را به صورت تحلیلی حل کرد. این روش بر پایه نمونه‌برداری تصادفی و تکرار محاسبات استوار است تا نتایج احتمالی را تخمین بزند. در این روش، با تعریف یک مدل ریاضی از سیستم مورد نظر شروع می‌شود و سپس با استفاده از اعداد تصادفی، ورودی‌های مدل را به‌طور مکرر تغییر داده می‌شود. هر بار که ورودی‌ها تغییر می‌کنند، مدل اجرا می‌شود و یک نتیجه جدید تولید می‌کند. با جمع‌آوری تعداد زیادی از این نتایج، می‌توان

1. Visual interpretation
2. Interquartile Range
3. Monte Carlo Method

4. Accuracy
5. Kappa

مانگروهای با طراوت و بدون طراوت نیز در هر دو سال روند افزایشی داشته‌اند.


مقایسه شاخص‌های NDVI و MVI نشان می‌دهد که هر دو شاخص در طبقه‌بندی پوشش مانگروهای با طراوت نتایج مشابهی ارائه داده‌اند؛ به گونه‌ای که مقادیر آن‌ها نزدیک به هم بوده و نشان‌دهنده هماهنگی مناسب در تشخیص این نوع پوشش بود. بررسی دقیق‌تر داده‌ها نشان می‌دهد که شاخص MVI در هر دو سال، مقدار بیشتری از پوشش مانگرو با طراوت را نسبت به NDVI ثبت کرده است. این تفاوت می‌تواند ناشی از ماهیت تخصصی‌تر شاخص MVI در تفکیک پوشش‌های مانگرویی باشد؛ چرا که این شاخص با در نظر گرفتن ویژگی‌های طیفی خاص جنگل‌های مانگرو طراحی شده و حساسیت بیشتری نسبت به ساختار این نوع پوشش دارد.

نهایی شامل چهار کلاس مانگروهای باطراوت، مانگروهای بدون طراوت، آب و خاک است.


نتایج حاصل از تحلیل این شاخص‌ها، بیانگر تغییرات چشمگیر در میزان پوشش گیاهی منطقه مورد مطالعه طی دو سال مذکور بود. بر اساس مقادیر استخراج شده، مناطق مورد بررسی کلاس‌بندی و درصد پوشش هر کلاس محاسبه شد، اطلاعات آن در شکل (۲) ارائه شده است.

بررسی داده‌های شکل (۲) نشان می‌دهد که در سال‌های ۲۰۱۹ و ۲۰۲۴، هر سه شاخص NDVI، EVI و MVI روندی تقریباً مشابه را دارند. در هر سه شاخص، کاهش بیش از ۲۰ درصد در پوشش آبی و افزایش بیش از ۲۰ درصد در سطح خاک مشاهده شده است که احتمالاً ناشی از پدیده جزرومد است. از سوی دیگر، پوشش


شاخص NDVI



شاخص EVI



شاخص MVI




شکل ۲- درصد پوشش کلاس‌های مانگرو بر اساس شاخص‌های NDVI، EVI و MVI در سال‌های ۲۰۲۴ و ۲۰۱۹
Fig 2. Percentage of Mangrove Cover Classes Based on NDVI, EVI and MVI Indices in 2019 and 2024

در شکل (۳)، میزان تغییرات سه شاخص NDVI، EVI و MVI در سال‌های ۲۰۱۹ و ۲۰۲۴ نمایش داده شده است. طبقه‌بندی انجام شده، با استناد به مشاهدات میدانی و بهره‌گیری از نقاط کنترل زمینی، در محیط ArcMap طراحی شد، به گونه‌ای که توانایی تفکیک درختان مانگروی بدون طراوت از درختان مانگرو با طراوت دارا باشد. ابتدا بازید میدانی از جنگل‌های مانگرو واقع در منطقه تیاب و کلاهی به همراهی کارشناسان اداره منابع طبیعی هرمزگان هم‌زمان با فصل شکوفایی و اوج سبزی‌نگی و رشد جنگل‌های حرا انجام شد. براساس مشاهدات میدانی و نظرات کارشناسان، وضعیت طراوت درختان مانگرو به صورت تصادفی در سطح منطقه تعیین شد و موقعیت جغرافیایی آن‌ها با استفاده از دستگاه GPS ثبت شد. در مرحله بعد، با استفاده از داده‌های میدانی، تلاش شد تا درختان مانگرو براساس میزان طراوت در محیط ArcMap تفکیک و شناسایی شوند و دامنه ارزش سلولی آن‌ها روی تصاویر رستری شاخص‌ها استخراج شد.


به منظور ارزیابی عدم قطعیت در نتایج طبقه‌بندی شاخص‌های NDVI، EVI و MVI از روش آماری IQR (دامنه بین چارک‌ها) و مونت کارلو استفاده شد. در این راستا، با محاسبه میانگین، انحراف معیار، Q_1 ، Q_2 ، Q_3 و IQR، نقاط پرت و داده‌های خارج از محدوده قابل اعتماد شناسایی شدند تا بتوان عملکرد هر شاخص را در طبقه‌بندی مقایسه نمود.

در شکل (۳) نمودار جعبه‌ای مربوط به سه شاخص فوق ارائه شده است، که در آن جعبه‌ها دامنه بین چارک‌ها (از Q_1 تا Q_3) را شامل می‌شوند و ۵۰ درصد میانی داده‌ها را نمایش می‌دهند. خط افقی وسط هر جعبه میانه داده‌ها، لبه‌های جعبه Q_1 و Q_3 ، خطوط عمودی بیرون زده حداقل و حداکثر مقادیر داده‌ها (به جز نقاط پرت) را نشان

