Spatiotemporal Analysis of Land Use and Vegetation Cover in the Takht–Qaleh Qazi Watershed Using Satellite Imagery and Machine Learning Algorithms

Mohammad Reza Dariaee Aftabi [a], **Ali Reza Nafarzadegan** [b *], **Abdolnabi Bagheri** [c]
[a] *M.Sc. graduate, Department of Natural Resources Engineering, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar-Abbas, Hormozgan, Iran.*
[b] *Associate Professor, Department of Natural Resources Engineering, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar-Abbas, Hormozgan, Iran. (Corresponding author)*
[c] *Assistant Professor, Agricultural Extension and Education Research, Education and Research Center for Natural and Agricultural Resources of Hormozgan, AREEO, Bandar-Abbas, Iran.*

Research Full Paper
Article History (Received: 2025/07/13 Accepted: 2025/09/15)

Extended abstract

1- Introduction

Vegetation cover is a fundamental component of ecosystems, covering a large portion of the Earth's surface and playing a crucial role in biogeochemical and hydrological cycles. It is closely linked with soil, water, and the atmosphere, while also providing essential ecosystem services such as carbon sequestration, water and soil conservation, air purification, and biodiversity preservation. Monitoring vegetation dynamics over time is therefore vital for assessing ecosystem health and sustainability. Land use and land cover (LULC) analyses are also critical in environmental studies, reflecting both human activities and natural processes that significantly influence biodiversity, environmental quality, and sustainable development. Rapid urban expansion, agricultural changes, and deforestation highlight the need for accurate and up-to-date LULC data to support effective resource management and planning. Recent advances in remote sensing and geographic information systems, combined with machine learning algorithms such as Support Vector Machine (SVM) and Random Forest (RF), have enhanced the precision of LULC classification and change detection. Earth observation satellite imagery, including Landsat and Sentinel-2, provides extensive spatial and temporal data for monitoring vegetation cover changes over large and inaccessible areas. This study focuses on the Takht–Qaleh Qazi watershed, an important agricultural region in Hormozgan Province, with the aim of analyzing spatiotemporal land use and vegetation cover changes using spectral indices (BSI, DSWI, EVI, GNDVI, MSI, NDMI, NDVI, SAVI) and machine learning classification models. The research seeks to address the lack of up-to-date environmental monitoring in this area and to provide valuable insights that support sustainable natural resource management.

2- Material and Methods

This study aimed to investigate land use changes and temporal vegetation dynamics in the Takht–Qaleh Qazi watershed over the period 2014 to 2024. The research process was designed in two main stages: The first stage involved generating classified land use maps for the target years (2014 and 2024) using satellite imagery and machine learning algorithms. The second stage consisted of analyzing temporal vegetation changes using spectral indices and multi-temporal Landsat and Sentinel-2 images within the Google Earth Engine environment. Data processing, spectral index calculation, and machine learning implementations were performed using the R programming language with specialized packages including caret, e1071, randomForest, raster, rasterVis, and Boruta. Satellite images were loaded based on required spectral bands and clipped to the study area using spatial boundary layers to retain relevant data only. Training and validation sample points were imported as separate spatial layers into R. Spectral indices such as NDVI, DSWI, and NDMI were calculated for each image and integrated with band data to create a comprehensive dataset for sample points. To reduce dimensionality and remove highly correlated variables, feature selection was conducted in two steps: Pearson correlation analysis via SPSS was first used to exclude highly correlated variables, followed by the Boruta algorithm in R to select the most important variables for modeling. Classification modeling was performed using Support Vector

* **Corresponding Author: a.r.nafarzadegan@hormozgan.ac.ir**

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

Machine (SVM) and Random Forest (RF) algorithms. Models were trained on training data and validated with evaluation data. Performance was assessed using appropriate statistical metrics. Finally, trained models were applied to the entire study area to produce and save final land use/land cover classification maps.

3- Results

This study evaluated the performance of two machine learning algorithms, Support Vector Machine (SVM) and Random Forest (RF), for land use classification and spatiotemporal analysisin the Takht–Ghaleh Ghazi watershed from 2014 to 2024. Both models showed improved classification accuracy over time, with SVM achieving superior results, particularly in identifying agricultural and orchard lands. By 2024, SVM accuracy reached 83% (Kappa = 0.75), outperforming RF's 78% accuracy (Kappa = 0.67). Analysis of land use changes revealed a decrease in agricultural land and water bodies, accompanied by increases in orchards and barren lands, reflecting dynamic land management and environmental pressures in the region. Vegetation health was assessed through spectral indices (EVI, NDVI, SAVI) derived from Landsat 8 and Sentinel-2 imagery. These indices peaked in 2020, indicating optimal vegetation density and vigor, followed by a declining trend attributed to factors such as urban expansion, land use change, and climate variability. Although some recovery was noted post-2020, vegetation conditions have yet to return to their peak state. The results demonstrate that machine learning models can effectively classify different kinds of land use over the study area and that satellite-derived spectral indices provide reliable temporal insights into vegetation dynamics. These findings underscore the potential of integrating advanced remote sensing and machine learning techniques for sustainable natural resource management and environmental monitoring.

4- Discussion & Conclusions

The results derived from vegetation indices (NDVI, EVI, and SAVI) extracted from Landsat 8-9 and Sentinel-2 satellite data revealed consistent trends in vegetation changes over the study periods. Despite some differences in absolute index values due to sensor and processing variations, both datasets showed synchronized increasing and decreasing patterns. The year 2020 was identified as the peak of vegetation density and health, with the highest recorded index values. Subsequent declines may be attributed to climatic factors, natural environmental changes, or human activities such as unsustainable resource exploitation. Land use change analysis using SVM and RF machine learning models on Landsat data from 2014 to 2024 demonstrated significant improvements in classification accuracy by 2024. The SVM model achieved an overall accuracy of 83% and a Kappa coefficient of 0.75, outperforming the RF model which reached 78% accuracy and 0.67 Kappa. This improvement aligns with findings from previous studies highlighting the impact of enhanced data quality and algorithm refinement. SVM showed particularly high accuracy in classifying agricultural lands, orchards, and water bodies, with balanced accuracy reaching 100% for orchards in 2024. RF performed well in identifying built-up areas in 2014 and orchards in 2024. These results are consistent with similar research but also highlight that model performance can vary depending on regional, temporal, and data-specific factors. Overall, this study emphasizes that combining multiple satellite data sources with advanced classification algorithms enhances the accuracy and reliability of environmental change assessments. The SVM algorithm, in particular, proves highly effective for detailed land use classification and, alongside RF, provides a robust toolset for monitoring land cover dynamics.

Key Words: GNDVI, Landsat-9, Land use change, Sentinel-2, Spectral vegetation indices.

Cite this article: Dariaee Aftabi, M., Nafarzadegan, AR., & Bagheri, A. (2026). Spatiotemporal analysis of land use and vegetation cover in the Takht–Qaleh Qazi watershed using satellite imagery and machine learning algorithms. *Journal of* Environmental *Erosion Research. 2026; 15 (4) :170-193*. http//doi.org/10.61186/jeer.15.4.170

© The Author(s).
DOI: http//doi.org/10.61186/jeer.15.4.170
Published by Hormozgan University Press.
URL: http://magazine.hormozgan.ac.ir

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

تحلیل مکانی-زمانی کاربری اراضی و پوشش گیاهی در حوضه آبخیز تخت – قلعه‌قاضی با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین

محمدرضا دریائی آفتابی: *دانش‌آموختهٔ کارشناسی‌ارشد علوم و مهندسی آبخیزداری، گروه مهندسی منابع طبیعی، دانشکدهٔ کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس*

علیرضا نفرزادگان*: *دانشیار، گروه مهندسی منابع طبیعی، دانشکدهٔ کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس*

عبدالنبی باقری: *استادیار، بخش تحقیقات کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی هرمزگان، سازمان تحقیقات و آموزش و ترویج کشاورزی، بندرعباس*

نوع مقاله: پژوهشی

تاریخچهٔ مقاله (تاریخ دریافت: ۱۴۰۴/۰۴/۲۲ تاریخ پذیرش: ۱۴۰۴/۰۶/۲۴)

DOI: http//doi.org/10.61186/jeer.15.4.170

چکیده

پوشش گیاهی به عنوان یکی از اجزای کلیدی بوم‌سازگان، نقش مهمی در حفظ تعادل محیط زیست و پایداری منابع طبیعی ایفا می‌کند. با توجه به تأثیر تغییرات کاربری اراضی بر سلامت پوشش گیاهی و اکوسیستم‌های محلی، پایش دقیق و تحلیل زمانی این تغییرات امری ضروری است. در این مطالعه، تغییرات کاربری اراضی و پوشش گیاهی در حوضه آبخیز تخت–قلعه‌قاضی طی بازه زمانی ۲۰۱۴ تا ۲۰۲۴ مورد بررسی قرار گرفت. به منظور طبقه‌بندی کاربری اراضی در سال‌های مورد مطالعه، از تصاویر ماهواره‌ای لندست به همراه الگوریتم‌های یادگیری ماشین، ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) استفاده شد. همچنین، برای تحلیل تغییرات پوشش گیاهی، شاخص‌های طیفی NDVI، EVI و SAVIاز داده‌های چندزمانه ماهواره‌های لندست ۸ و۹ و سنتینل-۲ در محیط گوگل ارث انجین استخراج و تحلیل شدند. نتایج نشان داد که دقت طبقه‌بندی مدل SVM در سال ۲۰۲۴ به ۸۳ درصد با ضریب کاپای ۰/۷۵ بوده است که نسبت به مدل RF با دقت ۷۸ درصد و کاپای ۰/۶۷، عملکرد بهتری داشته است. این مدل توانست کلاس‌های کشاورزی، باغات و پهنه‌های آبی را با دقت بالاتری شناسایی کند. همچنین تحلیل شاخص‌های پوشش گیاهی نشان داد که اوج تراکم و سلامت گیاهی در سال ۲۰۲۰ با مقادیر NDVI برابر با ۰/۱۸۳۸، EVI برابر با ۰/۱۵۴۴ و SAVI برابر با ۰/۱۳۷۴ بوده و پس از آن روندی نسبتاً کاهشی داشته‌اند. تغییرات کاربری اراضی نیز کاهش ۳۳۷ هکتاری اراضی زراعی و کاهش ۲۳۸ هکتاری پهنه‌های آبی را در کنار افزایش چشمگیر باغات (۱۳۹۳ هکتار) نشان می‌دهد. یافته‌ها اهمیت کاربرد داده‌های ماهواره‌ای و الگوریتم‌های پیشرفته یادگیری ماشین را در پایش تغییرات محیطی برجسته ساخته و نشان می‌دهد که این روش‌ها می‌توانند ابزارهای موثری برای مدیریت پایدار منابع طبیعی و تصمیم‌گیری‌های بهینه در حوضه‌های آبخیز باشند.

واژگان کلیدی: تغییرات کاربری اراضی، سنتینل-۲، شاخص‌های طیفی پوشش گیاهی، شاخص **GNDVI**، تصاویر لندست-۹.

