

Monitoring and detection of land use/land cover change using machine learning algorithms on the google earth engine platform: a case study of the Karun 1 Watershed

Sina Nabizadeh¹, Ali Asghar Naghipour^{2*}, Ataollah Ebrahimi³, Hamidreza Keshtkar⁴
Elham Ghehsareh³

¹Ph.D. Student, Department of Nature Engineering, Faculty of Natural Resources and Earth Sciences, Shahrekord University, Shahrekord, Iran

² Assistant Professor, Department of Nature Engineering, Faculty of Natural Resources and Earth Sciences, Shahrekord University, Shahrekord, Iran

³ Associate Professor, Department of Nature Engineering, Faculty of Natural Resources and Earth Sciences, Shahrekord University, Shahrekord, Iran

⁴ Assistant Professor, Department of Arid and Mountainous Regions Reclamation, Faculty of Natural Resources, University of Tehran, Iran

Received: 27 August 2025

Accepted: 30 December 2025

Extended abstract

Introduction

Land use/land cover (LULC) maps are among the key tools for natural resource management, regional planning, and achieving sustainable development; therefore, the need for their accurate and up-to-date monitoring is increasingly emphasized. Continuous changes in land use driven by natural and human-induced factors have significantly affected local and global ecosystems. In recent decades, advances in remote sensing technologies and machine learning algorithms have led to major improvements in the extraction and classification of spatial data. The Google Earth Engine (GEE) platform, as a powerful cloud-based infrastructure for processing large-scale spatiotemporal data, provides an efficient framework for producing accurate and updated maps. Within this context, the present study focuses on the integration of multi-temporal satellite images, the use of auxiliary data, and the comparison of three machine learning algorithms over a large and heterogeneous watershed (Karun 1), aiming to improve classification accuracy and enhance the capability for long-term monitoring of LULC changes.

Materials and methods

To assess LULC changes in the Karun 1 watershed, Landsat 7 ETM+ (2002) and Landsat 8 OLI (2024) images with cloud cover less than 10% and considering long-term mean precipitation were retrieved and processed as surface reflectance products in the GEE platform. Composite images were generated from nine Landsat scenes during the peak growing season (May to July) using a median filter and were then clipped to the watershed boundary. A total of 1,920 training samples representing seven LULC classes based on the Anderson classification scheme were collected using field survey data, aerial photographs, and Google Earth imagery. The reference dataset was randomly split into training (60%) and evaluation (40%) subsets. Auxiliary variables (such as NDVI, NDBI, NDWI, and a DSM) were derived and included alongside original spectral bands. Classification experiments were implemented in GEE using three supervised algorithms: CART, RF, and SVM. Model hyper parameters and training procedures were configured to ensure reproducibility and consistency across methods.

Results and discussion

The results showed that the CART, RF, and SVM algorithms produced classified maps with excellent accuracy. The incorporation of vegetation indices and auxiliary data improved both the overall accuracy and the Kappa coefficient for both study years. The highest overall accuracy and Kappa coefficient were achieved by the SVM algorithm, with values of 93% and 91.5% in 2002, and 93% and 92% in 2024, respectively. According to the results of all three algorithms, rangelands constitute the largest proportion of the watershed area (on average about 40%), followed by forests (approximately 27%). The temporal analysis indicated a decreasing trend in the area of rangelands and forests, as well as a notable reduction in water bodies, particularly based on the SVM results.

* Corresponding author: aa.naghipour@sku.ac.ir


Conclusions

The results of this study demonstrated that applying machine learning algorithms within the Google Earth Engine platform enables the production of accurate land use/land cover maps and the effective monitoring of environmental changes over a large and heterogeneous watershed. The obtained results can be used as an efficient tool for land use planning, natural resource management, monitoring vegetation degradation, and controlling land use changes in the study area. However, limitations related to the spatial resolution of Landsat imagery and pixel-mixing errors, particularly along the boundaries between LULC classes, are considered among the main challenges of this study. Accordingly, it is recommended that future research utilize higher spatial resolution data, such as Sentinel imagery, to improve classification accuracy, especially for vegetation cover mapping.

Keywords: Auxiliary data, Classification and Regression Tree (CART), Random Forest (RF), Remote sensing, Support Vector Machine (SVM)

Cite this article: Nabizadeh, S., Naghipour, A.A., Ebrahimi, A., Keshtkar, H., Ghehsareh, E., 2026. Monitoring and detection of land use/land cover change using machine learning algorithms on the google earth engine platform: a case study of the Karun 1 Watershed. *Watershed. Water. Eng. Manag.*18(1), 25-44.

