

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

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 analysis in 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>

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

محمدرضا دریائی آفتابی: دانش‌آموخته کارشناسی ارشد علوم و مهندسی آبخیزداری، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی،

دانشگاه هرمزگان، بندرعباس

علیرضا نفرزادگان*: دانشیار، گروه مهندسی منابع طبیعی، دانشکده 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

تاریخچه 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-قلعه قاضی 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 SAVI از داده‌های چندزمانه ماهواره‌های لندست ۸ و ۹ 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.

۱- مقدمه

پوشش گیاهی یکی از اجزای اساسی اکوسیستم است که حدود ۷۰ درصد از سطح زمین را در بر می گیرد و نقش مهمی در چرخه های بیوژئوشیمیایی و هیدرولوژیکی ایفا می کند (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 می سازد (Sheram, 1993; Wang et al., 2012). پوشش گیاهی علاوه بر این، نقش مهمی در کنترل گازهای گلخانه ای و تعدیل تغییرات اقلیمی دارد (Caputo, 2009). از این رو، پایش دقیق پوشش گیاهی و تغییرات آن در طول زمان، یکی از شاخص های کلیدی در ارزیابی سلامت اکوسیستم ها به شمار می رود. در مطالعات محیطی، پایش وضعیت کاربری زمین و پوشش زمین که اغلب به صورت مشترک با عنوان LULC^۱ مطرح می شوند، اهمیت فراوانی دارند. کاربری زمین نشان دهنده نوع بهره برداری انسان و اکوسیستم از اراضی است، در حالی که پوشش زمین ویژگی های فیزیکی سطح زمین را توصیف می کند (Mariye et al., 2022). تغییرات کاربری و پوشش زمین، به ویژه تحت تأثیر فعالیت های انسانی مانند شهرسازی، کشاورزی و جنگل زدایی، تأثیرات قابل توجهی بر محیط زیست، تنوع زیستی و توسعه پایدار دارند (Maitima et al., 2009). با افزایش نگرانی ها درباره گسترش بی رویه مناطق شهری، کاهش اراضی کشاورزی و تخریب زیستگاه های طبیعی، دسترسی به داده های دقیق و به روز درباره کاربری زمین برای برنامه ریزی توسعه پایدار و مدیریت منابع طبیعی ضروری است (FAO, 2002). مطالعه کاربری زمین اهمیت بسزایی در درک الگوهای تغییرات محیطی، برنامه ریزی شهری، حفظ منابع طبیعی و مقابله با تغییرات اقلیمی دارد، از این رو رشد سریع شهرها، تغییرات کشاورزی، تخریب جنگل ها و گسترش زیرساخت ها ضرورت استفاده از روش های نوین مانند سنجش از دور، سیستم اطلاعات جغرافیایی (GIS)، مدل سازی و یادگیری ماشین را افزایش داده است (Hersperger et al., 2018). این فناوری ها نه تنها امکان تحلیل دقیق تغییرات کاربری زمین را فراهم می کنند، بلکه پیش بینی روندهای آتی و ارزیابی اثرات سیاست های زیست محیطی را نیز امکان پذیر می سازند. در همین راستا، داده های ماهواره ای رایگان مانند سری Landsat و Sentinel-2 شرایط مناسبی برای پایش تغییرات زمین و پوشش گیاهی در مناطق وسیع و دسترسی ناپذیر فراهم کرده اند (Rong et al., 2023). علاوه بر این، سیستم اطلاعات جغرافیایی به عنوان ابزاری قدرتمند در مدیریت، تحلیل و نمایش داده های مکانی عمل کرده و نقشی کلیدی در شناسایی الگوهای فضایی کاربری زمین ایفا می کند (European Environment Agency, 2023). از سوی دیگر، یادگیری ماشین به عنوان شاخه ای از هوش مصنوعی، با توانایی استخراج الگوها و ارائه پیش بینی های دقیق، جایگاه ویژه ای در تحلیل داده های متنوع سنجش از دور دارد (Bishop, 2006) و به کارگیری الگوریتم های یادگیری نظارت شده و نظارت نشده، موجب افزایش دقت طبقه بندی و خود کارسازی فرآیند شناسایی تغییرات کاربری زمین شده و در نهایت امکان تحلیل جامع داده های پیچیده را فراهم می آورد. در سال های اخیر، استفاده از الگوریتم های یادگیری ماشین در طبقه بندی تصاویر ماهواره ای برای تحلیل کاربری زمین، مورد توجه زیادی قرار گرفته است. به عنوان نمونه، جولایی و وفایی نژاد (۱۴۰۲) در مطالعه ای با هدف ارزیابی دقت روش های یادگیری ماشین در طبقه بندی تصاویر لندست ۹ جهت برآورد کاربری های زمین شهری در