* نویسندهٔ مسئول: a.r.nafarzadegan@hormozgan.ac.ir

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

۱ـ مقدمه

پوشش گیاهی یکی از اجزای اساسی اکوسیستم است که حدود ۷۰ درصد از سطح زمین را در بر می‌گیرد و نقش مهمی در چرخه‌های بیوژئوشیمیایی و هیدرولوژیکی ایفا می‌کند (Arellano et al., 2015; Veraverbeke et al., 2012; Zhou et al., 2015). این پوشش با عناصر طبیعی دیگر همچون خاک، آب و جو ارتباط تنگاتنگی دارد و خدمات حیاتی مانند ترسیب کربن، حفظ آب و خاک، تصفیه هوا و حفظ تنوع زیستی را فراهم می‌سازد (Sheram, 1993; Wang et al., 2012). پوشش گیاهی علاوه بر این، نقش مهمی در کنترل گازهای گلخانه‌ای و تعدیل تغییرات اقلیمی دارد (Caputo, 2009). از این رو، پایش دقیق پوشش گیاهی و تغییرات آن در طول زمان، یکی از شاخص‌های کلیدی در ارزیابی سلامت اکوسیستم‌ها به شمار می‌رود. در مطالعات محیطی، پایش وضعیت کاربری زمین و پوشش زمین که اغلب به صورت مشترک با عنوان LULC[1] مطرح می‌شوند، اهمیت فراوانی دارند. کاربری زمین نشان‌دهنده نوع بهره‌برداری انسان و اکوسیستم از اراضی است، در حالی که پوشش زمین ویژگی‌های فیزیکی سطح زمین را توصیف می‌کند (Mariye et al., 2022). تغییرات کاربری و پوشش زمین، به ویژه تحت تأثیر فعالیت‌های انسانی مانند شهرسازی، کشاورزی و جنگل‌زدایی، تأثیرات قابل توجهی بر محیط زیست، تنوع زیستی و توسعه پایدار دارند (Maitima et al., 2009). با افزایش نگرانی‌ها درباره گسترش بی‌رویه مناطق شهری، کاهش اراضی کشاورزی و تخریب زیستگاه‌های طبیعی، دسترسی به داده‌های دقیق و به‌روز درباره کاربری زمین برای برنامه‌ریزی توسعه پایدار و مدیریت منابع طبیعی ضروری است (FAO, 2002). مطالعه کاربری زمین اهمیت بسزایی در درک الگوهای تغییرات محیطی، برنامه‌ریزی شهری، حفظ منابع طبیعی و مقابله با تغییرات اقلیمی دارد، از این رو رشد سریع شهرها، تغییرات کشاورزی، تخریب جنگل‌ها و گسترش زیرساخت‌ها ضرورت استفاده از روش‌های نوین مانند سنجش‌ازدور، سیستم اطلاعات جغرافیایی(GIS) ، مدل‌سازی و یادگیری ماشین را افزایش داده است (Hersperger et al., 2018). این فناوری‌ها نه‌تنها امکان تحلیل دقیق تغییرات کاربری زمین را فراهم می‌کنند، بلکه پیش‌بینی روندهای آتی و ارزیابی اثرات سیاست‌های زیست‌محیطی را نیز امکان‌پذیر می‌سازند. در همین راستا، داده‌های ماهواره‌ای رایگان مانند سری Landsatو Sentinel-2 شرایط مناسبی برای پایش تغییرات زمین و پوشش گیاهی در مناطق وسیع و دسترسی‌ناپذیر فراهم کرده‌اند (Rong et al., 2023). علاوه بر این، سیستم اطلاعات جغرافیایی به‌عنوان ابزاری قدرتمند در مدیریت، تحلیل و نمایش داده‌های مکانی عمل کرده و نقشی کلیدی در شناسایی الگوهای فضایی کاربری زمین ایفا می‌کند (European Environment Agency, 2023). از سوی دیگر، یادگیری ماشین به‌عنوان شاخه‌ای از هوش مصنوعی، با توانایی استخراج الگوها و ارائه پیش‌بینی‌های دقیق، جایگاه ویژه‌ای در تحلیل داده‌های متنوع سنجش‌ازدور دارد (Bishop, 2006) و به‌کارگیری الگوریتم‌های یادگیری نظارت‌شده و نظارت‌نشده، موجب افزایش دقت طبقه‌بندی و خودکارسازی فرآیند شناسایی تغییرات کاربری زمین شده و در نهایت امکان تحلیل جامع داده‌های پیچیده را فراهم می‌آورد. در سال‌های اخیر، استفاده از الگوریتم‌های یادگیری ماشین در طبقه‌بندی تصاویر ماهواره‌ای برای تحلیل کاربری زمین، مورد توجه زیادی قرار گرفته است. به عنوان نمونه، جولایی و وفایی‌نژاد (۱۴۰۲) در مطالعه‌ای با هدف ارزیابی دقت روش‌های یادگیری ماشین در طبقه‌بندی تصاویر لندست ۹ جهت برآورد کاربری‌های زمین شهری در

[1] Land Use / Land Cover

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

غرب تهران، از الگوریتم‌های Random Forest (RF)، Support Vector Machine (SVM) و Gradient Boosting استفاده کردند. نتایج این پژوهش نشان داد الگوریتم RF با دقت ۹۱/۴ درصد عملکرد برتری نسبت به سایر الگوریتم‌ها داشته است. همچنین ترکیب ویژگی‌های طیفی و بافتی موجب بهبود کیفیت طبقه‌بندی شد و اهمیت انتخاب الگوریتم مناسب در تحلیل‌های سنجش از دور تأکید گردید. در پژوهشی دیگر، کاظمی و جعفرپور (۱۴۰۳) به طبقه‌بندی سری زمانی کاربری اراضی با استفاده از شاخص‌های طیفی NDVI، NDWI، NDBI و SAVI و تصاویر سنتینل-۲ در محیط GEE پرداختند. در این مطالعه، الگوریتم‌های یادگیری ماشین نظیرRF، SVM و CART به کار گرفته شدند که الگوریتم RF با دقت ۹۲ درصد بهترین عملکرد را ارائه داد. همچنین استفاده از داده‌های چندزمانه و منابع آموزشی متنوع، موجب افزایش دقت و پایداری طبقه‌بندی شد. این پژوهش اهمیت کاربرد شاخص‌های طیفی و الگوریتم‌های یادگیری ماشین در تحلیل تغییرات کاربری اراضی را تأیید می‌کند .در این مطالعه، برای تحلیل پوشش گیاهی، از شاخص‌های طیفی متنوعی بهره گرفته شد که برخی از آن‌ها در محیط Google Earth Engine (GEE) محاسبه شدند. شاخص‌های طیفی پوشش گیاهی مانند NDVI[1]، SAVI[2] و EVI[3] که از ترکیب باندهای قرمز و فروسرخ نزدیک (NIR)[4] در تصاویر ماهواره‌ای استخراج می‌شوند، اطلاعات دقیقی درباره سلامت و تراکم پوشش گیاهی ارائه می‌دهند. این شاخص‌ها با تبدیل داده‌های خام بازتاب نوری به مقادیر عددی و نقشه‌های کاربردی، امکان پایش تغییرات پوشش گیاهی در طول زمان را فراهم می‌کنند و در مطالعات اکولوژیکی و مدیریت منابع طبیعی کاربرد گسترده‌ای دارند. حوضه آبخیز تخت-قلعه‌قاضی به‌عنوان یکی از قطب‌های کشاورزی استان هرمزگان شناخته می‌شود و نقش حیاتی در تأمین محصولات کشاورزی منطقه دارد. با این حال، تاکنون پژوهش جامعی در زمینه پایش تغییرات کاربری اراضی و پوشش گیاهی این حوضه انجام نشده است. این کمبود مطالعات علمی، ضرورت انجام تحقیقات دقیق و به‌روز در این منطقه را بیش از پیش نمایان می‌سازد. این پژوهش با بهره‌گیری از داده‌های ماهواره‌ای پیشرفته و روش‌های یادگیری ماشین، تلاش می‌کند خلأ موجود را پر کرده و اطلاعات مهمی برای مدیریت پایدار منابع طبیعی و حمایت از تصمیم‌گیری‌های محلی و منطقه‌ای فراهم آورد.

۲ـ منطقهٔ مورد مطالعه

حوضه آبخیز تخت–قلعه‌قاضی به مرکزیت شهر قلعه‌قاضی، یکی از دشت‌های مهم در محدوده‌ی حوضه‌های آبخیز شمیل–تخت و قلعه‌قاضی– میناب در استان هرمزگان است که به‌عنوان یکی از قطب‌های اصلی کشاورزی استان شناخته می‌شود. این حوضه در حدود ۴۰ کیلومتری شمال‌شرق بندرعباس و در محدوده جغرافیایی بین بین طول‌های شرقی ۵۶ درجه و ۱۵ دقیقه تا ۵۷ درجه و ۳ دقیقه و عرض‌های شمالی ۲۷ درجه و ۱۵ دقیقه تا ۲۸ درجه و ۱۵ دقیقه واقع شده است. وسعت کل این حوضه ۴۰۵۳/۳ کیلومتر مربع است که شامل ۱۵۵۱/۷۲ کیلومتر مربع اراضی دشت و ۲۵۰۱/۵۸ کیلومتر مربع مناطق کوهستانی و ارتفاعات پیرامونی می‌باشد. رودخانه‌های اصلی منطقه شامل حسنلنگی و جلابی هستند که در دشت جریان دارند. اقلیم منطقه به‌صورت گرم و مرطوب در تابستان و معتدل در زمستان است و میانگین

[1] Normalized Difference Vegetation Index
[2] Soil-Adjusted Vegetation Index
[3] Enhanced Vegetation Index
[4] Near infrared

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

بارندگی سالانه آن حدود ۱۹۰/۵ میلی‌متر گزارش شده است (Hormozgan Regional Water Company, 2022). جمعیت شهر قلعه‌قاضی بر اساس سرشماری عمومی سال ۱۳۹۵، برابر با ۱۶۰۴۹ نفر بوده است. بخش زیادی از اراضی این حوضه به فعالیت‌های زراعی اختصاص دارد و محصولاتی چون گوجه‌فرنگی، خیار، فلفل، بادمجان و سایر صیفی‌جات در آن کشت می‌شود. وجود خاک حاصلخیز، منابع آبی مناسب و شرایط اقلیمی مساعد، این منطقه را به یکی از مراکز مهم تولید محصولات کشاورزی استان تبدیل کرده است. با توجه به ویژگی‌های طبیعی، کشاورزی و اهمیت اقتصادی منطقه، و نیز نبود پژوهش‌های جامع در زمینه پایش مکانی-زمانی تغییرات کاربری اراضی و پوشش گیاهی، این حوضه آبخیز برای انجام پژوهش حاضر انتخاب شده است (شکل ۱).