در مقابل، شاخص EVI با وجود مزایای آن در اصلاح تأثیرات خاک و سایه‌های ناشی از توپوگرافی، در مقایسه با NDVI و MVI، میزان کمتری از پوشش مانگروهای با طراوت را در هر دو سال نشان داده است. این اختلاف معنادار می‌تواند ناشی از حساسیت پایین‌تر EVI نسبت به پوشش‌های گیاهی با تراکم متوسط تا پایین به ویژه در مناطقی با مانگروهای پراکنده یا در مراحل اولیه رشد باشد؛ همچنین، ساختار ریاضی این شاخص که عمدتاً برای محیط‌های جنگلی متراکم بهینه شده است، ممکن است موجب کاهش دقت آن در ارزیابی پوشش‌های مانگرویی شده باشد. بررسی پوشش مانگروهای بدون طراوت در سال ۲۰۱۹ نشان داد که شاخص NDVI مساحتی معادل ۶۳ هکتار، شاخص MVI مقدار ۴۴ هکتار و شاخص EVI میزان ۱۲۸ هکتار را برای این پوشش برآورد کرده‌اند. نتایج حاکی از آن است که در این سال، شاخص NDVI میزان بیشتری از مانگروهای بدون طراوت را نسبت به MVI شناسایی کرده است، در حالی که شاخص EVI به طور قابل توجهی مقدار بیشتری از این نوع پوشش را نشان داده است. در سال ۲۰۲۴، مقادیر به دست آمده برای مانگروهای بدون طراوت به ترتیب برای NDVI برابر با ۱۳۸ هکتار، برای MVI برابر با ۱۵۱ هکتار و برای EVI معادل ۱۳۱ هکتار بوده است. در این سال، شاخص NDVI نسبت به MVI میزان کمتری از پوشش بدون طراوت را نشان داده، اما همچنان مقدار بیشتری نسبت به شاخص EVI ثبت کرده است. مقایسه نتایج در دو بازه زمانی نشان می‌دهد که شاخص NDVI در سال ۲۰۱۹ نسبت به MVI مساحت بیشتری از مانگروهای بدون طراوت را برآورد کرده، در حالی که در سال ۲۰۲۴ این روند معکوس شده است. با این حال، شاخص MVI در هر دو سال مقادیر بالاتری از مانگروهای با طراوت را نسبت به NDVI ثبت کرده است.



شکل ۳- نقشه تغییرات پوشش مانگرو با شاخص‌های گیاهی NDVI، EVI و MVI (2019–2024)
Fig 3. Mangrove Cover Change Maps Using Spectral Indices NDVI, EVI and MVI (2019–2024)



شکل ۴- نمودار IQR سه شاخص NDVI، EVI و MVI در سال ۲۰۲۴
Fig 4. Boxplot of NDVI, EVI and MVI Showing IQR Variations in 2024

انتهای توزیع مشاهده شد که می‌تواند نشانه‌ای از ناهمگنی شدید در ساختار منطقه باشد. در مقابل، کلاس‌های ۵ تا ۷ با IQR بسیار کوچک و پراکندگی محدود، نشان‌دهنده یکنواختی زیاد یا احتمال کم بود داده است. شاخص EVI در مقایسه با MVI، عملکرد پویاتری داشت. کلاس‌های ۱ تا ۳ دارای پراکندگی قابل توجه بودند و در کلاس ۳ بیشترین میزان داده پرت مشاهده شد که ممکن است ناشی از حساسیت شاخص به پس‌زمینه باشد. در کلاس ۴، هیچ داده پرتی

می‌دهند. داده‌های پرت که خارج از محدوده ۱/۵ برابر IQR از Q_1 یا Q_3 قرار دارند، به صورت دایره‌های خالی مشخص شده‌اند. بر اساس شکل (۴) و مقادیر عددی ارائه‌شده در جدول (۱)، الگوی پراکندگی شاخص‌های پوشش گیاهی در کلاس‌های مختلف کاربری در سال ۲۰۲۴ مورد بررسی قرار گرفت. شاخص MVI در کلاس‌های ۲ و ۳ گستره‌ای نسبتاً وسیع از IQR داشت که بیانگر تنوع زیاد در این طبقات بود. در کلاس ۴، داده‌های پرت در هر دو

شناسایی نشد و IQR با دامنه کم داشت که حاکی از ثبات نسبی مقادیر در این طبقه است. کلاس‌های ۵ تا ۷ نیز مانند شاخص MVI، دارای داده‌های محدود با پراکندگی کم بودند. شاخص NDVI نیز در کلاس‌های ۱ تا ۴ رفتار قابل قبولی داشت. این شاخص توانست

در تمایز پوشش‌های متوسط تا متراکم عملکرد خوبی داشته باشد. در کلاس‌های ۵ تا ۷ نیز، مشابه دو شاخص دیگر، IQR بسیار کوچک بود و داده‌ها به سمت صفر میل می‌کردند که با پوشش‌های بدون گیاه مانند خاک و یا آب هم‌خوانی داشتند.


جدول ۱- نتایج کمی روش IQR سه شاخص NDVI، EVI و MVI در سال ۲۰۲۴

Table 1. Quantitative Results of the IQR Method for NDVI, EVI, and MVI Indices in 2024