^۱ Land Use / Land Cover

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 نظیر RF، 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-قلعه‌قازی 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.

۲- منطقه مورد مطالعه

حوضه آبخیز تخت-قلعه‌قازی به مرکزیت شهر قلعه‌قازی، یکی از دشت‌های مهم در محدوده‌ی حوضه‌های آبخیز شمال-تخت و قلعه‌قازی-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 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

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

۳- مواد و روش

این پژوهش با هدف ارزیابی تغییرات کاربری اراضی و بررسی زمانی تغییرات پوشش گیاهی در حوضه آبخیز تخت-قلعه قاضی طی بازه زمانی ۲۰۱۴ تا ۲۰۲۴ انجام شد. فرایند مطالعه در دو مرحله طراحی شد: مرحله نخست شامل تهیه نقشه‌های طبقه‌بندی شده 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.

۱-۳- 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.

۲-۳- 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 برداشت شده 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، برجسب کاربری، باندهای طیفی و مجموعه‌ای از شاخص‌های طیفی منتخب تشکیل شد.

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

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

در این پژوهش، از مجموعه‌ای از شاخص‌های طیفی به منظور بهبود دقت طبقه‌بندی کاربری اراضی و تحلیل پوشش گیاهی استفاده شد. این شاخص‌ها با هدف ارزیابی سلامت، تراکم و تنوع پوشش گیاهی، تمایز مناطق بایر و تحلیل وضعیت رطوبت خاک و گیاهان انتخاب شدند. شاخص $NDVI^1$ به عنوان پرکاربردترین شاخص برای بررسی سلامت گیاهان، از تفاوت بازتاب باند قرمز و NIR بهره می‌گیرد. EVI^2 و $SAVI^3$ نیز با اصلاح اثرات خاک و جو، تخمین دقیق‌تری از پوشش گیاهی به ویژه در مناطق خشک فراهم می‌آورند. برای تمایز اراضی بدون پوشش و مناطق بایر، از شاخص BSI^4 استفاده شد. شاخص‌های مرتبط با رطوبت نظیر $NDMI^5$ ، MSI^6 و $DSWI^7$ نیز امکان شناسایی استرس رطوبتی و وضعیت خشکی پوشش گیاهی را فراهم کردند. همچنین از شاخص نسبتاً جدید $NDVI$ سبز ($GNDVI^8$) که از باند طیفی سبز نیز استفاده می‌کند و حساسیت بالاتری نسبت به گیاهان در حال رشد داشته، به عنوان یکی از متغیرهای ورودی برای آشکارسازی دقیق‌تر مناطق کشاورزی استفاده شد. شاخص TVI^9 نیز برای تحلیل تغییرات ناشی از خشکسالی و شرایط اقلیمی در پوشش گیاهی به کار رفت. این شاخص‌ها بر پایه ترکیب باندهای مختلف طیفی از تصاویر Landsat و Sentinel-2 محاسبه شده و نقش مؤثری در افزایش تفکیک پذیری کلاس‌های کاربری زمین و پایش دقیق تغییرات پوشش گیاهی ایفا کرده‌اند. معادله و منابع علمی هریک از این شاخص‌ها 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 <i>et al.</i> , 2005	DSWI	$DSWI = \frac{(NIR - GREEN)}{(SWIR + RED)}$
۳	Huete <i>et al.</i> , 2002	EVI	$EVI = 2.5 \times \frac{(NIR - RED)}{(NIR + 6 \times RED - 7.5 \times BLUE) + 1}$
۴	García Cárdenas <i>et al.</i> , 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