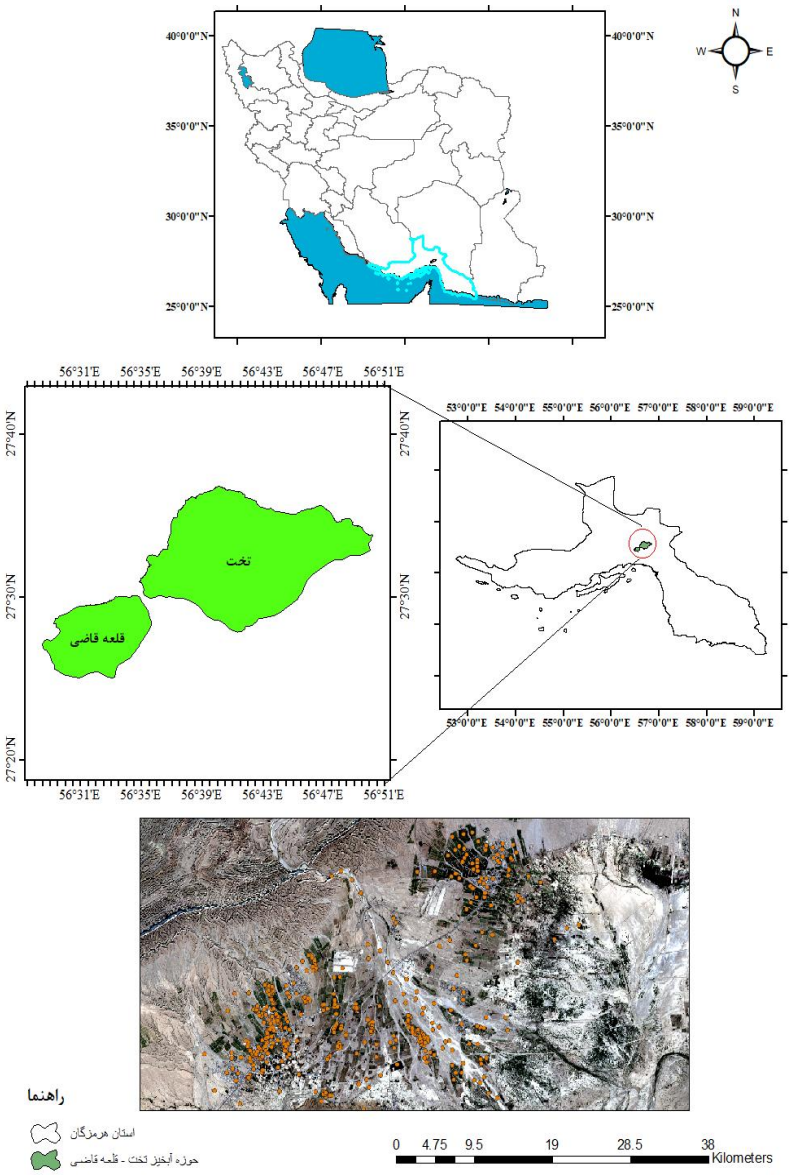

شکل ۱: موقعیت جغرافیایی حوضه آبخیز تخت – قلعه‌قاضی در کشور و استان هرمزگان

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

۳ـ مواد و روش

این پژوهش با هدف ارزیابی تغییرات کاربری اراضی و بررسی زمانی تغییرات پوشش گیاهی در حوضه آبخیز تخت–قلعه‌قاضی طی بازه زمانی ۲۰۱۴ تا ۲۰۲۴ انجام شد. فرایند مطالعه در دو مرحله طراحی شد: مرحله نخست شامل تهیه نقشه‌های طبقه‌بندی‌شده کاربری اراضی برای دو سال ۲۰۱۴ و ۲۰۲۴ (بازه زمانی ۱۰ ساله) با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین و مرحله دوم شامل پایش و تحلیل زمانی تغییرات پوشش گیاهی در گستره حوضه آبخیز با استفاده از شاخص‌های طیفی و تصاویر چندزمانه Landsat و Sentinel-2 در محیط GEE بود.

۳ـ۱ـ تصاویر و داده‌های ماهواره‌ای

در مرحله نخست، تصاویر ماهواره‌ای Landsat 8 (سال ۲۰۱۴) و Landsat 9 (سال ۲۰۲۴) از وبگاه رسمی سازمان زمین‌شناسی ایالات متحده (USGS Earth Explorer: https://earthexplorer.usgs.gov) دریافت شد. این تصاویر با قدرت تفکیک مکانی ۳۰ متر برای طبقه‌بندی کاربری اراضی استفاده شدند.

برای تحلیل زمانی پوشش گیاهی، از ۴۹۵ تصویر Landsat 8 در بازه ۲۰۱۴ تا ۲۰۲۴ و ۳۳۴ تصویر Sentinel-2 در بازه ۲۰۱۸ تا ۲۰۲۴ با درصد ابر کمتر از ۲۰ درصد استفاده شد. این تصاویر از سامانه GEE انتخاب و برای محاسبه شاخص‌های پوشش گیاهی مورد استفاده قرار گرفتند.

۳ـ۲ـ جمع‌آوری داده‌های میدانی و آماده‌سازی متغیرها

به‌منظور آموزش و ارزیابی مدل‌های طبقه‌بندی، داده‌های میدانی از اراضی منطقه با استفاده از دستگاه GPS برداشت شد. این نقاط شامل اطلاعات مکانی محصولات کشاورزی، اراضی بایر، مناطق شهری و سایر کاربری‌ها بود. داده‌های برداشت‌شده پس از پردازش، به نسبت ۷۰ درصد برای آموزش مدل و ۳۰ درصد برای ارزیابی عملکرد آن مورد استفاده قرار گرفتند (جدول ۱).

با بهره‌گیری از این نقاط مرجع، داده‌های مکانی با تصاویر ماهواره‌ای در محیط RStudio ترکیب شده و یک دیتافریم آموزشی شامل مختصات، برچسب کاربری، باندهای طیفی و مجموعه‌ای از شاخص‌های طیفی منتخب تشکیل شد.

جدول ۱: تعداد نمونه‌های برداشت شده در بازدیدهای میدانی با استفاده از GPS به تفکیک کاربری‌های مختلف

نوع کاربری اراضی	تعداد نمونه‌ها
زراعت	۱۱۶
باغات	۴۸
اراضی بایر	۴۷
ساخت و ساز انسانی	۹۴
پهنه آبی	۲۲

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

در این پژوهش، از مجموعه‌ای از شـاخص‌های طیفی به‌منظور بهبود دقت طبقه‌بندی کاربری اراضی و تحلیل پوشش گیاهی اسـتفاده شـد. این شـاخص‌ها با هدف ارزیابی سلامت، تراکم و تنوع پوشش گیاهی، تمایز مناطق بایر و تحلیل وضـعیت رطوبت خاک و گیاهان انتخاب شدند. شاخص NDVI[1] به‌عنوان پرکاربردترین شاخص برای بررسی سلامت گیـاهان، از تفاوت بازتاب باند قرمز و NIR بهره می‌گیرد EVI[2] و SAVI[3] نیز با اصـــلاح اثرات خاک و جو، تخمین دقیق‌تری از پوشـش گیاهی به‌ویژه در مناطق خشک فراهم می‌آورند. برای تمایز اراضی بدون پوشش و مناطق بایر، از شـاخص BSI[4] اسـتفاده شد. شاخص‌های مرتبط با رطوبت نظیر NDMI[5]، MSI[6] و DSWI[7] نیز امکان شناسایی استرس رطوبتی و وضـعیت خشکی پوشش گیاهی را فراهم کردند. همچنین از شاخص نسبتا جدید NDVI سبز (GNDVI[8])که از باند طیفی سبز نیز استفاده می‌کند وحساسیت بالاتری نسبت به گیاهان در حال رشد داشته، به عنوان یکی از متغیرهای ورودی برای آشـکارسـازی دقیق‌تر مناطق کشـاورزی اسـتفاده شد. شاخص TVI[9] نیز برای تحلیل تغییرات ناشی از خشـکســالی و شـرایط اقلیمی در پوشـش گیاهی به‌کار رفت.این شـاخص‌ها بر پایه ترکیب باندهای مختلف طیفی از تصـاویر Landsat و Sentinel-2 محاسـبه شـده و نقش مؤثری در افزایش تفکیک‌پذیری کلاس‌های کاربری زمین و پایش دقیق تغییرات پوشـش گیاهی ایفا کرده‌اند. معادله و منابع علمی هریک از این شـاخص‌ها در جدول ۲ ارائه شده است.

جدول ۲: نحوه محاسبه شاخص‌های طیفی مورد استفاده در این پژوهش

ردیف	مرجع	نام شاخص	معادله شاخص طیفی
۱	Milton, 1989	BSI	$BSI = \frac{(SWIR1 - RED)}{(SWIR1 + RED)}$
۲	Galvao *et al*., 2005	DSWI	$DSWI = \frac{(NIR - GREEN)}{(SWIR + RED)}$
۳	Huete *et al*., 2002	EVI	$EVI = 2.5 \times \frac{(NIR - RED)}{(NIR + 6 \times RED - 7.5 \times BLUE) + 1}$
۴	García Cárdenas *et al*., 2018	GNDVI	$GNDVI = \frac{(NIR - GREEN)}{(NIR + GREEN)}$
۵	Gao, 1996	MSI	$MSI = \frac{SWIR1}{NIR}$

[1] Normalized Difference Vegetation Index
[2] Enhanced Vegetation Index
[3] Soil-Adjusted Vegetation Index
[4] Bare Soil Index
[5] Normalized Difference Moisture Index
[6] Moisture Stress Index
[7] Disease Water Stress Index
[8] Green Normalized Difference Vegetation Index
[9] Transformed Vegetation Index

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

۶	Gao, 1996	NDMI	$NDMI = \frac{(NIR - SWIR1)}{(NIR + SWIR1)}$
۷	Tucker, 1979	NDVI	$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$
۸	Huete, 1988	SAVI	$(L+1) \times \frac{(NIR - RED)}{NIR + RED + L}$
۹	Lawrence *et al*., 2006	TVI	$TVI = \sqrt[2]{\frac{NIR - RED}{(NIR + RED)} + 0.5}$

۳ـ۳ـ طبقه‌بندی کاربری اراضی

طبقه‌بندی نهایی با بهره‌گیری از الگوریتم‌های جنگل تصادفی[1] و ماشین بردار پشتیبان[2] در محیط RStudio انجام گرفت. برای آموزش و ارزیابی مدل‌ها، مجموعه داده ترکیبی حاصل از تصاویر ماهواره‌ای، شاخص‌های طیفی و داده‌های میدانی به‌کار گرفته شـد. الگوریتم‌ها به‌طور جداگانه آموزش داده شـده و نتایج آن‌ها از نظر دقت با یکدیگر مقایسه گردیدند. تغییرات کاربری زمین مجموعاً حاکی از دگرگونی چشـمگیر در نحوه استفاده از زمین در منطقه طی بازه ده‌ساله است. برای محاسـبه مسـاحت تغییرات کاربری اراضی، از تعداد پیکسل‌های تغییر یافته در تصاویر ماهواره‌ای لندست استفاده شـد. با توجه به اینکه هر پیکسـل تصاویر لندست مساحتی معادل ۹۰۰ متر مربع (۳۰ متر × ۳۰ متر) را پوشش می‌دهد، ابتدا تعداد پیکسـل‌های تغییر یافته در ۹۰۰ ضـرب شده و سپس برای تبدیل به واحد هکتار (هر هکتار برابر با ۱۰،۰۰۰ متر مربع است)، حاصل بر ۱۰،۰۰۰ تقسیم شد. بنابراین، محاسبه مساحت تغییرات مطابق با معادله شماره (۱) است:

معادله (۱) **مساحت (هکتار) = ۱۰۰۰۰ ÷ (تعداد پیکسل ×۹۰۰)**

۳ـ۴ـ تحلیل پوشش گیاهی با شاخص‌های طیفی

برای ارزیابی روند پوشش گیاهی منطقه در بازه زمانی، از سه شاخص مهم NDVI، SAVI و EVI استفاده شد. این شاخص‌ها به‌صورت میانگین سالانه در محیط GEE بر اساس تصاویر Landsat و Sentinel-2 محاسبه شدند. داده‌های حاصل در قالب نمودارهای سری زمانی برای تحلیل روند تغییرات در پوشش گیاهی به‌کار رفتند.

[1] RF (Random Forest)
[2] SVM (Support Vector Machine)

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

۳-۵- ارزیابی دقت طبقه‌بندی

برای ارزیابی مدل‌های طبقه‌بندی، از معیارهای ارزیابی نظیر ماتریس سردرگمی[1]، دقت کلی[2] ، ضریب کاپا[3] و سنجه‌های حساسیت و ویژگی[4] استفاده شد جدول (۳). داده‌های میدانی برداشت‌شده، به دو بخش آموزش و ارزیابی تقسیم شده و نتایج طبقه‌بندی با مقادیر واقعی مقایسه شد.