© 2026, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



پایش و آشکارسازی روند تغییرات کاربری/پوشش زمین با استفاده از الگوریتم‌های یادگیری ماشین در بستر گوگل ارث انجین، مطالعه موردی: حوزه آبخیز کارون ۱

سینا نبی‌زاده^۱، علی اصغر نقی‌پور^{۲*}، عطاالله ابراهیمی^۳، حمیدرضا کشتکار^۴ و الهام قهساره^۲
^۱ دانشجوی دکتری علوم و مهندسی مرتع، دانشکده منابع طبیعی و علوم زمین، دانشگاه شهرکرد، شهرکرد، ایران
^۲ استادیار گروه مهندسی طبیعت، دانشکده منابع طبیعی و علوم زمین، دانشگاه شهرکرد، شهرکرد، ایران
^۳ دانشیار گروه مهندسی طبیعت، دانشکده منابع طبیعی و علوم زمین، دانشگاه شهرکرد، شهرکرد، ایران
^۴ استادیار گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

تاریخ پذیرش: ۱۴۰۴/۱۰/۰۹

تاریخ دریافت: ۱۴۰۴/۰۶/۰۵

چکیده مبسوط

مقدمه

نقشه‌های کاربری/پوشش زمین از ابزارهای کلیدی در مدیریت منابع طبیعی، برنامه‌ریزی منطقه‌ای و دستیابی به توسعه پایدار به شمار می‌آیند و از این رو ضرورت پایش دقیق و به‌روز آنها بیش‌ازپیش احساس می‌شود. تغییرات ناشی از عوامل انسانی و طبیعی، الگوهای کاربری زمین را به‌طور مستمر دستخوش تحول کرده و پیامدهای قابل توجهی بر بوم‌سازگان‌های محلی و جهانی ایجاد کرده‌اند. در دهه‌های اخیر، پیشرفت فناوری سنجنش از دور و الگوریتم‌های یادگیری ماشین تحول مهمی در استخراج و طبقه‌بندی داده‌های مکانی ایجاد کرده است. سامانه گوگل ارث انجین (GEE) به‌عنوان بستری قدرتمند برای پردازش کلان‌داده‌های مکانی-زمانی، امکان تولید نقشه‌های دقیق و به‌روز را فراهم می‌کند. در این چارچوب، مطالعه حاضر با تمرکز بر ترکیب تصاویر چندزمانه، بهره‌گیری از داده‌های کمکی و مقایسه سه الگوریتم یادگیری ماشین در یک حوزه آبخیز وسیع و ناهمگن همچون کارون ۱، با هدف بهبود دقت طبقه‌بندی و تقویت قابلیت پایش تغییرات بلندمدت پوشش زمین انجام شده است.

مواد و روش‌ها

به‌منظور ارزیابی تغییرات کاربری و پوشش زمین در حوزه آبخیز کارون ۱، تصاویر سنجنده‌های ETM⁺ لندست ۷ (سال ۲۰۰۲) و OLI لندست ۸ (سال ۲۰۲۴) با پوشش ابری کمتر از ۱۰ درصد و با لحاظ میانگین بارندگی بلندمدت، از طریق GEE و در قالب داده‌های بازتاب سطحی تصحیح‌شده مورد استفاده قرار گرفت. تصاویر ترکیبی حاصل از نه صحنه تصویری لندست طی دوره اوج رشد پوشش گیاهی (اردیبهشت تا تیر ماه) با فیلتر میانه تهیه و سپس مطابق مرز حوضه برش داده شدند. در ادامه، تعداد ۱۹۲۰ نقطه آموزشی در قالب هفت کلاس کاربری/پوشش زمین مطابق طبقه‌بندی آندرسون و بر پایه داده‌های میدانی، تصاویر هوایی و گوگل ارث برداشت شد. این داده‌ها به‌صورت تصادفی به دو مجموعه آموزش (۶۰ درصد) و ارزیابی (۴۰ درصد) تقسیم شدند. متغیرهای کمکی (مانند NDVI، NDBI، NDWI و DSM) استخراج و در کنار باندهای طیفی اصلی گنجانده شدند. آزمایش‌های طبقه‌بندی در GEE با استفاده از سه الگوریتم

* مسئول مکاتبات: aa.naghipour@sku.ac.ir

نظارت شده CART، RF و SVM اجرا شدند. پارامترهای مدل و رویه‌های آموزشی برای اطمینان از تکرارپذیری و سازگاری در بین روش‌ها پیکربندی شدند.

نتایج و بحث

نتایج نشان داد که الگوریتم‌های CART، RF و SVM نقشه‌های طبقه‌بندی را با دقت عالی تولید کردند و بهره‌گیری از شاخص‌های پوشش گیاهی و داده‌های کمکی، دقت کلی و ضریب کاپای طبقه‌بندی را در هر دو سال افزایش داد. بیشینه دقت کلی و کاپا مربوط به الگوریتم SVM بود که در سال ۲۰۰۲ به ترتیب ۹۳ و ۹۱/۵ درصد و در سال ۲۰۲۴ برابر ۹۳ و ۹۲ درصد به دست آمد. همچنین بر اساس نتایج هر سه الگوریتم، بخش عمده‌ای از مساحت حوضه (به طور متوسط ۴۰ درصد) از مراتع و حدود ۲۷ درصد از جنگل تشکیل شده است. روند زمانی نتایج نیز نشان‌دهنده کاهش مساحت مراتع و جنگل‌ها و به‌ویژه کاهش پهنه‌های آبی بر اساس الگوریتم SVM است.