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

۳-۳- طبقه‌بندی کاربری اراضی

طبقه‌بندی نهایی با بهره‌گیری از الگوریتم‌های جنگل تصادفی^۱ و ماشین بردار پشتیبان^۲ در محیط RStudio انجام گرفت. برای آموزش و ارزیابی مدل‌ها، مجموعه داده ترکیبی حاصل از تصاویر ماهواره‌ای، شاخص‌های طیفی و داده‌های میدانی به کار گرفته شد. الگوریتم‌ها به طور جداگانه آموزش داده شده و نتایج آن‌ها از نظر دقت با یکدیگر مقایسه گردیدند. تغییرات کاربری زمین مجموعاً حاکی از دگرگونی چشمگیر در نحوه استفاده از زمین در منطقه طی بازه ده‌ساله است. برای محاسبه مساحت تغییرات کاربری اراضی، از تعداد پیکسل‌های تغییر یافته در تصاویر ماهواره‌ای لندست استفاده شد. با توجه به اینکه هر پیکسل تصاویر لندست مساحتی معادل ۹۰۰ متر مربع (۳۰ متر × ۳۰ متر) را پوشش می‌دهد، ابتدا تعداد پیکسل‌های تغییر یافته در ۹۰۰ ضرب 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:

$$\text{معادله (۱)} \quad \text{مساحت (هکتار)} = (10000 \div (\text{تعداد پیکسل} \times 900))$$

۳-۴- 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 به صورت 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 به کار رفتند.

^۱ RF (Random Forest)

^۲ SVM (Support Vector Machine)

۳-۵- ارزیابی دقت طبقه‌بندی

برای ارزیابی مدل‌های طبقه‌بندی، از معیارهای ارزیابی نظیر ماتریس سردرگمی^۱، دقت کلی^۲، ضریب کاپا^۳ و سنجه‌های حساسیت و ویژگی^۴ 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)	$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$	True Positives :TP (مثبت‌های درست)
۲	دقت متوازن	$Balanced Accuracy = \frac{TPR + TNR}{2}$	True Negatives :TN (منفی‌های درست) False Positives :FP (منفی‌های نادرست) False Negatives :FN (مثبت‌های نادرست)
۳	حساسیت	$Sensitivity = \frac{TP}{TP + FN}$	True Positives Rate :TPR (نرخ حساسیت)
۴	ویژگی خاص	$Specificity = \frac{TN}{TN + FP}$	True Negatives Rate :TNR (نرخ اختصاصی)

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^۵ 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 به صورت 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^۶ در دو مرحله انجام شد. در مرحله اول، آزمون همبستگی پیرسون^۷ در محیط نرم‌افزار SPSS اجرا شد تا متغیرهای با همبستگی بالا