جدول ۳: معیارهای ارزیابی دقت و عملکرد

شماره	نام	معادله	توضیحات
۱	دقت کلی (OA)	$\textbf{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$	TP: True Positives (مثبت‌های درست) TN: True Negatives (منفی‌های درست) FP: False Positives (منفی‌های نادرست) FN: False Negatives (مثبت‌های نادرست) TPR: True Positives Rate (نرخ حساسیت) TNR: True Negatives Rate (نرخ اختصاصی)
۲	دقت متوازن	$\textbf{Balanced Accuracy} = \frac{TPR + TNR}{2}$	
۳	حساسیت	$\textbf{Sensitivity} = \frac{TP}{TP + FN}$	
۴	ویژگی خاص	$\textbf{Specificity} = \frac{TN}{TN + FP}$	

۳-۶- پردازش و تهیه نقشه نهایی

در این پژوهش، پردازش داده‌ها، محاسبه شاخص‌ها و پیاده‌سازی الگوریتم‌های یادگیری ماشین با استفاده از زبان برنامه‌نویسی R و چندین کتابخانه تخصصی انجام گرفت. از جمله کتابخانه‌های کلیدی مورد استفاده می‌توان به بسته‌های caret، e1071، randomForest، raster، rasterVis و Boruta اشاره کرد که هر یک نقش خاصی در تحلیل داده‌های مکانی و مدل‌سازی داشتند. ابتدا به کمک توابع طراحی‌شده، تصاویر ماهواره‌ای بر اساس باندهای موردنیاز برای تحلیل‌های مختلف فراخوانی شدند. سپس این تصاویر به صورت سری زمانی[5] قرار گرفته و ناحیه مورد مطالعه با استفاده از لایه‌های اطلاعات مکانی محدوده پژوهش برش داده شد تا فقط داده‌های مرتبط با منطقه موردنظر باقی بمانند. نقاط نمونه آموزش و ارزیابی نیز به‌صورت لایه‌های اطلاعات مکانی جداگانه به محیط R وارد شدند. سپس شاخص‌های طیفی که در بخش پیشین معرفی شدند (مانند NDVI، DSWI، NDMI و...) برای هر تصویر محاسبه و به داده‌های موجود افزوده شدند. در این مرحله، یک دیتافریم نهایی حاوی مقادیر باندها و شاخص‌های طیفی برای تمام نقاط نمونه آموزش و ارزیابی تولید شد.برای کاهش ابعاد داده و حذف متغیرهای دارای همبستگی بالا، فرآیند انتخاب ویژگی[6] در دو مرحله انجام شد. در مرحله اول، آزمون همبستگی پیرسون[7] در محیط نرم‌افزار SPSS اجرا شد تا متغیرهای با همبستگی بالا

[1] Confusion Matrix
[2] Overall Accuracy
[3] Kappa Coefficient
[4] Metrics of Sensitivity and Specificity
[5] Time Series
[6] Feature Selection
[7] Pearson Correlation

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

شـناسایی و حذف گردند. سپس در مرحله دوم، از الگوریتم Boruta در محیط R استفاده شد تا مهم‌ترین متغیرها جهت تغذیه به مدل‌های یادگیری ماشـین انتخاب شـوند. در گام بعد، مدل‌سازی طبقه‌بندی با استفاده از دو الگوریتم یادگیری ماشین SVM وRF انجام گرفت. مدل‌ها بر اساس داده‌های آموزشی ساخته شده و سپس با داده‌های ارزیابی، اعتبارسنجی شـدند. برای ارزیابی عملکرد مدل‌ها، معیارهای گفته شده محاسبه شد. در نهایت، با اعمال مدل‌های آموزش‌دیده شده بر کل تصویر منطقه، نقشه‌های نهایی طبقه‌بندی تولید و ذخیره شدند.

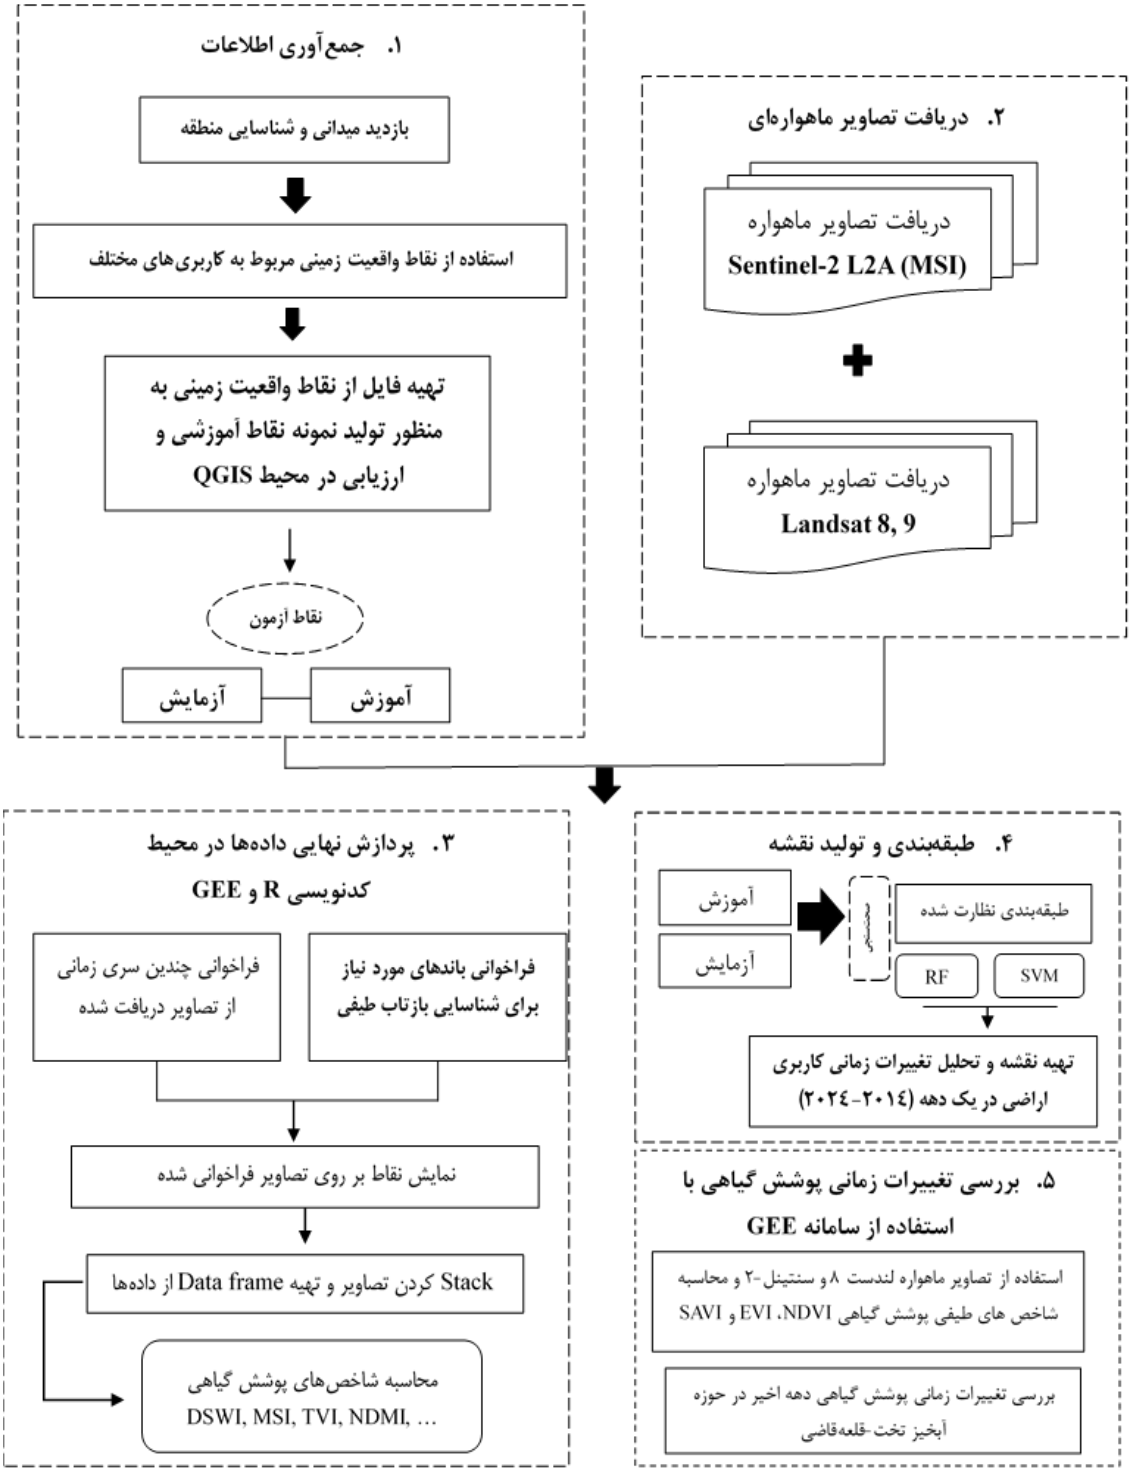

شکل ۲: نمودار جریانی تحقیق

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

۴-نتایج

۴-۱- نتایج مدل‌های طبقه‌بندی و تحلیل تغییرات کاربری اراضی

برای ارزیابی دقت مدل‌های یادگیری ماشین به‌کاررفته در طبقه‌بندی کاربری اراضی سال‌های ۲۰۱۴ و ۲۰۲۴، شاخص‌های مختلفی شامل دقت داده‌های آموزشی[1]، دقت داده‌های آزمایشی[2]، دقت کلی، ضریب کاپا، دقت متوازن و سنجه‌های حساسیت و ویژگی محاسبه شد. این شاخص‌ها به منظور بررسی میزان صحت طبقه‌بندی، توانایی تفکیک کلاس‌های مختلف و میزان توافق نتایج طبقه‌بندی با داده‌های واقعی به کار گرفته شده‌اند. نتایج حاصل از اجرای مدل‌های ماشین بردار پشتیبان و جنگل تصادفی برای هر دو سال، در جدول (۴) ارائه شده است تا امکان مقایسه‌ی عملکرد این مدل‌ها در بازه‌ی زمانی مورد مطالعه فراهم گردد.

جدول ۴: مقایسه دقت مدل‌های SVM و RF در طبقه‌بندی تغییرات کاربری اراضی (۲۰۱۴-۲۰۲۴) بر اساس درصد

سال	معیارهای ارزیابی مدل	دقت کلی		ضریب کاپا
	مدل	دقت آموزش	دقت آزمایش	
۲۰۱۴	SVM	۷۵	۶۶	۰/۶۲
	RF	۷۵	۶۵	۰/۶۰
۲۰۲۴	SVM	۸۲	۸۳	۰/۷۵
	RF	۸۱	۷۸	۰/۶۷

مطابق جدول (۴) در سال ۲۰۱۴ مدل SVM با دقت ۶۶ درصد و ضریب کاپای ۰/۵۲ و مدل RF با دقت ۶۵ درصد و ضریب کاپای ۰/۵۰ عملکرد مشابهی داشتند. در سال ۲۰۲۴، هر دو مدل بهبود قابل توجهی نشان دادند؛ مدل SVM به دقت ۸۳ درصد و ضریب کاپای ۰/۷۵ رسید، در حالی که مدل RF با دقت ۷۸ درصد و ضریب کاپای ۰/۶۷ عملکرد خوبی داشت. این بهبود می‌تواند ناشی از تغییر کیفیت داده‌ها یا تغییر الگوهای کاربری اراضی باشد. همچنین، شاخص‌های حساسیت و ویژگی برای ارزیابی عملکرد مدل‌ها در طبقه‌بندی تصاویر ماهواره‌ای در جدول (۵) ارائه شده‌اند.