نتیجه‌گیری

نتایج این پژوهش نشان داد که به‌کارگیری الگوریتم‌های یادگیری ماشین در بستر گوگل ارث انجین امکان تولید نقشه‌های دقیق کاربری/پوشش زمین و پایش مؤثر تغییرات محیطی را در یک حوزه آبخیز وسیع و ناهمگن فراهم می‌سازد. نتایج حاصل می‌تواند به‌عنوان ابزاری کارآمد در برنامه‌ریزی کاربری اراضی، مدیریت منابع طبیعی، پایش تخریب پوشش گیاهی و کنترل تغییرات کاربری در منطقه مورد استفاده قرار گیرد. با این حال، محدودیت‌های ناشی از وضوح مکانی تصاویر لندست و خطاهای اختلاط پیکسلی به‌ویژه در مرز بین طبقات کاربری/پوشش زمین از جمله چالش‌های این مطالعه محسوب می‌شوند. بر این اساس، پیشنهاد می‌شود در پژوهش‌های آتی از داده‌های با قدرت تفکیک مکانی بالاتر مانند تصاویر سنتینل برای بهبود دقت طبقه‌بندی به‌ویژه در پوشش‌های گیاهی بهره گرفته شود.

واژگان کلیدی: جنگل تصادفی (RF)، داده‌های کمکی، درخت طبقه‌بندی و رگرسیون (CART)، سنجش از دور، ماشین بردار پشتیبان (SVM)

مقدمه

کره زمین از تأثیر فعالیت‌های انسانی مصون مانده‌اند (Khan et al., 2016). بین سال‌های ۱۹۶۰ تا ۲۰۱۹، حدود ۱۷ درصد از سطح خشکی‌های زمین دستخوش تغییر کاربری شده‌اند؛ که به وضوح تأثیرات عمیق فعالیت‌های انسانی را بر بوم‌سازگان‌های طبیعی نشان می‌دهد (Winkler et al., 2021).

رشد بی‌وقفه جمعیت جهانی (از ۲/۵ میلیارد نفر در سال ۱۹۵۰ به ۸ میلیارد نفر در سال ۲۰۲۲ و پیش‌بینی ۱۰/۴ میلیارد نفر تا سال ۲۱۰۰)، توسعه سریع شهرنشینی، صنعتی شدن و افزایش فعالیت‌های اقتصادی-اجتماعی، از عوامل اصلی شتاب تغییرات کاربری/پوشش زمین به شمار می‌روند (Lambin and United Nations Department of Meyfroidt, 2011 Roy et al., Economic and Social Affairs, 2022). علیرغم پیامدهای گسترده این تغییرات در

نقشه‌های کاربری/پوشش زمین^۱ از مهم‌ترین ابزارها برای مدیریت محیط‌زیست، برنامه‌ریزی منطقه‌ای و دستیابی به توسعه پایدار به شمار می‌روند (Patino and Duque, 2013؛ Liu et al., 2017). این نقشه‌ها اطلاعات ارزشمندی در خصوص ویژگی‌های طبیعی و همچنین ساخت‌وسازهای انسانی نظیر مراتع، جنگل‌ها، پهنه‌های آبی، فضاهای ساخته‌شده و اراضی کشاورزی ارائه می‌دهند (Nedd et al., 2021).

ماهیت پویا و تغییرپذیر کاربری/پوشش زمین که عمدتاً ناشی از فعالیت‌های انسانی یا فرایندهای طبیعی است، بر ضرورت پایش مستمر و به‌روزرسانی سریع این داده‌ها تأکید دارد (Amin and Fazal, 2012). بر اساس مطالعات انجام‌شده، تنها بخش‌های محدودی از سطح

¹ Land Use / Land Cover (LULC)

و عملکرد بالایشان، در طیف وسیعی از مطالعات علوم زمین به کار گرفته شده‌اند (Pandey et al., 2021). مطالعه‌ای در شمال غربی ایران با استفاده از تصاویر Landsat، الگوریتم‌های CART، SVM و RF را برای تهیه نقشه‌های کاربری/پوشش زمین در محیط GEE با یکدیگر مقایسه کرد؛ که در این میان الگوریتم SVM بالاترین عملکرد از نظر دقت را داشت (Feizizadeh et al., 2023).

پژوهش دیگری در منطقه مردان پاکستان گزارش داد که الگوریتم RF عملکرد بهتری نسبت به الگوریتم‌های SVM و CART دارد (Zhao et al., 2024). محققان در حوضه مونرو کشور هند این سه الگوریتم را با استفاده از تصاویر ماهواره‌ای چند زمانی Sentinel-2 و Landsat-8 بررسی کردند. نتایج نشان داد که الگوریتم RF بالاترین دقت در طبقه‌بندی تصاویر مورد استفاده در سامانه GEE را دارد (Loukika et al., 2021). در یک مطالعه مروری-فراتحلیلی، عملکرد الگوریتم‌های RF و SVM در طبقه‌بندی تصاویر سنجش‌ازدور بر اساس تحلیل ۲۵۱ مقاله علمی معتبر بررسی شده است. نتایج این مطالعه نشان داد که برتری عملکرد SVM و RF به صورت یکنواخت قابل تعمیم نیست و کارایی هر یک از این الگوریتم‌ها به عواملی نظیر نوع داده‌های سنجش‌ازدور، حوزه کاربرد، قدرت تفکیک مکانی، تعداد ویژگی‌های استخراج شده و شرایط پیاده‌سازی مدل وابسته است؛ به طوری که هر یک می‌توانند بسته به شرایط، نتایج دقیق‌تری نسبت به دیگری ارائه دهند (Sheykhoumou et al., 2020).