وضعیت داده‌های پرت Outlier Status	بازه IQR IQR Range	میانه Median	کلاس Class	شاخص Indices	سال Year
تعداد کمی داده پرت Few outliers	0.1 تا 0.7	0.3	1		
بیشتر از کلاس ۱، در بازه پایین و نزدیک به صفر zero More than Class 1, in the lower range and close to	0.83 تا 1.20	0.95	2		
در محدوده بالا، نزدیک به عدد ۲ In the upper range, close to the value of 2	0.6 تا 1.1	0.8	3		
در هر دو حد بالا و پایین At both ends of the range	-0.40 تا -0.24	-0.32	4	MVI	2024
داده‌ها محدود و پراکنده Data are limited and scattered	0.02 تا 0.05	0.07	5		
داده‌ها محدود و پراکنده Data are limited and scattered	0.02 تا 0.05	0.03	6		
داده‌ها محدود و پراکنده Data are limited and scattered	0.02 تا 0.05	0.08	7		
بیشتر از شاخص MVI، در هر دو بازه بالا و پایین دارای داده پرت است Contains more outliers than the MVI index in both upper and lower ranges	0.07 تا 0.32	0.19	1		
هر دو بازه بالا و پایین مشاهده شد Observed in both upper and lower ranges	0.34 تا 0.45	0.38	2		
دارای بیشترین نقاط پرت در میان کلاس‌های EVI Has the highest number of outliers among EVI classes	0.34 تا 0.46	0.37	3		
بدون داده پرت No outliers	-0.14 تا -0.06	-0.10	4	EVI	2024
پراکندگی کم، داده‌ها محدود Low dispersion; data are limited	0.04 تا 0.05	0.003	5		
پراکندگی کم، داده‌ها محدود Low dispersion; data are limited	0.04 تا 0.05	0.009	6		
کمترین IQR در بین کلاس‌ها، داده‌ها محدود و متمرکز Smallest IQR among all classes; data are limited and concentrated	حدود 0.009	0.03	7		
میزان قابل توجه در هر دو بازه، نزدیک به مقادیر حداقل و حداکثر Significant outliers at both ends, close to minimum and maximum values	0.13 تا 0.49	0.30	1	NDVI	2024
بیشتر در بازه بالا مشاهده شد Mostly observed in the upper range	0.56 تا 0.68	0.59	2		
با فاصله زیاد در هر دو بازه بالا و پایین Wide outlier spread on both sides	0.53 تا 0.67	0.57	3		
بیشتر در بازه پایین Mostly in the lower range	-0.23 تا -0.12	-0.18	4		
IQR بسیار کوچک، داده‌ها نزدیک به صفر Minimal IQR; near-zero values	حدود 0.01	0.004	5		
IQR بسیار کوچک، داده‌ها نزدیک به صفر Minimal IQR; near-zero values	حدود 0.01	0.01	6		
IQR بسیار کوچک، داده‌ها نزدیک به صفر Minimal IQR; near-zero values	حدود 0.01	0.03	7		

بر اساس شکل (۵) و مقادیر عددی ارائه شده در جدول (۲)، الگوی پراکندگی شاخص‌های پوشش گیاهی در کلاس‌های مختلف کاربری در سال ۲۰۲۴ مورد بررسی قرار گرفت. شاخص MVI در کلاس‌های ۱ تا ۳ میانه‌هایی نسبتاً بالا و IQR متعادلی داشت که بیانگر تمرکز مناسب داده‌هاست. در کلاس‌های پایین‌تر (۵ تا ۷)، میانه‌ها به سمت صفر یا منفی میل کرده و پراکندگی به‌طور قابل‌توجهی کاهش یافت، که حاکی از یکنواختی زیاد در این طبقات است. EVI در کلاس‌های با پوشش متراکم، مانند کلاس ۱، داده‌های پرت گسترده‌ای نشان داد که احتمالاً ناشی از حساسیت این شاخص به نویز،

سایه یا پس‌زمینه خاکی است. اگرچه در طبقات بالاتر میانه‌ها منطقی بودند، در طبقات با پوشش ضعیف‌تر، رفتار EVI ناپایدارتر شد. تنها در کلاس ۷ این شاخص عملکرد نسبتاً باثباتی از خود نشان داد. NDVI در کلاس‌های ۱ تا ۳ دارای میانه‌های بالا و IQR کم بود که نشان‌دهنده تمرکز خوب داده‌هاست. با این حال، در برخی طبقات مانند ۱ و ۳، داده‌های پرت در بازه بالا مشاهده شد. در کلاس‌های پایین‌تر، بازه IQR گسترش یافت و داده‌های پرت بیشتری گزارش شد که می‌تواند بیانگر حساسیت این شاخص به بازتاب خاک یا پوشش‌های کم تراکم باشد.



شکل ۵- نمودار IQR سه شاخص NDVI، EVI و MVI در سال ۲۰۱۹

Fig 5. Boxplot of NDVI, EVI and MVI Showing IQR Variations in 2019

جدول ۲- نتایج کمی روش IQR سه شاخص NDVI، EVI و MVI در سال ۲۰۱۹

Table 2. Quantitative Results of the IQR Method for NDVI, EVI, and MVI Indices in 2019

وضعیت داده‌های پرت Outlier Status	IQR بازه IQR Range	میانه Median	کلاس Class	شاخص Indices	سال Year
داده‌های پرت با فاصله زیاد در هر دو بازه بالا و پایین Wide outliers at both ends	0.66 تا 0.33	0.47	1	MVI	2019
داده‌های پرت نزدیک به حدود بالا و پایین Outliers near both ranges	0.65 تا 0.52	0.57	2		
بیش از کلاس ۱، نزدیک به هر دو بازه More outliers than Class 1, near both bounds	0.70 تا 0.51	0.60	3		
در هر دو حد بالا و پایین Outliers in both upper and lower ranges	-0.40 تا -0.48	-0.44	4		
فقط در بازه پایین مشاهده شد Outliers only in lower range	-0.05 تا -0.06	-0.05	5		
تعداد کمی در هر دو بازه پایین و بالا Few outliers in both ranges	-0.03 تا -0.40	-0.20	6		
بدون داده پرت No outliers	0.07 تا 0.05	0.06	7		
داده‌های پرت بسیار زیاد و دور از بازه‌ها Numerous distant outliers	0.33 تا 0.21	0.27	1	EVI	2019

Quantitative Results of the IQR Method for NDVI, EVI, and MVI Indices in 2019.(continued) Table 2.