[1] Training Accuracy
[2] Test Accuracy

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

جدول ۵: مقایسه سنجه‌های حساسیت و ویژگی مدل‌های SVM و RF برای سال‌های ۲۰۱۴ و ۲۰۲۴ بر اساس درصد

		سال ۲۰۱۴		سال ۲۰۲۴	
کلاس کاربری اراضی	مدل (Model)	حساسیت Sensitivity	ویژگی Specificity	حساسیت Sensitivity	ویژگی Specificity
کشاورزی	SVM	۷۹/۵۹	۶۸/۳۳	۱۰۰	۸۰
	RF	۸۱/۶۳	۷۰	۹۱/۸۴	۷۸/۳۳
باغات	SVM	۷۰	۱۰۰	۱۰۰	۱۰۰
	RF	۷۰	۹۸/۹۹	۱۰۰	۹۸/۹۹
اراضی بای‌ر	SVM	۴۰	۹۸/۹۳	۴۶/۶۶	۹۶/۸۰
	RF	۴۰	۹۸/۹۳	۶۰	۹۵/۷۴
ساخت و ساز انسانی	SVM	۶۷/۸۶	۸۱/۴۸	۸۲/۱۴	۹۶/۳۰
	RF	۷۱/۴۳	۸۰/۲۵	۷۵	۹۲/۵۹
پهنه‌های آبی	SVM	۴۲/۸۵	۱۰۰	۲۸/۵۷	۱۰۰
	RF	۰	۱۰۰	۰	۱۰۰

نتایج جدول (۵) نشان می‌دهد که در سال ۲۰۱۴، مدل SVM در شناسایی کلاس‌های کشاورزی و پهنه‌های آبی عملکرد خوبی داشت، در حالی که مدل RF در بیشتر کلاس‌ها به‌ویژه کشاورزی و باغات عملکرد قابل قبولی داشت، اما در شناسایی ساخت و ساز انسانی ضعیف‌تر بود. در سال ۲۰۲۴، مدل SVM بهبود قابل‌توجهی داشت و در شناسایی کلاس‌های کشاورزی، باغات و پهنه‌های آبی عملکرد بهتری ارائه داد. مدل RF نیز در باغات عملکرد خوبی داشت، اما در شناسایی ساخت و ساز انسانی نسبت به SVM ضعیف‌تر بود. به‌طور کلی، مدل SVM در سال ۲۰۲۴ بهبود قابل توجهی در دقت داشت.

۲-۴- ارزیابی دقت متوازن

به منظور تحلیل دقیق‌تر عملکرد مدل‌های طبقه‌بندی، دقت متوازن برای هر یک از کلاس‌های کاربری اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴ به تفکیک محاسبه شد. این معیار با درنظرگرفتن دقت تشخیص صحیح برای هر کلاس به طور مجزا، شکل کامل‌تری از توانایی مدل‌ها در تفکیک کلاس‌های مختلف ارائه می‌دهد. نتایج به‌دست‌آمده در جدول ۶ ارائه شده است:

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

جدول ۶: دقت متوازن مدل‌های SVM و RF بر اساس درصد برای سال ۲۰۱۴

کلاس کاربری اراضی	۲۰۱۴		۲۰۲۴	
	دقت متوازن SVM	دقت متوازن RF	دقت متوازن SVM	دقت متوازن RF
کشاورزی	۷۳/۹۶	۷۵/۸۲	۹۰	۸۵/۰۹
باغات	۸۵	۸۴/۴۹	۱۰۰	۹۹/۴۹
اراضی بایر	۶۹/۴۷	۶۹/۴۷	۷۱/۷۳	۷۷/۸۷
ساخت و ساز انسانی	۷۴/۶۸	۷۵/۸۴	۸۹/۲۲	۸۳/۸۰
پهنه‌های آبی	۷۱/۴۳	۵۰	۶۴/۲۹	۵۰

در سال ۲۰۱۴ (جدول ۶)، مدل SVM در طبقه‌بندی کلاس کشاورزی با دقت متوازن ۷۳/۹۶ درصد عملکرد بسیار خوبی داشت و در سایر کلاس‌ها نیز دقت قابل قبولی نشان داد. در مقابل، مدل RF در کلاس ساخت و ساز انسانی با دقت متوازن ۷۵/۸۴ درصد بهترین عملکرد را ثبت کرد. با این حال، دقت متوازن در برخی کلاس‌ها مانند پهنه‌های آبی برای هر دو مدل پایین‌تر بود.

در سال ۲۰۲۴ جدول (۶)، هر دو مدل پیشرفت قابل توجهی در دقت متوازن نشان دادند. مدل SVM در طبقه‌بندی باغات به دقت متوازن کامل ۱۰۰ درصد رسید و در سایر کلاس‌ها نیز بهبود داشت. همچنین مدل RF در طبقه‌بندی باغات با دقت متوازن ۹۹/۴۹ درصد و در طبقه‌بندی کشاورزی با دقت ۸۵/۰۹ درصد عملکرد بالایی از خود نشان داد. این نتایج بیانگر بهبود توان تفکیک مدل‌ها در سال ۲۰۲۴ نسبت به سال ۲۰۱۴ است.

در تحلیل‌های انجام شده، مدل‌های ماشین بردار پشتیبان و جنگل تصادفی برای طبقه‌بندی تغییرات کاربری اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴ مورد ارزیابی قرار گرفتند. بر اساس نتایج به‌دست‌آمده، مدل SVM در هر دو سال ۲۰۱۴ و ۲۰۲۴ دقت بالاتری نسبت به مدل RF نشان داد. این برتری به ویژه در شاخص‌های حساسیت و ویژگی مشهود است، به طوری که مدل SVM قادر بوده در شناسایی برخی کلاس‌ها، مانند کشاورزی و باغات، دقت بالاتری را نسبت به مدل RF ارائه دهد. در مرحله بعد، برای ارزیابی تغییرات فضایی ناشی از تغییرات کاربری اراضی در دو دوره زمانی، تصاویر طبقه‌بندی‌شده مدل‌ها برای سال‌های ۲۰۱۴ و ۲۰۲۴ به‌طور جداگانه تولید شد. این تصاویر به کمک ابزارهای تحلیلی برای بررسی تغییرات فضایی و مقایسه نتایج طبقه‌بندی در دو سال مختلف با اختلاف زمانی ۱۰ سال مورد استفاده قرار گرفتند. پس از آن، تغییرات در طبقه‌بندی‌ها با استفاده از شاخص‌های مختلف محاسبه و مورد تحلیل قرار گرفت.

جدول ۷: تغییرات مساحت کلاس‌های اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴ در منطقه تخت-قلعه‌قاضی

نام کلاس	سال ۲۰۱۴	سال ۲۰۲۴	تغییرات (هکتار)
زراعت	۱۰۱۶۴/۳۳	۹۸۲۶/۸۳	-۳۳۷/۵
باغات	۸۱۵/۰۴	۲۲۰۸/۹۶	۱۳۹۳/۹۲
اراضی بایر	۵۷۳۴/۸۹	۶۵۵۳/۸	۸۱۸/۹۱
پهنه آبی	۳۴۳/۸۹	۱۰۵/۶۶	-۲۳۸/۲۳

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

نتایج جدول (۷) تغییرات مساحت کلاس‌های اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴ نشان می‌دهند که در این دوره زمانی، تغییرات قابل توجهی در استفاده از اراضی رخ داده است. مساحت اراضی زراعی کاهش یافته است (۳۳۷/۵ هکتار)که ممکن است به دلیل کاهش فعالیت‌های کشاورزی باشد. در مقابل، مساحت باغات و اراضی بایر افزایش یافته است (۱۳۹۳/۹۲ هکتار و ۸۱۸/۹۱ هکتار)، که می‌تواند نشان‌دهنده تغییرات در سیاست‌های کشاورزی یا استفاده‌های دیگر از اراضی باشد. پهنه آبی نیز کاهش یافته است (۲۳۸/۲۳ هکتار)، که ممکن است به دلیل تغییرات اقلیمی و کاهش منابع آب باشد.

جدول ۸: تغییرات کاربری اراضی تبدیل‌شده به زراعت در بازه ۲۰۱۴ تا ۲۰۲۴

سال ۲۰۲۴	سال ۲۰۱۴	مساحت (هکتار)	درصد
زراعت	زراعت	۶۷۴۷/۸۴	۶۸/۷
	باغات	۱۴۱۲/۶۴	۱۴/۴
	اراضی بایر	۱۳۷۴/۸۴	۱۴
	ساخت و ساز انسانی	۲۴۴/۶۲	۲/۵
	پهنه آبی	۴۶/۸۹	۰/۵
مجموع		۹۸۲۶/۸۳	۱۰۰

نتایج جدول (۸) نشان می‌دهد که در سال ۲۰۲۴، بیشترین بخش از اراضی زراعی کنونی (حدود ۶۸/۷ درصد) قبلاً نیز کاربری زراعی داشته‌اند که بیانگر پایداری نسبی این نوع کاربری در طول زمان است. با این حال، حدود ۱۴ درصد از این اراضی از زمین‌های بایر، ۱۴/۴ درصد از باغات و ۲/۵ درصد از ساخت و ساز انسانی به زراعت تبدیل شده‌اند. این تغییرات می‌تواند ناشی از فشار برای افزایش سطح زیرکشت، سیاست‌های توسعه کشاورزی یا تغییرات کاربری برنامه‌ریزی نشده باشد.

جدول ۹: تغییرات کاربری اراضی تبدیل‌شده به باغات در بازه ۲۰۱۴ تا ۲۰۲۴

سال ۲۰۲۴	سال ۲۰۱۴	مساحت (هکتار)	درصد
باغات	زراعت	۱۰۰۲/۸۷	۴۵/۴۰
	باغات	۵۰۹/۰۴	۲۳/۰۴
	اراضی بایر	۵۹۹/۸۵	۲۷/۱۶
	ساخت و ساز انسانی	۶۷/۱۴	۳/۰۴
	پهنه آبی	۱/۳۶	۱/۳۶
مجموع		۲۲۰۸/۹۶	۱۰۰

نتایج جدول (۹) نشان می‌دهد که بیش از ۴۵ درصد از اراضی باغی در سال ۲۰۲۴، پیش‌تر در سال ۲۰۱۴ به زراعت اختصاص داشته‌اند، که نشان‌دهنده‌ی تغییر جهت قابل‌توجهی از کشاورزی سنتی به باغ‌داری است. همچنین حدود ۲۷ درصد این اراضی از اراضی بایر، و ۲۳ درصد نیز از باغات قبلی بوده‌اند که حاکی از گسترش باغات در مناطق جدید و بازسازی یا حفظ برخی باغات قبلی است. سهم ساخت و ساز انسانی و پهنه‌های آبی در این تغییر ناچیز بوده و در

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]
[DOI: 10.61186/jeer.15.4.170]

مجموع کمتر از ۵ درصـد بوده اسـت. این الگو ممکن است بیانگر افزایش تمایل به توسعه باغ‌داری به عنوان گزینه‌ای پایدارتر یا پرسودتر در مقایسه با زراعت سنتی باشد.

جدول ۱۰: تغییرات کاربری اراضی تبدیل‌شده به اراضی بایر در بازه ۲۰۱۴ تا ۲۰۲۴

سال ۲۰۲۴	سال ۲۰۱۴	مساحت (هکتار)	درصد
اراضی بایر	زراعت	۲۰۰۴/۸۴	۳۰/۵۹
	باغات	۴۶/۳۵	۰/۷۱
	اراضی بایر	۳۴۹۸/۳۹	۵۳/۳۸
	ساخت و ساز انسانی	۸۶۱/۰۳	۱۳/۱۴
	پهنه آبی	۱۴۳/۱۹	۲/۱۸
مجموع		۶۵۵۳/۸	۱۰۰

نتایج جدول (۱۰) نشان می‌دهد که بیشتر اراضی بایر سال ۲۰۲۴ قبلاً نیز کاربری بایر داشته‌اند (حدود ۵۳ درصد)، اما حدود ۳۰ درصد از آن‌ها از اراضی زراعی و ۱۳ درصد از ساخت و ساز انسانی تغییر یافته‌اند که نشان‌دهنده افزایش بایر شدن اراضی به‌ویژه در زمین‌های کشاورزی است.

۳-۴- تغییرات کاربری اراضی

نتایج تحلیل تغییرات کاربری اراضی بین سال‌های ۲۰۱۴ و ۲۰۲۴ نشان داد که الگوریتم SVM توانسته است با دقت بالا تفکیک مناسبی بین کلاس‌های مختلف ایجاد کند. در این بازه زمانی، بیشترین پایداری مربوط به کاربری‌های زراعت و اراضی بایر بوده است. همچنین تغییرات مهمی مانند تبدیل زراعت به اراضی بایر و افزایش سطح باغات از طریق تبدیل اراضی زراعی و بایر مشاهده شد. تغییر در پهنه‌های آبی محدود بود و کمترین جابه‌جایی در این کلاس رخ داد.