همچنین، بهره‌گیری و بررسی داده‌های کمکی همچون شاخص‌های پوشش گیاهی (مانند NDVI)، داده‌های ارتفاعی (مانند DEM) و پروداکت‌های موجود در GEE می‌تواند به افزایش دقت طبقه‌بندی تصاویر ماهواره‌ای توسط الگوریتم‌ها کمک کنند (Aghababaei et al., 2021). با این حال، با وجود نوآوری‌های GEE و الگوریتم‌های یادگیری ماشین و تحولات عظیمی که در سنجش از دور ایجاد کرده‌اند، کاربرد و مقایسه جامع روش‌های یادگیری ماشین برای طبقه‌بندی تصاویر

سطوح محلی، منطقه‌ای و جهانی، پیگیری توسعه اقتصادی و اجتماعی برای پاسخ‌گویی نیازهای جمعیت در حال رشد، اجتناب‌ناپذیر است. از این رو، نیاز به مطالعات پایش و تهیه نقشه‌های تغییر کاربری/پوشش زمین برای ارزیابی بهتر محیط زیست و تضمین استفاده عاقلانه و پایدار از منابع طبیعی، بیش از پیش ضروری شده است (Armenteras et al., 2019).

در این میان، فناوری سنجش از دور^۱ به عنوان ابزاری کارآمد و موثر برای نقشه‌برداری، پایش و آشکارسازی تغییرات کاربری/پوشش زمین مورد توجه قرار گرفته است (Inglada et al., 2017). بررسی پیشینه پژوهش نشان می‌دهد که نقشه‌برداری کاربری/پوشش زمین همواره یکی از کاربردهای اصلی سنجش از دور بوده است. با این حال، تهیه، طبقه‌بندی و نقشه‌برداری آن با استفاده از تصاویر ماهواره‌ای به ظرفیت محاسباتی قابل توجهی نیاز دارد. برای غلبه بر این محدودیت‌ها و بهره‌برداری از حجم زیاد داده‌های مکانی و زمانی، توسعه یک زیرساخت با عملکرد بالا که بتواند جمع‌آوری، مدیریت، به اشتراک‌گذاری، تحلیل، بصری‌سازی و انتشار داده‌های بزرگ مکانی و زمانی را از طریق یک شبکه پرسرعت پشتیبانی کند، ضروری است (He and Yue, 2015). در این راستا، GEE^۲ به عنوان سامانه ابری و پیشگام، قابلیت‌های بی‌نظیری را برای پایش و مدل‌سازی کاربری‌های زمین در مقیاس وسیع فراهم آورده است (Zhang et al., 2020).

GEE با دسترسی رایگان به مجموعه داده‌های متنوع و ابزارهای تحلیلی مختلف به عنوان یک سامانه قدرتمند این فرایند را برای کاربران تسهیل می‌کند. همزمان با توسعه این سامانه‌ها، پیشرفت الگوریتم‌های یادگیری ماشین^۳ موجب تحول در حوزه طبقه‌بندی و مدل‌سازی کاربری زمین شده است (Rwanga and Ndambuki, 2017). GEE نیز از اجرای چندین الگوریتم یادگیری ماشین پشتیبانی می‌کند که از میان آنها، الگوریتم‌های ماشین بردار پشتیبان^۴، جنگل تصادفی^۵ و درخت طبقه‌بندی و رگرسیون^۶، به دلیل انعطاف‌پذیری، توانایی پردازش داده‌های پیچیده، دقت

^۴ Support Vector Machine (SVM)

^۵ Random Forest (RF)

^۶ Classification and Regression Tree (CART)

^۱ Remote Sensing (RS)

^۲ Google Earth Engine (GEE)

^۳ Machine Learning

بایوفیزیکی و داده‌های سنجش‌ازدور، شدت بیشتر تخریب جنگل‌ها در مناطق کوهستانی و تبدیل آنها به اراضی کشاورزی و شهری را تأیید می‌کنند (Torahi and Rai., 2013).

بر این اساس، هدف این پژوهش، مقایسه عملکرد الگوریتم‌های ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF) و درخت طبقه‌بندی و رگرسیون (CART) به همراه بهره‌گیری هم‌زمان از داده‌های کمکی، در طبقه‌بندی، پایش و آشکارسازی تغییرات کاربری/پوشش زمین در یک حوزه آبخیز وسیع و ناهمگن به نام کارون ۱ در زاگرس مرکزی است. در این مطالعه، با اتکا بر تصاویر چندزمانی ماهواره‌ای و پیاده‌سازی مدل‌ها در بستر پردازش ابری GEE، امکان تحلیل یکپارچه و دقیق تغییرات بلندمدت پوشش زمین در مقیاسی فراهم شده است که پیش‌تر به صورت جامع مورد بررسی قرار نگرفته بود. رویکرد اتخاذشده می‌تواند چارچوبی کارآمد برای ارتقای پایش محیط‌زیست و مدیریت منابع طبیعی در مناطق خشک و نیمه‌خشک ارائه دهد.

مواد و روش‌ها

منطقه مورد مطالعه: حوزه آبخیز کارون ۱ با مساحتی بالغ بر ۲۷۰۷۲ کیلومتر مربع (تا محل سد شهید عباسپور) یکی از زیرحوضه‌های بزرگ آبریز خلیج فارس به شمار می‌آید. این حوزه در منطقه کوهستانی زاگرس مرکزی واقع شده و به‌عنوان یک بوم‌سازگان راهبردی، نقش حیاتی در تأمین خدمات ایفا می‌کند. این منطقه، سرچشمه رودخانه‌های مهمی همچون کارون بوده و با تغذیه آبخوان‌ها و تولید بارش، امنیت آبی بخش وسیعی از ایران را تضمین می‌نماید.