وضعیت داده‌های پرت Outlier Status	بازه IQR IQR Range	میان Median	کلاس Class	شاخص Indices	سال Year
داده‌های پرت نزدیک به هر دو حد بالا و پایین Outliers near both limits	0.34 تا 0.28	0.30	2	NDVI	2019
بالا کم، پایین بسیار زیاد Few in upper, many in lower range	0.34 تا 0.28	0.32	3		
در هر دو بازه پایین و بالا مشاهده شد Outliers at both ends	-0.11 تا -0.17	-0.14	4		
داده‌های پرت فراوان در بازه پایین Numerous outliers in lower range	-0.01 تا -0.03	-0.03	5		
داده‌های پرت با فاصله زیاد از هر دو بازه Outliers far from both ranges	0.0 تا -0.14	-0.08	6		
داده‌های پرت بسیار اندک در هر دو بازه Very few outliers in both ranges	0.03 تا 0.02	0.03	7		
داده‌های پرت فراوان در بازه بالا Numerous outliers in upper range	0.50 تا 0.34	0.39	1		
بالا بدون پرت، پایین تعداد کمی No outliers in upper, few in lower	0.50 تا 0.43	0.45	2		
در هر دو بازه مشاهده شد Outliers in both ranges	0.52 تا 0.44	0.47	3		
داده‌های پرت در بالا و پایین Outliers at both ends	-0.20 تا -0.28	-0.25	4		
داده‌های پرت با فاصله از بازه‌ها Outliers far from both bounds	0.01 تا -0.07	0.05	5		
داده‌های پرت در بازه پایین و بالا Outliers in both ranges	0.0 تا -0.26	-0.14	6		
تعداد کمی داده پرت مشاهده شد Few outliers	0.03 تا -0.02	0.03	7		

درصد) عملکرد قابل قبولی داشت در حالی که دقت در کلاس‌های ۵ (۵۰ درصد) و ۶ (۳۹/۴ درصد) نسبتاً پایین بود. خطاهای اصلی عمدتاً مربوط به اشتباه در تفکیک بین کلاس‌های ۵، ۶ و ۷ بود که این مسئله نشان‌دهنده هم‌پوشانی و عدم قطعیت در تعیین مرز این کلاس‌ها است.

در جدول (۴) نتایج شبیه‌سازی مونت-کارلو در سال ۲۰۲۴ با استفاده از شاخص‌های EVI، MVI و NDVI نیز آورده شده است. دامنه‌های توزیع شبیه‌سازی شده برای شاخص MVI (۰/۵- تا ۰/۲)، شاخص EVI (۰/۲- تا ۰/۶) و شاخص NDVI (۰/۴- تا ۰/۱) نشان دهنده تغییرات در گستره مقادیر و عدم قطعیت در داده‌ها است. MVI نسبت به سال ۲۰۱۹ دامنه وسیع‌تری را نشان می‌دهد، EVI دامنه‌ای نسبتاً ثابت داشته است و NDVI کاهش در دامنه منفی را داشت. دقت پیش‌بینی در سال ۲۰۲۴ برای کلاس‌های ۱ (۷۷/۲ درصد) و ۴ (۸۹ درصد) در محدوده قابل قبولی تا بسیار خوب قرار گرفتند. با این حال دقت طبقه‌بندی در کلاس‌های ۲ (۴۶ درصد)، ۳ (۴۶/۷ درصد)، ۵ (۴۰ درصد) و ۶ (۳۵/۵ درصد) به طور قابل توجهی کاهش یافت. کلاس ۷ نیز با دقت ۶۶/۹ درصد عملکرد

در مجموع، MVI در هر دو سال به‌ویژه در طبقات میانی، عملکرد باثبات و قابل اعتمادی داشت و توانسته تنوع پوشش را با پراکندگی منطقی منعکس کند. NDVI نیز شاخصی با پراکندگی کم و تمرکز بالا در طبقات با پوشش گیاهی است، اما در طبقات خاکی یا بدون پوشش، داده‌های پرت بیشتری دارد. در مقابل، EVI با وجود توان بالای تفکیک در طبقات متراکم، نسبت به نویزهای پس‌زمینه حساس‌تر است و در هر دو سال رفتار ناپایدارتری داشته است. در نتیجه MVI را شاخصی باثبات، NDVI را متعادل و EVI را حساس ولی پویاتر دانست.

در جدول (۳) نتایج شبیه‌سازی مونت-کارلو برای سال ۲۰۱۹ با استفاده از شاخص‌های طیفی EVI، MVI و NDVI ارائه شده است. شاخص MVI در بازه ۰/۱- تا ۱/۵، EVI در بازه ۰/۲- تا ۰/۶ و NDVI در بازه ۰/۶- تا ۰/۱، به ترتیب با فواصل کلاسی ۰/۵، ۰/۲ و ۰/۲ تغییر کرده‌اند. این توزیع‌ها به خوبی بیانگر عدم قطعیت موجود در محاسبات شاخص‌ها هستند. دقت پیش‌بینی، مدل طبقه‌بندی برای کلاس ۱ (۹۵/۷ درصد)، ۲ (۸۷/۱ درصد)، ۳ (۸۰/۴ درصد) و ۴ (۸۱/۴ درصد) دارای دقت بالایی بودند، کلاس ۷ (۶۴/۷ درصد)

جدول ۳- دقت پیش‌بینی و الگوی خطاها برای طبقه‌بندی کلاس‌ها در سال ۲۰۱۹

Table 3. Prediction Accuracy and Error Patterns for Class Classification in 2019

توضیحات	خطای اصلی (کلاس و درصد)	دقت پیش‌بینی صحیح (درصد)	کلاس
Description	Main error (class & percentage)	Correct prediction accuracy (percentage)	Class
دقت بسیار بالا	کلاس ۲ (۳.۶٪)، کلاس ۳ (۰.۴٪)	95.70	1
Very high accuracy	Class-2 (%3.6), Class-3 (%0.4)		
دقت بالا	کلاس ۱ (۹.۸٪)، کلاس ۳ (۳.۱٪)	87.10	2
High precision	Class-1 (%9.8), Class-3 (%3.1)		
دقت خوب	کلاس ۱ (۱۳.۴٪)، کلاس ۲ (۶.۲٪)	80.40	3
Good accuracy	Class-1 (%13.4), Class-2 (%6.2)		
دقت خوب	کلاس ۶ (۱۶.۸٪)، کلاس ۵ (۱.۸٪)	81.40	4
Good accuracy	Class-6 (%16.8), Class-5 (%1.8)		
دقت پایین	کلاس ۶ (۲۸.۴٪)، کلاس ۷ (۱۹.۵٪)	50.00	5
Low accuracy	Class-6 (%28.4), Class-7 (%19.5)		
دقت بسیار پایین	کلاس ۵ (۲۸.۴٪)، کلاس ۷ (۲۲.۹٪)	39.40	6
Very low accuracy	Class-5 (%28.4), Class-7 (%22.9)		
دقت متوسط	کلاس ۶ (۳۰.۳٪)، کلاس ۵ (۵٪)	64.70	7
Average accuracy	Class-6 (%30.3), Class-5 (%5)		