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

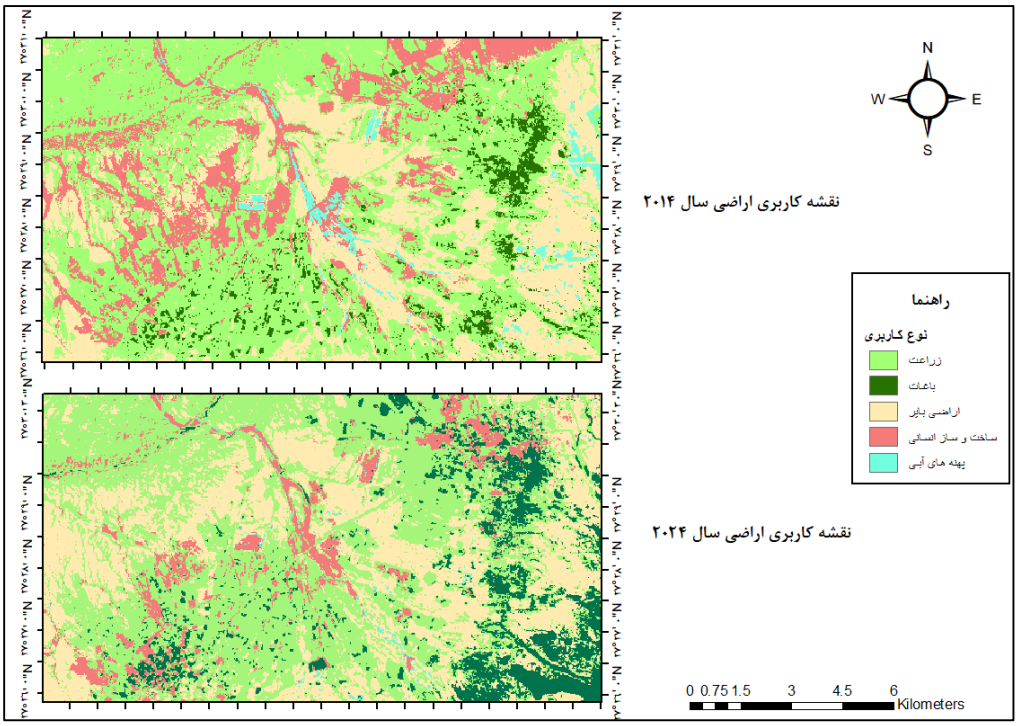

شکل ۳: تصویر تغییرات کاربری اراضی در دو بازه زمانی (۲۰۱۴–۲۰۲۴)، حوضه آبخیز تخت- قلعه‌قاضی

در شکل (۳) نقشه‌های کاربری اراضی مربوط به سال‌های ۲۰۱۴ و ۲۰۲۴ ارائه شده است که تغییرات عمده در کاربری‌ها، به ویژه در تبدیل اراضی زراعی به اراضی بایر و توسعه باغات، به خوبی قابل مشاهده هست.

۴-۴- بررسی روند تغییرات زمانی پوشش گیاهی با تصاویر لندست ۸ طی بازه زمانی ۲۰۱۴ تا ۲۰۲۴

به‌منظور تحلیل تغییرات پوشش گیاهی در منطقه مورد مطالعه، سه شاخص پرکاربرد NDVI، EVI و SAVI که از تصاویر ماهواره‌ای لندست ۸ استخراج شده‌اند، در طی بازه زمانی ۲۰۱۴ تا ۲۰۲۴ بررسی شدند. داده‌های مورد استفاده از محیط کدنویسی GEE استخراج و پردازش شده‌اند. این شاخص‌ها توانایی بالایی در ارزیابی وضعیت سلامت و تراکم پوشش گیاهی دارند. در ادامه، نمودارهای تغییرات سالانه شاخص‌های پوشش گیاهی به تفکیک هر شاخص ارائه شده‌اند تا روند تغییرات زمانی پوشش گیاهی در محدوده مورد پژوهش به‌صورت بصری قابل بررسی باشد.

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

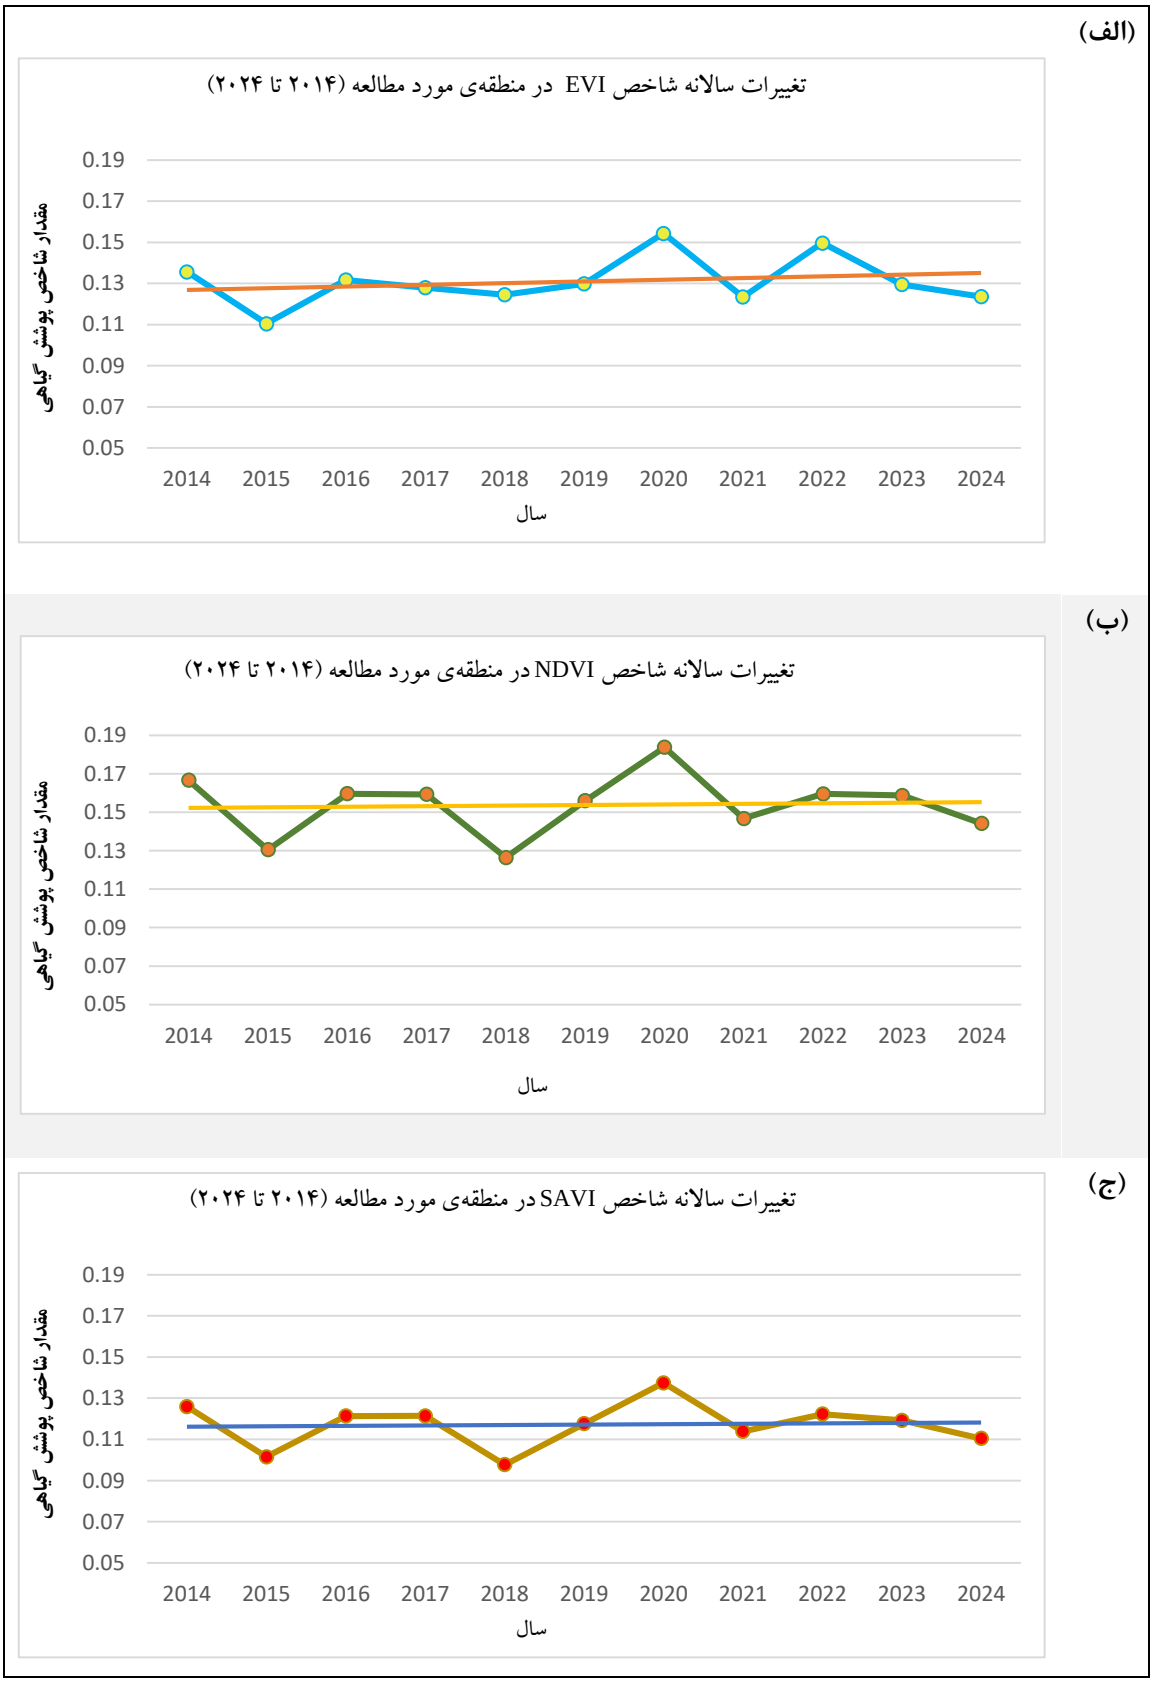

شکل ۴: روند تغییرات سالانه شاخص‌های EVI، NDVI و SAVI استخراج شده از تصاویر لندست ۸ به‌منظور پایش پوشش گیاهی در حوضه آبخیز تخت-قلعه‌قاضی **(۲۰۱۴-۲۰۲۴)**

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

نمودارهای ترسیم‌شده برای سه شاخصEVI، NDVI و SAVI که از تصاویر ماهواره‌ای لندست ۸ استخراج شده‌اند، روند تغییرات پوشش گیاهی را در بازه زمانی ۲۰۱۴ تا ۲۰۲۴ به‌خوبی نمایش می‌دهند. در میان سال‌های بررسی‌شده، سال ۲۰۲۰ به‌عنوان نقطه اوج وضعیت پوشش گیاهی در منطقه قابل شناسایی است. در این سال، شاخص EVI به مقدار ۰/۱۵۴۴، NDVI به ۰/۱۸۳۸ و SAVI به ۰/۱۳۷۴ رسیده‌اند که بیشترین مقادیر ثبت‌شده در دوره مورد نظر هستند. این ارقام حاکی از سلامت نسبی و تراکم بالای پوشش گیاهی در سال ۲۰۲۰ است. در مقابل، پایین‌ترین مقادیر شاخص‌ها عمدتاً در سال‌های ۲۰۱۵ و ۲۰۱۸ دیده می‌شوند. به‌طور خاص، در سال ۲۰۱۵ مقادیرEVI، NDVI و SAVI به ترتیب برابر با ۰/۱۱۰۴، ۰/۱۳۰۵ و ۰/۱۰۱۵ بوده‌اند. همچنین در سال ۲۰۱۸، SAVI به کمترین مقدار خود یعنی ۰/۰۹۷۷ رسیده است که نشان‌دهنده شرایط ضعیف پوشش گیاهی در آن سال‌هاست. احتمالاً این افت‌ها ناشی از عوامل محیطی نظیر کاهش بارندگی، خشکسالی‌های محلی یا فشارهای انسانی بوده است. بررسی روند کلی تغییرات نیز نشان می‌دهد که از سال ۲۰۱۴ تا ۲۰۲۰ یک روند افزایشی در هر سه شاخص وجود داشته که بیانگر بهبود نسبی شرایط پوشش گیاهی در این بازه زمانی است. اما از سال ۲۰۲۰ به بعد، روندی نزولی در شاخص‌ها دیده می‌شود. برای مثال، شاخص EVI از مقدار ۰/۱۵۴۴ در سال ۲۰۲۰ به ۰/۱۲۳۶ در سال ۲۰۲۴ کاهش یافته است. شاخص NDVI نیز از ۰/۱۸۳۸ در سال ۲۰۲۰ به ۰/۱۴۴۱ در سال ۲۰۲۴ رسیده که کاهش قابل توجهی به حساب می‌آید. این روند نزولی ممکن است به دلیل عوامل انسانی مانند توسعه شهری، تغییر کاربری اراضی یا تغییرات اقلیمی و افزایش دمای منطقه باشد.