همچنین، این حوزه با دارا بودن جنگل‌های ارزشمند بلوط و تنوع زیستی بالا، خدمات محیط‌زیستی مهمی مانند تثبیت خاک، کنترل فرسایش و تولید اکسیژن را فراهم می‌سازد. این حوزه با تأمین آب پایدار برای تولید برق آبی و تأمین آب شرب و آبیاری کشاورزی در دشت خوزستان، از اهمیت استراتژیک ملی برخوردار است. پایداری این حوزه مستقیماً بر عملکرد سدها و کیفیت منابع آبی تأثیرگذار است و از این رو حفظ آن برای توسعه پایدار جنوب و مرکز ایران حیاتی است

ماهواره‌ای همراه با شاخص‌ها و داده‌های کمکی به صورت جامع بررسی نشده است.

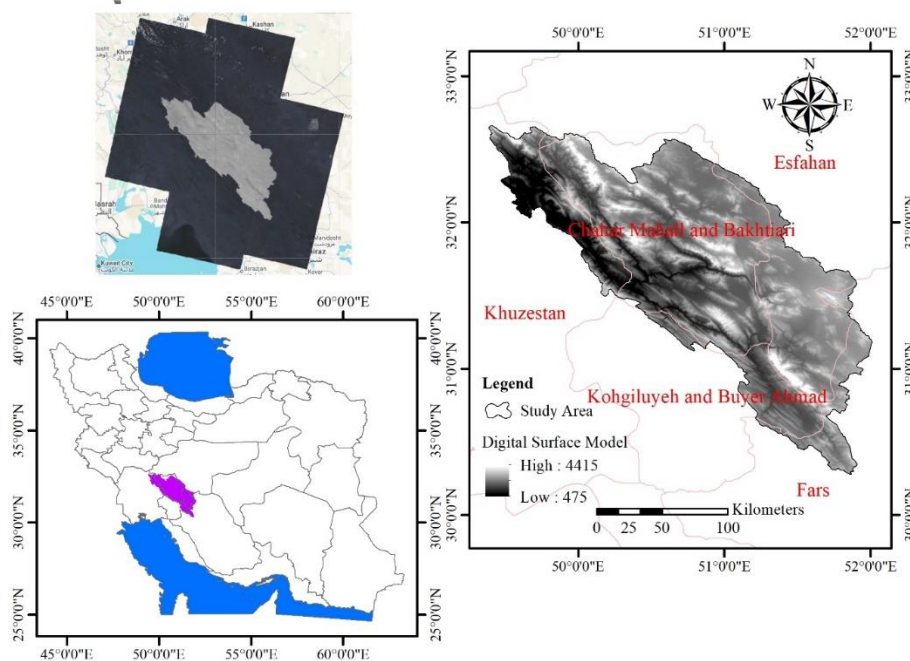
حوزه آبخیز کارون ۱، به‌عنوان یکی از راهبردی‌ترین حوضه‌های کشور، نقشی اساسی در تأمین آب شرب، کشاورزی و تولید برق آبی در جنوب و مرکز ایران ایفا می‌کند. این منطقه که در قلب زاگرس مرکزی واقع شده، علاوه بر دارا بودن جنگل‌های ارزشمند و مراتع گسترده، منبع تغذیه اصلی رودخانه کارون به شمار می‌آید. با این حال، عوامل متعددی نظیر تغییرات اقلیمی، طرح‌های انتقال بین‌حوضه‌ای آب، توسعه اراضی کشاورزی و افزایش بهره‌برداری انسانی، پوشش طبیعی این حوزه را در معرض تهدید قرار داده‌اند (Rahimi et al., 2025).

بررسی دقیق و علمی روند تغییرات کاربری/پوشش زمین در این منطقه، از یک سو به شناسایی مناطق بحرانی و حساس کمک می‌کند و از سوی دیگر، ابزار لازم را برای برنامه‌ریزی پایدار منابع طبیعی و کنترل تخریب محیط‌زیستی فراهم می‌آورد. به همین دلیل، انجام مطالعات پیشرفته با بهره‌گیری از فناوری‌های نوین سنجش‌از دور و یادگیری ماشین در این منطقه از اولویت‌های محیط‌زیستی و ملی محسوب می‌شود. مطالعات در زاگرس مرکزی و حوضه کارون طی سال‌های اخیر نشان‌دهنده تغییرات چشمگیر در کاربری و پوشش زمین است. بررسی تصاویر لندست در استان لرستان طی سال‌های ۱۹۸۹ تا ۲۰۱۳ حاکی از تخریب شدید جنگل‌ها در این استان بوده و بر اساس نتایج مدل‌سازی، روند کاهش آنها تا سال ۲۰۵۰ نیز تداوم خواهد داشت (Japelaghi et al., 2022).