جدول ۴- دقت پیش‌بینی و الگوی خطاها برای طبقه‌بندی کلاس‌ها در سال ۲۰۲۴

Table 4. Prediction Accuracy and Error Patterns for Class Classification in 2024

توضیحات	خطای اصلی (کلاس و درصد)	دقت پیش‌بینی صحیح (درصد)	کلاس
Description	Main error (class & percentage)	Correct prediction accuracy (percentage)	Class
دقت خوب	کلاس ۲ (۸.۷٪)، کلاس ۳ (۴.۳٪)	77.20	1
Good accuracy	Class-2 (%8.7), Class-3 (%4.3)		
دقت پایین	کلاس ۱ (۳۸.۸٪)، کلاس ۳ (۱۵.۲٪)	46.00	2
low accuracy	Class-1 (%38.8), Class-3 (%15.2)		
دقت پایین	کلاس ۱ (۴۶.۷٪)، کلاس ۲ (۳۸٪)	46.70	3
low accuracy	Class-1 (%46.7), Class-2 (%38)		
دقت خوب	کلاس ۶ (۳.۶٪)، کلاس ۵ (۷٪)	89.00	4
Good accuracy	Class-6 (%3.6), Class-5 (%7)		
دقت پایین	کلاس ۶ (۱۵.۹٪)، کلاس ۷ (۳۴.۶٪)	40.00	5
low accuracy	Class-6 (%15.9), Class-7 (%34.6)		
دقت بسیار پایین	کلاس ۷ (۲۹.۲٪)، کلاس ۵ (۱۷.۷٪)	35.50	6
Very low accuracy	Class-7 (%29.2), Class-5 (%17.7)		
دقت متوسط	کلاس ۶ (۲۱.۵٪)، کلاس ۵ (۱۰.۶٪)	66.90	7
Average accuracy	Class-6 (%21.5), Class-5 (%10.6)		

در پیش‌بینی صحیح نمونه‌ها است. ضریب کاپا که معیار توافق مدل با داده‌های مرجع است نیز از ۰/۵۹ به ۰/۶۶ ارتقا یافته که نشان‌دهنده کاهش خطاهای تصادفی و بهبود کیفیت طبقه‌بندی است. امتیاز F1 از ۰/۶۷ به ۰/۷۳ افزایش یافته که نشان‌دهنده بهبود کلی عملکرد مدل در شناسایی صحیح نمونه‌های مثبت است.

این بهبود در تفکیک طبقه‌بندی شاخص‌های مختلف می‌تواند ناشی از افزایش کیفیت داده‌ها، بهبود پارامترهای مدل، یا بهبود روش‌های پیش‌پردازش و انتخاب ویژگی‌ها باشد. به طور کلی، نتایج حاصل از جدول (۵) نشان‌دهنده ارتقای قابل توجه عملکرد مدل در سال ۲۰۲۴ در مقایسه با سال ۲۰۱۹ هستند.

متوسطی داشت. بیشتر خطاهای مدل مربوط به اشتباه در تفکیک کلاس ۲ با ۱ یا کلاس ۵ با ۶ و ۷ بود، که نشان‌دهنده چالش مدل در مرزبندی دقیق این گروه‌ها بود. به منظور کاهش خطاها و ارتقای دقت طبقه‌بندی ادغام کلاس‌های ۵، ۶ و ۷ در قالب کلاس‌های اصلی بر اساس شباهت‌های طیفی صورت گرفت.

بر اساس نتایج ارائه‌شده در جدول (۵) برای دو سال ۲۰۱۹ و ۲۰۲۴، مشاهده می‌شود که تمامی شاخص‌های ارزیابی مدل شامل دقت، ضریب کاپا و امتیاز F1 در سال ۲۰۲۴ نسبت به سال ۲۰۱۹ بهبود قابل توجهی داشته‌اند. دقت مدل از ۰/۶۷ در سال ۲۰۱۹ به ۰/۷۳ در سال ۲۰۲۴ افزایش یافته است، که بیانگر افزایش توان مدل


جدول ۵- ارزیابی عملکرد مدل مونت کارلو در سال‌های ۲۰۲۴ و ۲۰۱۹

Table 5. Monte Carlo Model Performance Evaluation in 2019 and 2024


سال year	دقت Accuracy	ضریب کاپا Kappa	امتیاز (F1) F1 Score
2019	0.67	0.59	0.67
2024	0.73	0.66	0.73

با توجه به شکل ۶، بررسی کارایی مدل‌ها در تفکیک طبقه‌بندی در سال‌های ۲۰۱۹ و ۲۰۲۴ نشان می‌دهد که شاخص MVI به عنوان شاخص تخصصی برای ارزیابی پوشش گیاهی مانگرو، با رفتاری ثابت طبقه‌بندی در سال‌های ۲۰۱۹ و ۲۰۲۴ انجام داد، شاخص NDVI در سال ۲۰۲۴ نسبت به سال ۲۰۱۹ کارایی کمتر شده است و اما در مقابل شاخص EVI نسبت به NDVI در سال ۲۰۲۴ نسبت به سال ۲۰۱۹ بهبود پیدا کرده است. بر طبق بررسی میزان توانمندی هر شاخص در طبقه‌بندی، نتایج نشان داد شاخص MVI با رفتاری ثابت بهترین شاخص و بعد از آن شاخص EVI قرار می‌گیرد اما شاخص NDVI رفتاری ثابت و قابل اتکایی نداشت.

Feature Importance in final model in 2024



Feature Importance in final model in 2019



شکل ۶- کارایی شاخص‌های مختلف در تفکیک کلاس‌های پوشش گیاهی

Fig 6. Performance of Different Indices in Class Separability

در حوزه‌های آبخیز ساحلی جنگل‌های مانگرو به دلیل دارا بودن کارکردهای اکولوژیک، اقتصادی و حفاظتی، از اهمیت بالایی برخوردار بوده و حفظ و احیای آن‌ها ضرورتی اجتناب‌ناپذیر در مدیریت پایدار مناطق ساحلی به شمار می‌رود.