۵-۴- بررسی روند تغییرات زمانی پوشش گیاهی با تصاویر سنتینل ۲ طی بازه زمانی ۲۰۱۸ تا ۲۰۲۴

به‌منظور تحلیل تغییرات پوشش گیاهی در منطقه مورد مطالعه، سه شاخص پرکاربرد NDVI، EVI و SAVI که از تصاویر ماهواره‌ای سنتینل ۲ استخراج شده‌اند، در طی بازه زمانی ۲۰۱۸ تا ۲۰۲۴ بررسی شدند. داده‌های مورد استفاده با استفاده از کدنویسی در محیط گوگل ارث انجیناستخراج و پردازش شده‌اند. این شاخص‌ها توانایی بالایی در ارزیابی وضعیت سلامت و تراکم پوشش گیاهی دارند.

در ادامه، نمودارهای تغییرات سالانه شاخص‌های پوشش گیاهی به تفکیک هر شاخص ارائه شده‌اند تا روند تغییرات زمانی پوشش گیاهی با تصاویر سنتینل-۲ در محدوده مورد پژوهش به‌صورت بصری قابل بررسی باشد.

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

(الف)

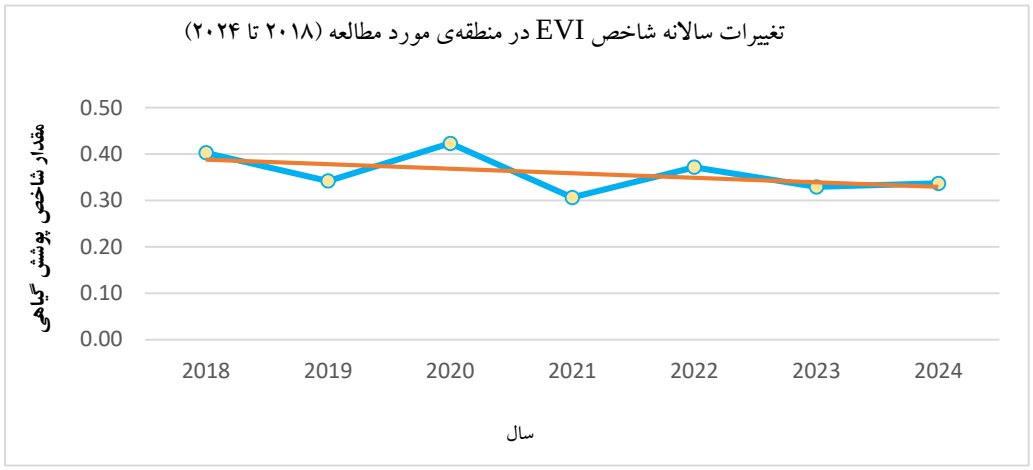

(ب)

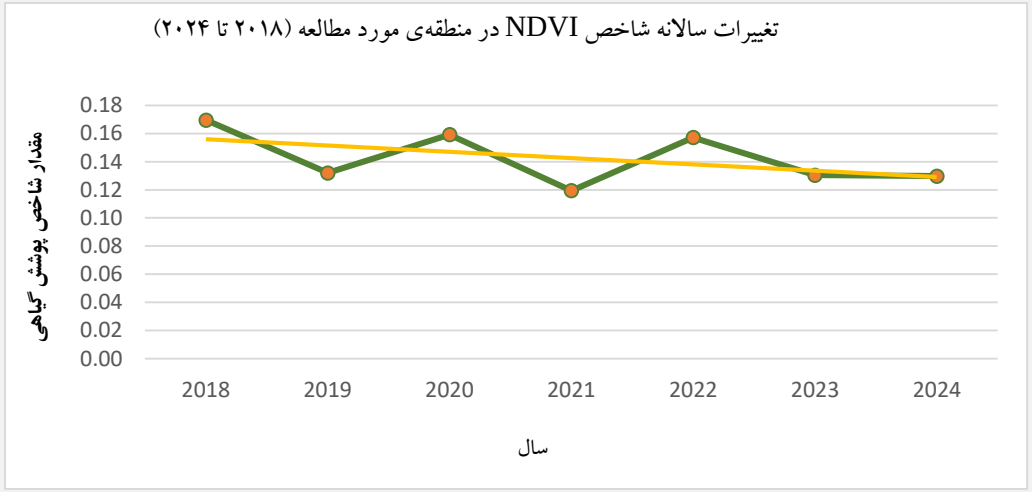

(ج)

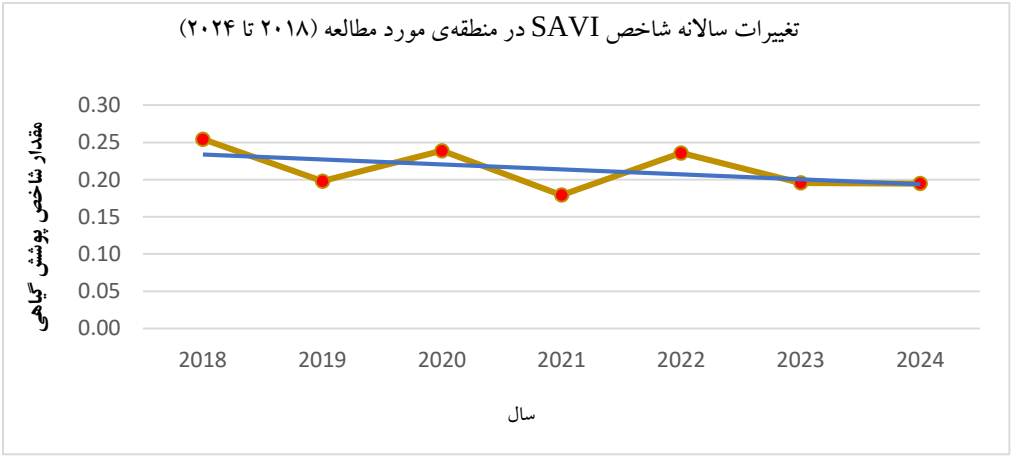

شکل ۵: روند تغییرات سالانه شاخص‌های EVI، NDVI و SAVI استخراج شده از تصاویر سنتینل-۲ به‌منظور پایش پوشش گیاهی در حوضه آبخیز تخت-قلعه‌قاضی (۲۰۱۸-۲۰۲۴)

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

نمودارهای مربوط به سه شاخص EVI، NDVI و SAVI که از تصاویر ماهواره‌ای سنتینل-۲ استخراج شده‌اند، روند تغییرات پوشش گیاهی در بازه زمانی ۲۰۱۸ تا ۲۰۲۴ را به خوبی نشان می‌دهند. در میان سال‌های مورد بررسی، سال ۲۰۲۰ با مقادیر شاخص EVI برابر با ۰/۴۲۳۱، NDVI برابر با ۰/۱۵۹۲ و SAVI برابر با ۰/۲۳۸۷، وضعیت بهتری از پوشش گیاهی را نسبت به سایر سال‌ها نشان می‌دهد که بیانگر تراکم و سلامت نسبی پوشش گیاهی در این دوره است. پایین‌ترین مقادیر شاخص‌ها عمدتاً در سال ۲۰۲۱ مشاهده می‌شود که به ترتیب مقدار EVI به ۰/۳۰۶۴، NDVI به ۰/۱۱۹۴ و SAVI به ۰/۱۷۹۱ کاهش یافته‌اند. این کاهش ممکن است تحت تأثیر شرایط محیطی نامطلوب، تغییرات اقلیمی یا فشارهای انسانی باشد. روند کلی شاخص‌ها در این بازه زمانی نشان می‌دهد که وضعیت پوشش گیاهی دارای نوساناتی است، به گونه‌ای که پس از رسیدن به اوج در سال ۲۰۲۰، مقادیر شاخص‌ها کاهش یافته و در سال‌های بعدی تا حدی بازیابی شده‌اند اما هنوز به میزان اوج سال ۲۰۲۰ نرسیده‌اند.

۵ـ بحث و نتیجه‌گیری

نتایج حاصل از شاخص‌های پوشش گیاهیNDVI ، EVI و SAVI که با استفاده از داده‌های ماهواره‌ای لندست-۸ (۲۰۱۴–۲۰۲۴) و سنتینل-۲ (۲۰۱۸–۲۰۲۴) استخراج شدند، نشان‌دهنده هم‌راستایی نسبی در روند تغییرات پوشش گیاهی منطقه هستند. اگرچه مقادیر مطلق این شاخص‌ها به دلیل تفاوت‌های فنی میان سنجنده‌ها و فرآیندهای پردازش تصویر تفاوت‌هایی با یکدیگر دارند، اما الگوهای افزایشی و کاهشی آن‌ها هماهنگی بالایی نشان داده است. بر اساس هر دو مجموعه داده، سال ۲۰۲۰ به‌عنوان سال اوج تراکم و سلامت پوشش گیاهی شناسایی شد؛ به‌گونه‌ای که مقادیر شاخص‌ها در این سال بیشترین مقدار ثبت‌شده را نشان دادند. کاهش نسبی مقادیر شاخص‌ها در سال‌های پس از آن، می‌تواند ناشی از عوامل اقلیمی (مانند کاهش بارندگی یا افزایش دما)، تغییرات طبیعی محیطی، یا تأثیرات انسانی نظیر بهره‌برداری ناپایدار از منابع و تغییر کاربری اراضی باشد. به‌طور خاص، افت شاخص‌ها در سال‌های ۲۰۱۵، ۲۰۱۸ و ۲۰۲۱ هم‌زمان با گزارش‌های محلی از وقوع خشکسالی‌های شدید و افزایش فشارهای انسانی بر زمین‌های کشاورزی بوده است. کاهش نسبی شاخص‌های پوشش گیاهی در سال‌های ۲۰۱۵، ۲۰۱۸ و ۲۰۲۱ احتمالاً ناشی از خشکسالی‌های شدید و فشارهای انسانی بر منابع آب و اراضی کشاورزی بوده است (Ahmadalipour et al., 2023). تحلیل تغییرات کاربری اراضی با استفاده از مدل‌های یادگیری ماشین SVM و RF و داده‌های ماهواره‌ای لندست در بازه زمانی ده‌ساله (۲۰۱۴ و ۲۰۲۴) نیز نشان داد که دقت کلی و ضریب کاپای هر دو مدل در سال ۲۰۲۴ به شکل قابل توجهی افزایش یافته‌اند. مدل SVM با دقت کلی ۸۳ درصد و ضریب کاپای ۷۵/۰ و مدل RF با دقت کلی ۷۸ درصد و کاپای ۶۷/۰ عملکرد بهتری نسبت به سال ۲۰۱۴ ارائه دادند. این بهبود بیانگر ارتقای کیفیت داده‌ها و توان الگوریتم‌ها در بازتاب تغییرات محیطی است و با یافته‌های Karan و Samadder (2016) همخوانی دارد.