^۱ Confusion Matrix

^۲ Overall Accuracy

^۳ Kappa Coefficient

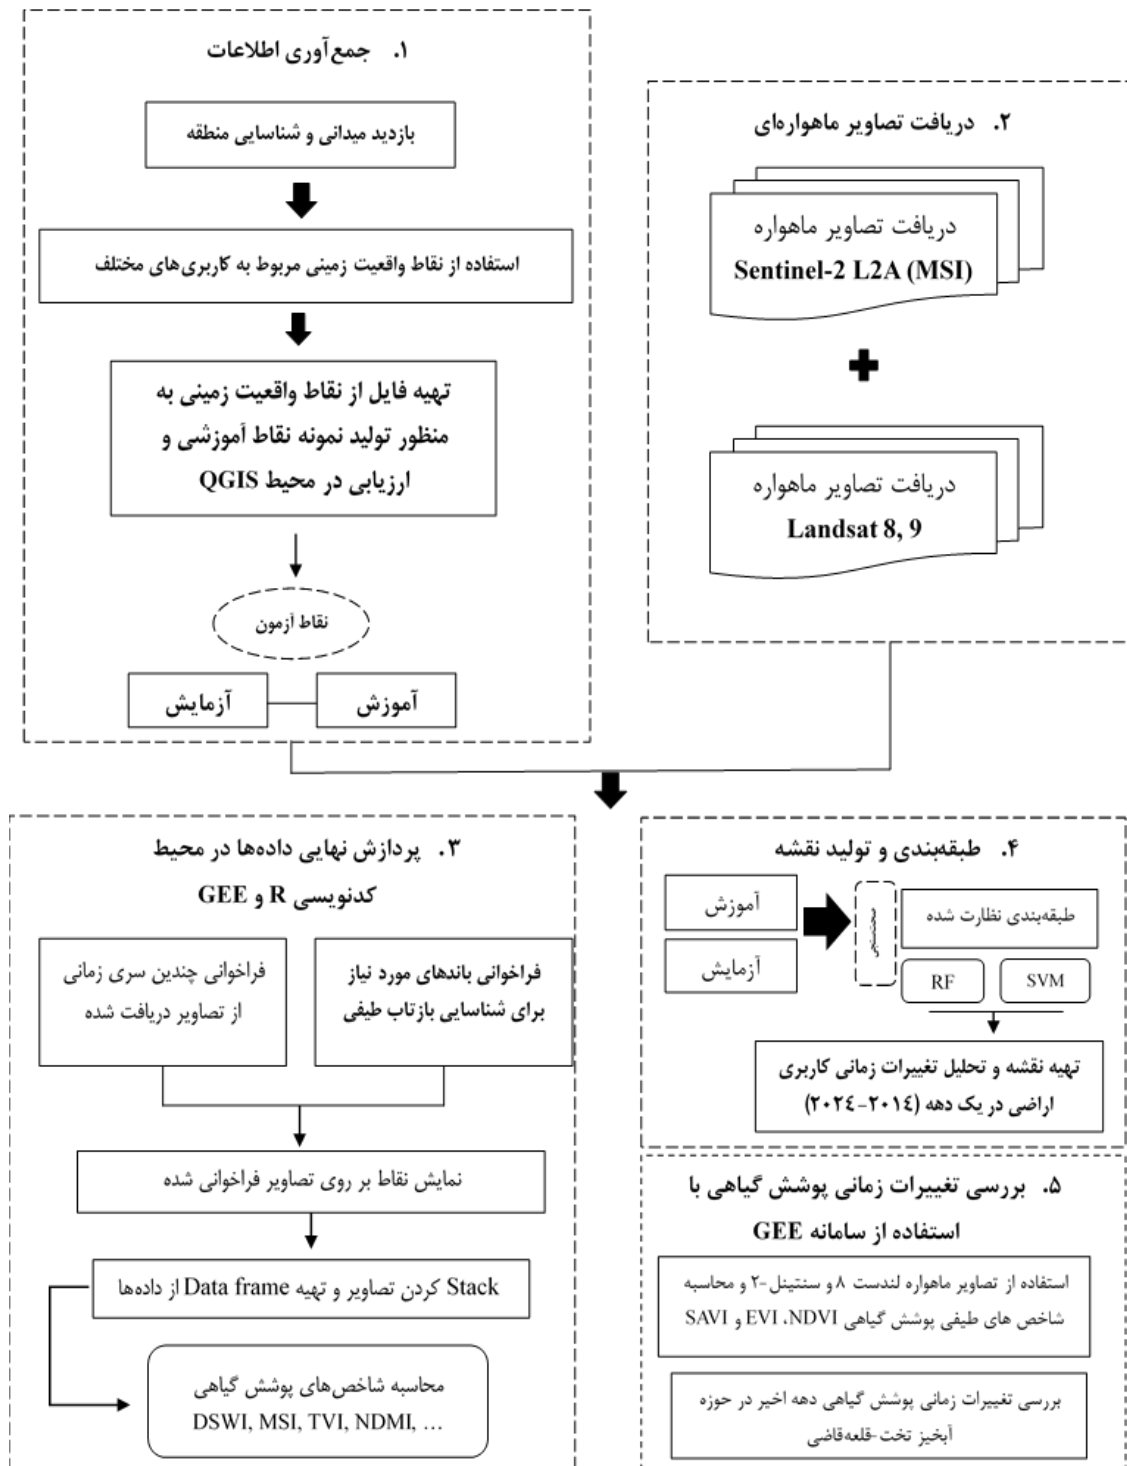
^۴ Metrics of Sensitivity and Specificity