در این پژوهش، به منظور بررسی تغییرات پوششی جنگل‌های مانگرو، سه شاخص NDVI، EVI و MVI از تصاویر ماهواره‌ای در سال‌های ۲۰۱۹ و ۲۰۲۴ مورد استفاده قرار گرفتند، نتایج طبقه‌بندی تصاویر در بازه مذکور، کاهش سطح آب و افزایش سطح خاک و همچنین افزایش مانگروهای با طراوت و بدون طراوت را نشان داد. شاخص EVI بیشترین مساحت پوشش مانگروهای بدون طراوت را نشان داده است، که می‌تواند بیانگر حضور پوشش‌های در حال تخریب، نیمه‌خشک یا کم‌تراکم باشد.

تفاوت در برآورد میزان تخریب مانگروها در سال ۲۰۲۴ بین شاخص‌ها قابل توجه است؛ به‌طوری‌که شاخص MVI میزان تخریب را بیشتر از NDVI نشان داده است، که این امر نشان‌دهنده توان بالای MVI در شناسایی پوشش گیاهی مانگروهای تخریب شده است. با وجود شباهت‌های نسبی در برآوردها، تفاوت در حساسیت شاخص‌ها و توانایی آن‌ها در تشخیص الگوهای متفاوت تخریب، بر اهمیت انتخاب شاخص مناسب تأکید می‌کند. بررسی عدم قطعیت با روش IQR و شبیه‌سازی مونت-کارلو صورت گرفت و نتایج روش IQR نشان داد، شاخص MVI عملکرد باثبات و قابل اعتمادی داشته و توانسته تنوع پوشش را با پراکندگی منطقی منعکس کند. NDVI نیز شاخصی با پراکندگی کم و تمرکز بالا در طبقات با پوشش گیاهی است، اما در طبقات خاکی یا بدون پوشش، داده‌های پرت بیشتری دارد. در مقابل، EVI با وجود توان بالای تفکیک در طبقات متراکم، نسبت به نویزهای پس‌زمینه حساس‌تر است و رفتار ناپایدارتری داشته است. در نتیجه MVI را شاخصی باثبات، NDVI را متعادل و EVI را حساس ولی پویاتر دانست. اما در روش نتایج مونت-کارلو افزایش دقت کلی مدل از ۰/۶۷ درصد در سال ۲۰۱۹ به ۰/۷۳ درصد در سال ۲۰۲۴ را نشان داد. همچنین بر طبق بررسی میزان توانمندی هر شاخص برای طبقه‌بندی نشان داد که شاخص MVI با رفتاری ثابت بهترین شاخص و بعد از آن شاخص EVI قرار می‌گیرد، اما شاخص NDVI رفتاری ثابت و قابل اتکایی نداشت.

عرفانی‌فرد و لطفی [۴] با استفاده از شاخص MVI به شناسایی و طبقه‌بندی جنگل‌های مانگرو در جنوب ایران پرداختند. نتایج حاصل از به‌کارگیری الگوریتم جنگل تصادفی و ارزیابی دقت با شاخص‌های مختلف، نشان‌دهنده عملکرد بالای شاخص MVI در شناسایی پوشش‌های مانگرویی بود. در پژوهش حاضر نیز، شاخص MVI در تفکیک مانگروهای با طراوت، نسبت به NDVI عملکرد بهتری از خود نشان داده است؛ نتایج پژوهش حاضر هم‌راستا با نتایج مطالعه عرفانی‌فرد و لطفی (۱۴۰۲) است. به‌طور کلی، هر

سه شاخص NDVI، EVI و MVI بیانگر روند تخریب پوشش جنگلی مانگرو هستند؛ به‌گونه‌ای که میزان کاهش درختان مانگرو در سال ۲۰۲۴ نسبت به سال ۲۰۱۹، در تمامی شاخص‌ها افزایش داشته و نشان‌دهنده وضعیت بحرانی و روند رو به زوال این پوشش گیاهی ارزشمند است. مافی‌غلامی و جعفری [۱۵]، تغییرات پوشش جنگل‌های مانگرو در استان هرمزگان را طی سه دهه گذشته بررسی کرده‌اند، و نشان دادند که خشکسالی‌های طولانی مدت، کاهش میزان بارندگی و فعالیت‌های انسانی از جمله عوامل اصلی پس‌روی و کاهش سطح پوشش مانگروها بوده‌اند.

همچنین، بر اساس یافته‌های ایزدیان و همکاران [۱۱]، که از طریق نظرسنجی میدانی انجام شده است، دو تهدید اصلی برای این زیست‌بوم شامل آلودگی ناشی از تخلیه سوخت قاقاق و فعالیت‌های صید و صیادی بی‌رویه و غیرمجاز هستند، که در میان سایر تهدیدات، بیشترین اولویت را داشته‌اند. اگرچه در گذشته عوامل طبیعی فشار اصلی بر جنگل‌های مانگرو را تشکیل می‌دادند، اما در حال حاضر با افزایش دخالت‌های انسانی، میزان تخریب این بوم‌سازگان به‌طور چشمگیری افزایش یافته است. پژوهش حاضر نیز نشان داد بخشی از جنگل‌های مانگرو تخریب شده است که می‌تواند ناشی از عواملی باشد که در تحقیقات مافی‌غلامی و جعفری (۱۳۹۸) و ایزدیان و همکاران (۱۴۰۲) ذکر شد، باشد.