در حوضه کارون بزرگ، مدل‌سازی تغییرات کاربری با استفاده از زنجیره مارکوف و اتوماتای سلولی نشان داد که رشد جمعیت و شهرنشینی موجب تشدید بیابان‌زایی و کاهش منابع آب شده است (Minaei et al., 2025). در یکی از زیرحوضه‌های کارون ۱ نیز نتایج مدل LCM و تصاویر لندست طی سال‌های ۱۹۸۶، ۲۰۰۹ و ۲۰۱۷ نشان داد که اراضی مرتعی ۴۳۷۹ هکتار کاهش و اراضی کشاورزی ۱۹۲۲ هکتار افزایش یافته‌اند و پیش‌بینی‌ها برای سال ۱۴۰۶ نیز بیانگر تداوم این روند است (Nabizadeh et al., 2019). همچنین مطالعات منطقه زاگرس با استفاده از مدل‌های

پایین‌دست این حوزه، سد شهید عباسپور با ظرفیت مخزن حدود ۳/۷ میلیارد مترمکعب واقع شده است. علاوه بر آن، سه سد دیگر نیز در بالادست این سد احداث شده‌اند (شکل ۱).

(Rahimi et al., 2025). از منظر جغرافیایی، این حوزه در محدوده عرض‌های شمالی $34^{\circ}16'30''$ تا $33^{\circ}01'11''$ و طول‌های شرقی $56^{\circ}22'56''$ تا $59^{\circ}49'00''$ قرار گرفته است. در بخش



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه به همراه جزئیات سطحی

Fig. 1. Geographical Location of the Study Area with Surface Details

زیر ۱۰ درصد فراخوانی شده و مورد پردازش قرار گرفتند.

GEE، تصاویر تصحیح شده به صورت بازتاب سطحی^۱ را در اختیار کاربران قرار می‌دهد و دیگر نیازی به تصحیحات اتمسفری نیست. این امر سبب بهبود ویژگی‌های تصویر و تشخیص بهتر عوارض و تغییرات در آنها می‌شود (Wahap and Shafri, 2020). با توجه به تنوع و پیچیدگی پوشش اراضی در حوزه آبخیز کارون ۱ تصاویر مربوط به بازه زمانی اردیبهشت تا تیرماه (می تا جولای)، یعنی فصل اوج رشد پوشش گیاهی، مورد استفاده قرار گرفت. این منطقه توسط نه صحنه تصویری لندست پوشش داده می‌شود و برای هر سال، با استفاده از فیلتر میانه^۲، تصاویر به یک تصویر ترکیبی تبدیل (Kollert et al., 2021) و بر اساس مرز حوزه مورد مطالعه برش داده شدند (شکل ۲).

داده‌های مورد استفاده: ماهواره‌های سری لندست به دلیل پوشش جهانی، آرشو بلندمدت، دسترسی آزاد به داده‌ها و وضوح مکانی مناسب (۳۰ متر)، از سال ۱۹۷۴ تاکنون به‌عنوان منبعی مطمئن برای مطالعات کاربری/پوشش زمین مورد استفاده قرار گرفته‌اند (Wahap and Shafri, 2020). برای تهیه نقشه‌های کاربری/پوشش زمین و بررسی تغییرات آن، تصاویر سنجنده ETM⁺ ماهواره لندست ۷ برای سال ۲۰۰۲ و سنجنده OLI لندست ۸ مربوط به سال ۲۰۲۴ با توجه به میزان بارندگی هر سال متناسب با میانگین بارندگی بلند مدت حوزه آبخیز کارون ۱ انتخاب شد (جدول ۱). از باندهای طیفی خام (۱ تا ۷) ($2/35 \mu\text{m}$ تا $0/45 \mu\text{m}$) ماهواره لندست ۷ و از باندهای طیفی خام (۲ تا ۷ و ۱۰) ($2/294 \mu\text{m}$ تا $0/453 \mu\text{m}$) ماهواره لندست ۸ جهت طبقه‌بندی تصاویر سال‌های مورد مطالعه استفاده شد. تصاویر مورد نظر در محیط GEE، با توجه به پوشش ابر

² Median

¹ Surface reflectance

جدول ۱- مشخصات تصاویر ماهواره‌ای مورد استفاده در مطالعه

Table 1. Characteristics of satellite images used in the study

| Satellite | Sensor | Acquisition date | Row | Path | Band | Resolution (m) |
|-----------|------------------|----------------------|----------|------------|-----------------|----------------|
| Landsat 7 | ETM ⁺ | 2002-5-1 to 2002-7-1 | 37 to 39 | 163 to 165 | (1 to 7) | 30 |
| Landsat 8 | OLI/TIRS | 2024-5-1 to 2024-7-1 | 37 to 39 | 163 to 165 | (2 to 7 and 10) | 30 |

به منظور آشکارسازی و نمایش بارزتر مناطق شهری از خاک‌های بایر و لخت از شاخص NDBI^۴ استفاده شد. این شاخص با تحلیل بازتاب طیفی در محدوده مادون قرمز طول موج کوتاه (SWIR) در مقایسه با محدوده NIR بر اساس رابطه (۳) محاسبه می‌شود و تا حدودی کمک به تفکیک این مناطق می‌کند (Zha et al., 2003).

$$NDBI = \frac{SWIR-NIR}{SWIR+NIR} \quad (۳)$$

شاخص NDWI^۵ با هدف مشخص شدن هرچه بهتر پهنه‌های آبی بر مبنای بیشینه مقدار جذب آب و بیشینه مقدار بازتاب برای پوشش گیاهی در باند مادون قرمز نزدیک بر اساس رابطه (۴) استخراج شد (McFeeters, 1996). در رابطه زیر Green باند سبز است. مقادیر بالا این شاخص حاکی از وجود پهنه‌های آبی است.

$$NDWI = \frac{GREEN-NIR}{GREEN+NIR} \quad (۴)$$

در نهایت داده‌های ماهواره‌ای به فرمت GeoTIFF در یک ترکیب ۱۲ باندی ۳۰m طیفی برای هر سال، جهت تهیه و بالا بردن دقت نقشه‌های کاربری/پوشش زمین تولید شده در سامانه GEE مورد استفاده قرار گرفتند (شکل ۲).