از منظر کلاس‌های کاربری، نتایج نشان داد که مدل SVM در سال ۲۰۱۴ در طبقه‌بندی دقیق‌تر کلاس‌هایی مانند کشاورزی و پهنه‌های آبی عملکرد مطلوبی داشت و در سال ۲۰۲۴ توانست دقت ۱۰۰٪ را در شناسایی باغات به دست آورد. همچنین در تشخیص سایر کلاس‌ها از جمله کشاورزی، اراضی بایر و ساخت‌وساز انسانی نیز نتایج دقیق‌تری حاصل شد. مدل RF نیز در طبقه‌بندی ساخت‌وساز انسانی در سال ۲۰۱۴ و باغات در سال ۲۰۲۴ عملکرد خوبی داشت.

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

این یافته‌ها با نتایج پژوهش کاظمی و جعفرپور (۱۴۰۳) همخوانی دارد که در آن مدل RF در بسیاری از کلاس‌ها دقت قابل قبولی داشت. با این حال، نتایج مدل RF یک ضعف جدی را نشان داد؛ به‌گونه‌ای که حساسیت (Sensitivity) برای کلاس پهنه‌های آبی برابر با صفر گزارش شد. این موضوع می‌تواند ناشی از چند عامل باشد: نخست، تعداد محدود نمونه‌های آموزشی مربوط به این کلاس که منجر به ناتوانی الگوریتم در یادگیری الگوهای مناسب شده است؛ دوم، شباهت طیفی پهنه‌های آبی کم‌عمق با سایر کلاس‌ها نظیر اراضی بایر روشن یا اراضی کشاورزی مرطوب که باعث بروز خطا در طبقه‌بندی شده است؛ و سوم، تأثیر کیفیت تصاویر در برخی بازه‌های زمانی (مانند وجود سایه یا تداخل با پوشش گیاهی آبی) که تشخیص دقیق این کلاس را دشوار کرده است. بنابراین، برای بهبود نتایج در مطالعات آینده پیشنهاد می‌شود حجم داده‌های آموزشی پهنه‌های آبی افزایش یابد، از تصاویر با قدرت تفکیک مکانی و طیفی بالاتر استفاده شود، و الگوریتم‌های ترکیبی یا پس‌پردازش (نظیر فیلترهای مکانی) به‌کار گرفته شوند.

با توجه به اینکه منطقه مورد مطالعه به‌عنوان یکی از قطب‌های کشاورزی استان هرمزگان شناخته می‌شود، نتایج این پژوهش اهمیت بیشتری پیدا می‌کند. رشد و گسترش باغات که در نتایج پهنه‌بندی و طبقه‌بندی نیز مشاهده شد، نقش مهمی در افزایش شاخص‌های پوشش گیاهی در برخی سال‌ها داشته است. این موضوع بیانگر آن است که سرمایه‌گذاری در توسعه باغات و تغییر الگوی کشت توانسته به‌طور مستقیم بر بهبود شرایط پوشش گیاهی اثرگذار باشد. با این حال، کاهش مقادیر شاخص‌ها در برخی سال‌ها هشداردهنده بوده و نشان می‌دهد که فشارهای انسانی و اقلیمی همچنان تهدیدی جدی برای پایداری اکوسیستم منطقه محسوب می‌شوند.

مقایسه نتایج این پژوهش با مطالعات پیشین نیز نشان می‌دهد که انتخاب مدل مناسب در طبقه‌بندی کاربری اراضی باید متناسب با ویژگی‌های محلی، نوع داده و اهداف تحقیق انجام گیرد. برای مثال، Thanh Noi و Kappas (2017) بالاترین دقت کلی را برای مدل SVM در طبقه‌بندی با داده‌های سنتینل-۲ گزارش کردند، در حالی که Dabija و همکاران (۲۰۲۱) عملکرد بهتر RF را در برخی مناطق خاص نشان دادند. این تفاوت‌ها ضرورت انتخاب رویکرد بومی‌سازی‌شده را برای هر منطقه تأکید می‌کند.

در مجموع، یافته‌های این پژوهش نشان می‌دهد که استفاده ترکیبی از منابع داده‌ای مختلف (نظیر لندست و سنتینل) و به‌کارگیری مدل‌های پیشرفته طبقه‌بندی می‌تواند ابزار کارآمدی برای پایش تغییرات کاربری و پوشش زمین باشد. به‌ویژه الگوریتم SVM توانسته دقت بالایی در شناسایی باغات و اراضی کشاورزی منطقه قلعه‌قاضی ارائه دهد که این موضوع با توجه به نقش محوری کشاورزی در اقتصاد و معیشت محلی از اهمیت بالایی برخوردار است. بنابراین، پژوهش حاضر علاوه بر کمک به درک بهتر روند تغییرات پوشش گیاهی و کاربری اراضی، می‌تواند مبنای تصمیم‌گیری برای مدیریت پایدار منابع آب و خاک، برنامه‌ریزی کشاورزی و مقابله با تهدیدهای اقلیمی و انسانی در مناطق خشک و نیمه‌خشک مشابه باشد. از محدودیت‌های پژوهش حاضر می‌توان به وابستگی نتایج به داده‌های ماهواره‌ای با قدرت تفکیک مکانی متوسط، نبود داده‌های میدانی گسترده برای صحت‌سنجی دقیق‌تر و همچنین نداشتن دسترسی به داده‌های اقلیمی با تفکیک زمانی مناسب اشاره کرد. این موارد می‌تواند بر دقت نتایج اثرگذار باشد و پیشنهاد می‌شود در مطالعات آینده با ترکیب داده‌های زمینی و سنجش‌ازدور با قدرت تفکیک بالاتر، این محدودیت‌ها برطرف شود. در مجموع، نتایج این پژوهش نشان داد که استفاده از شاخص‌های پوشش گیاهی و مدل‌های یادگیری

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

ماشین می‌تواند ابزاری کارآمد برای پایش تغییرات کاربری و پوشش زمین در مناطق کشاورزی باشد. سال ۲۰۲۰ به‌عنوان نقطه اوج سلامت پوشش گیاهی و باغات شناسایی شد، اما کاهش مقادیر شاخص‌ها در سال‌های بعد بیانگر تهدیدهای اقلیمی و انسانی است. بنابراین، یافته‌های این پژوهش می‌تواند مبنایی برای برنامه‌ریزی کشاورزی پایدار، مدیریت منابع طبیعی و اتخاذ سیاست‌های سازگار با تغییرات اقلیمی در استان هرمزگان و سایر مناطق خشک و نیمه‌خشک کشور باشد.

۶ـ تشکر و قدردانی

این مقاله برگرفته از پایان‌نامه کارشناسی ارشد با عنوان «بررسی تغییرات زمانی پوشش گیاهی در حوضه آبخیز تخت–قلعه‌قاضی و آشکارسازی بیماری‌های گیاهان زراعی در دشت قلعه‌قاضی با استفاده از تصاویر ماهواره‌ای و یادگیری ماشین» است که با حمایت پارک علم و فناوری استان هرمزگان انجام شده است.

"نویسندگان از حمایت مالی پارک علم وفناوری هرمزگان از این مقاله قدردانی می‌نمایند."

حمایت شده توسط
وزارت علوم تحقیقات و فناوری
پارک علم و فناوری هرمزگان

منابع

1. Arellano, P., Tansey, K., Balzter, H., & Boyd, D. S. (2015). Detecting the effects of hydrocarbon pollution in the Amazon forest using hyperspectral satellite images. *Environmental Pollution*, 205, 225–239.
2. Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
3. Caputo, J. (2009). *Sustainable forest biomass: Promoting renewable energy and forest stewardship*. Washington, DC, USA: Environmental and Energy Study Institute.
4. FAO (Food and Agriculture Organization of the United Nations). (2002). *Land use*. https://www.fao.org
5. Galvao, L. S., Formaggio, A. R., & Tisot, D. A. (2005). Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. *Remote sensing of Environment*, 94(4), 523-534.
6. Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3), 257-266.
7. García Cárdenas, D. A., Ramón Valencia, J. A., Alzate Velásquez, D. F., & Palacios Gonzalez, J. R. (2018, November). Dynamics of the indices NDVI and GNDVI in a rice growing in its reproduction phase from multi-spectral aerial images taken by drones. In International Conference of ICT for Adapting Agriculture to Climate Change (pp. 106-119). Cham: *Springer International Publishing*.
8. Hersperger, A. M., Oliveira, E., Pagliarin, S., Palka, G., Verburg, P., Bolliger, J., & Grădinaru, S. (2018). Urban land-use change: The role of strategic spatial planning. *Global Environmental Change*, 51, 32–42.
9. Hormozgan Regional Water Company, 2022

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]

10. Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.
11. Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote sensing of environment*, 83(1-2), 195-213.
12. Joulaei, H., & Vafaeinejad, A. (2023). Application of machine learning methods for classification of Landsat 9 satellite imagery to assess urban land use area (Case study: West of Tehran). *Journal of Remote Sensing and Spatial Information Research*, 2(1), 113–126. (in Persian)
13. Kazemi, M., & Jafarpoor, A. (2024). Time series classification of land use using spectral indices, Sentinel-2 imagery, and variable training samples in Google Earth Engine (GEE). *Iranian Journal of Watershed Science and Engineering*, 18(67), 1–15. (in Persian)
14. Lawrence, R. L., Wood, S. D., & Sheley, R. L. (2006). Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (RandomForest). *Remote Sensing of Environment*, 100(3), 356-362.
15. Maitima, J. M., Mugatha, S. M., Reid, R. S., Gachimbi, L. N., Majule, A., Lyaruu, H., ... & Mugisha, S. (2009). The linkages between land use change, land degradation and biodiversity across East Africa. *African Journal of Environmental Science and Technology*, 3(10).
16. Mariye, M., Mariyo, M., Changming, Y., Teffera, Z. L., & Weldegebrial, B. (2022). Effects of land use and land cover change on soil erosion potential in Berhe district: A case study of Legedadi watershed, Ethiopia. *International Journal of River Basin Management*, 20(1), 79–91.
17. Milton, E. J. (1989). On the suitability of Kodak neutral test cards as reflectance standards. *International Journal of Remote Sensing*, 10(6), 1041-1047.
18. Rong, C., & Fu, W. (2023). A comprehensive review of land use and land cover change based on knowledge graph and bibliometric analyses. *Land use*, 12(8), 1573.
19. Sheram, K. (1993). *The environmental data book: A guide to statistics on the environment and development*. Washington, DC: The World Bank.
20. Siasar, H., Salari, A., Bahrami, M., & Hamidifar, H. (2025). Integrating remote sensing and meteorological analysis for monitoring drought conditions in arid regions: a case study from Sistan and Baluchestan province, Iran. Theoretical and Applied Climatology, 156(5), 291.
21. Sivakumar, M. V. K. (2003). Satellite remote sensing and GIS applications in agricultural meteorology. *Agricultural and Forest Meteorology*, 118(1–2), 1–5.
22. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
23. Veraverbeke, S., Gitas, I., Katagis, T., Polychronaki, A., Somers, B., & Goossens, R. (2012). Assessing post-fire vegetation recovery using red–near infrared vegetation indices: Accounting for background and vegetation variability. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, 28–39.
24. Wang, G., Han, L., Tang, X. Y., & Jin, Z. C. (2012). Temporal and spatial variation of vegetation in the Jinsha River basin. *Resources and Environment in the Yangtze Basin*, 21(10), 1191–1196.
25. Zhou, Y., Zhang, L., Fensholt, R., Wang, K., Vitkovskaya, I., & Tian, F. (2015). Climate contributions to vegetation variations in central Asian drylands: Pre- and post-USSR collapse. *Remote Sensing*, 7(3), 2449–2470.

[Downloaded from magazine.hormozgan.ac.ir on 2025-12-15]

[DOI: 10.61186/jeer.15.4.170]