یافته‌های این مطالعه می‌تواند در برنامه‌های مدیریتی و سیاست‌گذاری‌های حفاظتی در مناطق ساحلی مورد استفاده قرار گیرند. به‌ویژه، اطلاعات حاصل از پایش تغییرات تخریب، ابزار مهمی برای تصمیم‌گیران و نهادهای مرتبط در اولویت‌بندی اقدامات حفاظتی و احیایی فراهم می‌آورد. همچنین، تأکید بر آموزش، آگاهی‌رسانی و جلب مشارکت جوامع محلی، می‌تواند نقش مهمی در کاهش فشارهای انسانی و ارتقاء سطح حفاظت از جنگل‌های مانگرو ایفا کند. جوامع محلی، به‌عنوان ذی‌نفعان مستقیم این زیست‌بوم‌ها، باید در فرآیندهای حفاظت، احیا و پایش مشارکت داده شوند تا پایداری درازمدت این بوسازگان تضمین گردد.

بر اساس نتایج بدست آمده در این پژوهش جهت بهبود مطالعات آینده پیشنهاد می‌شود که از الگوریتم‌های پیشرفته‌تری مانند SVM، Random Forest یا شبکه‌های عمیق یادگیری برای افزایش دقت مدل استفاده شود. همچنین داده‌های تکمیلی از سنجنده‌های با تفکیک بالاتر به کار گرفته شود تا تفکیک کلاس‌هایی با هم‌پوشانی زیاد بهبود یابد. از طرفی، تحلیل حساسیت و ارزیابی منابع عدم قطعیت برای انتخاب شاخص مناسب در شرایط خاص منطقه‌ای، گسترش یابد. این پژوهش با ارائه تحلیلی دقیق از تغییرات تخریب مانگروها، بر ضرورت پایش مستمر و به‌کارگیری شاخص‌های منتخب متناسب با ویژگی‌های منطقه‌ای تأکید دارد و بستر مناسبی برای سیاست‌گذاری‌های حفاظتی در نواحی مصب در حوزه‌های آبخیز ساحلی فراهم می‌آورد.

5- Firouzi, F. and Tavousi, T. Mahmoudi, P. 2019. Sensitivity analysis of NDVI and EVI vegetation indices to drought and wet conditions in arid and semi-arid regions: Case study of Sistan Plain, Iran. *Geographical Information Quarterly "Sepehr"* 28(110): 163–179. <https://doi.org/10.22131/sepehr.2019.36621>. (In Persian)

6- Ghayas, M. 2014. An Introduction to the Monte Carlo Simulation Method. *Scientific-Promotional Quarterly Journal* 4(1): 67–77.

7- Giri, Ch. 2016. Observation and Monitoring of Mangrove Forests Using Remote Sensing: Opportunities and Challenges. *Remote sensing* 8(9): 783. DOI:10.3390/rs8090783

8- Halder, B. and Bandyopadhyay, J. Khatun, R. 2024. Google Earth Engine and Sentinel 1/2 data-based forest degradation monitoring of Sundarban Biosphere Reserve. *Sustainable Horizons* 9: 100088. DOI:10.1016/j.horiz.2023.100088

9- Hamzeh, M. A. 2017. Assessment of the total area and spatial distribution of mangrove forests along the southern coasts of Iran. *Environment and Development*, 11(72): 111–172. DOI:10.22034/evat.2024.206086 (In Persian)

10- Hasan, M. and Hassan, L. Abdullah Al, M. Mustafa Kamal, A, H. Idris, M, H and et al. 2024. Human intervention caused massive destruction of the second largest mangrove forest, Chakaria Sundarbans, Bangladesh. *Environmental Science and Pollution Research* 31: 25329-25341. DOI: <https://doi.org/10.1007/s11356-024-32792-2>.

11- Izadian, M. and Hoseini Tayefe, F. Raygani, B. 2023. Biodiversity threats to the international Hara wetland of the Shour, Shirin, and Minab rivers and proposing participatory conservation strategies. *Marine Science and Technology Journal* 22(4): 96–114. DOI: T.2023.376136.2508. (In Persian)

12- Kathiresan, K. 2012. Importance of Mangrove Ecosystem. *International Journal of Marine Science* 2(10): 70-89. DOI: 10.5376/ijms.2012.02.0010

13- Kazemi, M. and Jafarpoor, A. 2025. Multi Temporal Land use/Land cover using Spectral indices, Sentinel-2 Imagery and Migrated Training Samples in Google Earth Engine. *jwmseir* 18 (67) : 1. <https://doi.org/10.22034/18.67.1>. (In Persian)

14- Khan, S. and Bhardwaj, A. Sakthive, M. 2024. Accuracy assessment of land use land cover classification using machine learning classifiers in Google Earth Engine: A case study of Jammu District. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 48 (4): 263–269. <https://doi.org/10.1016/j.isprs.2024.04.011>.

سپاسگزاری

بدین وسیله از معاونت محترم پژوهشی دانشگاه هرمزگان به دلیل حمایت مالی و پژوهشی صمیمانه سپاسگزاری می‌شود. همچنین از اداره منابع طبیعی که شرایط ایاب و ذهاب به منطقه تیاب و کلاهی را فراهم ساختند، تشکر و قدردانی به عمل می‌آید. شایسته است از شرکت تعاونی گردشگری کالنگ بندر تیاب میناب هرمزگان نیز به سبب در اختیار قرار دادن قایق جهت نمونه برداری های دریایی قدردانی به عمل آید.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

لاله شریفی پور: روش تحقیق، نگارش متن اصلی مقاله، نرم افزار مرضیه رضایی: آنالیز داده‌ها، نمونه برداری محمد کاظمی: نرم افزار و بازبینی مقاله، صحت سنجی داده‌ها علیرضا نفرزادگان: ویرایش و بازبینی مقاله رسول مهدوی نجف آبادی: بروزرسانی و بازبینی مقاله

منابع مورد استفاده

- Arvin, M. and Shahriari Moghaddam, M. Rahdari, V. Maleki Najafabadi, S. 2025. Assessment of conservation effects on land use/land cover changes in Gwatar Bay and Bahu Kalat Estuary after designation as a Ramsar site. *Ethnoecology and Biodiversity Conservation*, 2(1): 66–77. <https://doi.org/10.22091/ethc.2025.11662.1042>
- Baloloy, A, B. and Blanco, A, C. Rhommel C, R. Nadaoka, K. 2020. Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping. *ISPRS Journal of Photogrammetry and Remote Sensing* 166: 95-117. DOI:10.1016/j.isprsjprs.2020.06.001.
- Erfanifard, Y. and Lotfi Nasirabad, M. Stereńczak, K. 2022. Assessment of Iran's Mangrove Forest Dynamics (1990–2020) Using Landsat Time Series. *Remote Sensing* 14(19): 4912. <https://doi.org/10.3390/rs14194912>. (In Persian)
- ErfaniFard, Y. and Lotfi-Nasireabad, M. 2023. Zoning the Extent of Mangrove Forests in Iran Using Sentinel-2 Imagery. *Iranian Journal of Forest and Poplar Research* 31(2): 98–112. DOI: 10.22092/ijfpr.2023.360820.2081.