داده‌های آموزشی: پس از فراخوانی تصاویر ماهواره لندست و ایجاد مجموعه ترکیبی با داده‌های کمکی، اقدام به برداشت نقاط آموزشی شد. این مرحله، یکی از مراحل کلیدی در طبقه‌بندی دقیق نقشه‌های کاربری/پوشش زمین محسوب شده و نیازمند داده‌های معتبر و کافی است (Feizizadeh and Kienberger, 2017).

در این مطالعه، ۱۹۲۰ نقطه آموزشی در هفت طبقه کاربری/پوشش زمین شامل پهنه‌های آبی، پوشش یخ و برف، اراضی بدون پوشش، اراضی کشاورزی، جنگل،

ویژگی‌های استخراج شده و شاخص‌ها: به منظور

غنی‌سازی مجموعه ویژگی‌های ورودی برای الگوریتم‌های طبقه‌بندی و بهبود تفکیک‌پذیری طبقه‌های کاربری/پوشش زمین، از مدل رقومی ارتفاع جهانی^۱ ماهواره ALOS World 3D با قدرت تفکیک مکانی ۳۰ متر در سال ۲۰۱۱ استفاده شد (Santillan et al., 2016). توپوگرافی زمین تأثیر قابل توجهی بر توزیع و ویژگی‌های پوشش گیاهی، الگوهای جریان آب و کاربری‌های انسانی دارد. بنابراین، گنجاندن اطلاعات ارتفاعی می‌تواند به طور چشمگیری دقت طبقه‌بندی تصاویر ماهواره‌ای را افزایش دهد (Tadono et al., 2014).

در ادامه از شاخص^۲ که به‌عنوان یک ویژگی قدرتمند در سنجش از دور، با کمی‌سازی سلامت و تراکم پوشش گیاهی از طریق تحلیل بازتاب طیفی در باندهای قرمز (RED) و مادون قرمز نزدیک (NIR)، امکان پایش دقیق تغییرات پوشش گیاهی و تفکیک بهینه‌تر انواع پوشش گیاهی را فراهم می‌آورد (Kriegler et al., 1969)، استفاده شد. این شاخص از رابطه (۱) محاسبه می‌شود.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (۱)$$

همچنین شاخص RVI^۳ یکی دیگر از شاخص‌های پوشش گیاهی می‌باشد که با استفاده از تحلیل بازتاب طیفی فوق بر اساس رابطه (۲) استفاده شد (Jordan, 1969). مقدار بالای این شاخص نشان‌دهنده تراکم بیشتر پوشش گیاهی و فعالیت فتوسنتزی بالاتر است، در حالی که مقادیر پایین آن معمولاً به خاک‌های بایر، مناطق خشک یا پوشش گیاهی ضعیف اشاره دارد.

$$Ratio = \frac{NIR}{RED} \quad (۲)$$

³ Ratio Vegetation Index (RVI)

⁴ Normalized Difference Built-Up index

⁵ Normalized Difference Water Index

¹ Digital Surface Model (DSM)

² Normalized Difference Vegetation Index (NDVI)

الگوریتم در طول فرایند طبقه‌بندی، یک درخت تصمیم‌گیری بزرگ شکل داده و در یک نمایش سلسله‌مراتبی با استفاده از ویژگی (باندطیفی)، آستانه تخمین زده شده (طبقه) را نمایش دهد.

درخت تصمیم با توجه به آستانه تصمیم‌گیری، گره‌هایی را تشکیل می‌دهد؛ سپس داده‌های ورودی را بر اساس یک ویژگی به دو زیر گره تقسیم می‌کند. این فرایند تا زمانی که همه گره‌ها خالص (یعنی نشان دهنده یک طبقه) و دیگر هیچ تقسیم قابل بهبودی وجود نداشته باشد، ادامه می‌یابد. این الگوریتم به شدت به اندازه نمونه استفاده شده در هر طبقه وابسته است. عملکرد الگوریتم CART در داده‌های با ابعاد بالا که منجر به ایجاد ساختارهای درختی پیچیده می‌شوند، مختل می‌شود (Loukika et al., 2021).

ماشین بردار پشتیبان (SVM): این الگوریتم یکی از روش‌های اصلی یادگیری ماشین است که در سال ۱۹۹۵ توسط Vapnik معرفی شد. این الگوریتم بر اساس تئوری یادگیری آماری ناپارامتریک برای غلبه بر مشکلات پیچیده مرتبط با طبقه‌بندی و رگرسیون توسعه داده شد (Ballabio and Sterlacchini, 2012). الگوریتم SVM بر اساس اصل حداقل‌سازی ریسک ساختاری علاوه بر کاهش خطاهای آموزشی، به کنترل پیچیدگی مدل و جلوگیری از بیش‌برازش می‌پردازد.