^۵ Time Series

^۶ Feature Selection

^۷ Pearson Correlation

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



شکل ۲: نمودار جریان تحقیق

۴- نتایج

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

برای ارزیابی دقت مدل‌های یادگیری ماشین به کاررفته در طبقه‌بندی کاربری اراضی سال‌های ۲۰۱۴ و ۲۰۲۴، شاخص‌های مختلفی شامل دقت داده‌های آموزشی^۱، دقت داده‌های آزمایشی^۲، 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		ضریب کاپا
	مدل	دقت آموزش	دقت آزمایش
۲۰۱۴	SVM	۷۵	۶۶
	RF	۷۵	۶۵
۲۰۲۴	SVM	۸۲	۸۳
	RF	۸۱	۷۸

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.

^۱ Training Accuracy

^۲ Test Accuracy

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

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

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 و ساز انسانی ضعیف‌تر بود. در سال ۲۰۲۴، مدل SVM بهبود قابل توجهی 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 در نظر گرفتن دقت تشخیص صحیح برای هر کلاس به طور مجزا، شکل کامل‌تری از توانایی مدل‌ها در تفکیک کلاس‌های مختلف ارائه می‌دهد. نتایج به‌دست آمده در جدول ۶ ارائه شده است:

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 به‌دست آمده، 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 طبقه‌بندی شده 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-قلعه‌قازی

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

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 نشان‌دهنده تغییر جهت قابل توجهی 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

مجموع کمتر از ۵ درصد بوده است. 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.




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

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

به منظور 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 به صورت بصری قابل بررسی باشد.


(الف)



(ب)



(ج)



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


نمودارهای ترسیم شده برای سه شاخص NDVI، EVI و SAVI که از تصاویر ماهواره‌ای لندست ۸ استخراج شده‌اند، روند تغییرات پوشش گیاهی را در بازه زمانی ۲۰۱۴ تا ۲۰۲۴ به خوبی نمایش می‌دهند. در میان سال‌های بررسی شده، سال ۲۰۲۰ به عنوان 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 ثبت شده 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. به طور خاص، در سال ۲۰۱۵ مقادیر NDVI، EVI 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.

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


به منظور 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 به صورت بصری قابل بررسی باشد.


(الف)



(ب)



(ج)



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

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.

۵- بحث و نتیجه‌گیری

نتایج حاصل از شاخص‌های پوشش گیاهی EVI ، $NDVI$ 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 به عنوان سال اوج تراکم و سلامت پوشش گیاهی شناسایی شد؛ به گونه‌ای که مقادیر شاخص‌ها در این سال بیشترین مقدار ثبت شده 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. به طور 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.

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؛ به گونه‌ای 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) به کار 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 بومی‌سازی شده 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

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.

۶- تشکر و قدردانی

این مقاله برگرفته از پایان‌نامه کارشناسی ارشد با عنوان «بررسی تغییرات زمانی پوشش گیاهی در حوضه آبخیز تخت‌قلعه‌قازی و آشکارسازی بیماری‌های گیاهان زراعی در دشت قلعه‌قازی 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 و فناوری هرمزگان از این مقاله قدردانی می‌نمایند."



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., Verbarg, 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

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., & Jafarpour, 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.