- 23- Safa Isini, H. and Danekar, A. Kamrani, E. 2006. Study of the Structure of Mangrove Forests in the Koulghan, Tiab, and Kolahi Areas in the Strait of Hormuz. *Environmental Sciences* 11: 1–10. https://envs.sbu.ac.ir/article_97106.html (In Persian)
- 24- Somvanshi, Sh, s. and Kumari, M. 2020. Comparative analysis of different vegetation indices with respect to atmospheric particulate pollution using sentinel data. *Applied Computing and Geosciences* 7: 100032. <https://doi.org/10.1016/j.acags.2020.100032>
- 25- Swami, R. and Dave, M. Ranga, V. 2023. IQR-based approach for DDoS detection and mitigation in SDN. *Defence Technology* 25: 76–87. DOI:10.1016/j.dt.2022.10.006
- 26- Safiari, Sh. 2010. Mangrove forests in Iran. *Nature of Iran* 2(6): 24-33. DOI: 10.22092/irn.2018.115186 (In Persian)
- 27- Tran, T, V. and Reef, R. Zhu, X. 2022. A review of spectral indices for mangrove remote sensing. *Remote Sensing* 14(19): 4868. DOI:10.3390/rs14194868
- 28- Tian, P. and Li, J. Wang, H. Gong, H. Kong, C. 2025. Evolution characteristics of land-sea coordination under high-intensity development in Taizhou coastal zone, China. *Chinese Geographical Science*, 35(2): 358–373. <https://doi.org/10.1007/s11769-025-1500-y>
- 29- Wicaksono, P. and Danoedoro, P. Hartono, & Nehren, U. 2016. Mangrove biomass carbon stock mapping of the Karimunjawa Islands using multispectral remote sensing. *Remote Sensing* 37(1): 26-52. <https://doi.org/10.1080/01431161.2015.1117679>
- 30- Yarmohammadi, M. and AleSheikh, A.A. Sharif, M. 2023. A convolutional neural network model for predicting dust storm trajectories using remote sensing and GIS. *Iranian Remote Sensing & GIS* 15 (1): 129–139. DOI: 10.52547/gisj.15.1.129 (In Persian)
- 31- Zhu, B. and Liao, J. Shen, G. 2021. Combining time series and land cover data for analyzing spatio-temporal changes in mangrove forests: A case study of Qinglangang Nature Reserve, Hainan, China. *Ecological Indicators* 131: 108135. DOI:10.1016/j.ecolind.2021.1081
- doi.org/10.5194/isprs-archives-XLVIII-4-2024-263-2024
- 15- Mafi Gholami, D.a and Jafari, A. 2020. Changes in seaward and landward extents of mangrove habitats on the coasts of Hormozgan Province. *Scientific Journal of Forests and Rangelands Protection and Conservation Research of Iran* 18(1): 1–13. DOI:10.22092/ijfrpr.2020.126154.1382. (In Persian)
- 16- Martinez, M. and Osland, M, J. Enwright, N, M. Grace, J, B. Stagg, C, L. Kaalstad, S. et al. 2024. Integrating remote sensing with ground-based observations to quantify the effects of an extreme freeze event on black mangroves (*Avicennia germinans*) at the landscape scale. *Ecosystems*, 27(1): 45–60. <https://doi.org/10.1007/s10021-023-00871-z>
- 17- Miandej, M,R. and Ashournejad, Q. Garshasbi, F. 2024. Assessment of Remote Sensing Images and Products in Mapping Mangrove Forests of Iran (Northern Coasts of the Persian Gulf and the Gulf of Oman). *DESERT* 29 (2): 283-302. DOI: 10.22059/jdesert.2024.100718. (In Persian)
- 18- Neri, M, P. and Baloloy, A, B. Blanco, A, C. 2021. Limitation Assessment And Workflow Refinement Of The Mangrove Vegetation Index (MVI)-Based Mapping Methodology Using Sentinel-2 Imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 46(4). <https://doi.org/10.5194/isprs-archives-XLVI-4-W6-2021-235-2021>
- 19- Parhizkar, F. and Rajabi, M. Yamani, M. Mokhtari, D. 2021. Analysis of changes in the range of mangrove forests in the north and east of the Strait of Hormuz affected by coastal morphology and hydrodynamics of the Persian Gulf. *Hydrogeomorphology* 7(25): 61–84. DOI: 10.22034/hyd.2021.39655.1531 (In Persian)
- 20- Pham, T, D. and Yokoya, N. Bui, D, T. Yoshino, K. Friess, D, A. 2019. Remote Sensing Approaces for Monitoring Mangrove Species, Structure, and Biomass: Opportunities and Challenges. *Remote sensing* 11(3): 230. DOI:10.3390/rs11030230
- 21- Prameswari, A, A, S, R. and Hariyanto, T. Sidik, F. 2015. Analisis indeks vegetasi mangrove menggunakan citra satelit ALOS AVNIR-2 (Studi kasus: Estuari Perancak, Bali). *Geoid* 11(1): 40-45. DOI: 10.12962/j24423998.v11i1.1094
- 22- Purnomo Aji, M, A. and Kamal, M. Farda, N, M. 2023. Mangrove species mapping through phenological analysis using random forest algorithm on Google Earth Engine. *Remote Sensing Applications: Society and Environment* 30: 100978. DOI: 10.1016/j.rsase.2023.100978