وظیفه اصلی این الگوریتم ایجاد یک ابر صفحه‌ای فرا سطحی است که داده‌ها را به بهترین شکل ممکن از هم جدا و طبقه‌بندی کند. برای این منظور، الگوریتم SVM حداکثر حاشیه (فاصله) جداسازی بین طبقات را پیدا می‌کند و یک ابر صفحه طبقه‌بندی در مرکز حداکثر حاشیه می‌سازد. یعنی با استفاده از داده‌های آموزشی و روش‌های بهینه‌سازی (صفحه‌ای که داده‌ها را با بیشینه فاصله از هم جدا کند)، بردارهای پشتیبان را تشکیل می‌دهد. سپس با استفاده از بردارهای پشتیبان مرز تصمیم‌گیری مشخص شده و ابر صفحه‌ای فرا سطحی اقدام به جداسازی طبقات می‌کند (Kamran et al., 2021).

شاخص‌های اصلی برای انتخاب بردارهای پشتیبان شامل ضریب هزینه، ضریب گاما و توابع هسته هستند (Hsu et al., 2003). برای دستیابی به نتایج پیش‌بینی

مرتفع و اراضی مسکونی و صنعتی (بر اساس تقسیم‌بندی آندرسون^۱ که در سال ۱۹۷۶ توسط موسسه زمین‌شناسی آمریکا انجام شد) در حوزه آبخیز کارون ۱ در سال‌های ۲۰۰۲ و ۲۰۲۴ جمع‌آوری شد.

مجموعه داده‌های عملیات میدانی همراه با عکس‌های هوایی و تصاویر گوگل ارث برای جمع‌آوری و کمک به انتخاب نقاط آموزشی مورد نیاز در سامانه GEE استفاده شد. نقاط آموزشی به‌طور یکنواخت در سراسر منطقه مورد مطالعه به صورتی که هر نقطه آموزشی نماینده صحیح و خالص هر کاربری در سال‌های ۲۰۰۲ و ۲۰۲۴ باشد، برداشت شد. سپس، ۶۰ درصد داده‌ها برای آموزش مدل‌ها و ۴۰ درصد برای ارزیابی دقت به‌صورت تصادفی تخصیص یافت.

روش طبقه‌بندی: طبقه‌بندی تصاویر ماهواره‌ای فرایندی دشوار و بسیار پیچیده است. برای طبقه‌بندی تصاویر در سامانه GEE الگوریتم‌های متعددی به‌صورت توابع آماده در دسترس هستند. انتخاب الگوریتم مناسب برای طبقه‌بندی تصاویر یکی از اصلی‌ترین مراحل در تهیه نقشه‌های کاربری/پوشش زمین است. الگوریتم‌های نظارت شده درخت طبقه‌بندی و رگرسیون (CART)، ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) به علت ترکیب روش‌های مکانی و زمانی برای تحلیل کاربری/پوشش زمین و توانایی آنها برای طبقه‌بندی و پیش‌بینی دقیق طبقه‌های کاربری، تشخیص تغییرات در طول زمان، ارائه بینش‌های ارزشمند جهت مدیریت اراضی، پایش محیط زیست و برنامه‌ریزی شهری مورد توجه پژوهشگران هستند (Pandey et al., 2021). در ادامه به توضیح این روش‌ها پرداخته می‌شود.

درخت طبقه‌بندی و رگرسیون (CART): این الگوریتم یکی از ساده‌ترین و در عین حال قدرتمندترین الگوریتم‌ها در یادگیری ماشین محسوب می‌شود که در سال ۱۹۸۴ توسط Brieman توسعه داده شد. این الگوریتم جزو روش‌های طبقه‌بندی نظارت شده^۲ است که از یک الگوی آماری ناپارامتریک پیروی می‌کند. این الگوریتم بر اساس درخت تصمیم‌گیری دودویی عمل می‌کند؛ یعنی با معرفی نمونه‌های آموزشی به این

² Supervised Machine

¹ Anderson

قطر اصلی قرار می‌گیرند و عناصر غیر قطری، مجموعه خطاها هستند.

تعداد سطر و ستون این ماتریس مربعی با تعداد طبقه‌ها برابر است. سامانه GEE بر اساس ماتریس خطا، دقت کلی^۱ (رابطه ۵) و ضریب کاپا^۲ (K) را محاسبه (رابطه ۶) و به صورت عددی گزارش می‌دهد. در صورتی که مقادیر ضریب کاپا کمتر از ۴۰ درصد باشد نشان‌دهنده توانایی ضعیف مدل در برآورد، مقادیر ۶۰-۴۰ درصد نشان‌دهنده یک برآورد متوسط، مقادیر ۸۰-۶۰ درصد نمایانگر یک برآورد خوب، و مقادیر بالای ۸۰ درصد نشان‌دهنده توانایی برآورد عالی مدل است (Wu et al., 2024).

$$OA = \left(\frac{P_c}{P_n} \right) * 100 \quad (5)$$

Pc تعداد پیکسل‌هایی که به درستی طبقه‌بندی شده‌اند و Pn تعداد کل پیکسل‌ها است.

$$K = N + \sum_{i=1}^r x_{ii} - \frac{\sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (6)$$

N تعداد کل مشاهدات، r تعداد سطرها و ستون‌ها در ماتریس خطا، x_{ii} تعداد پیکسل‌های درست طبقه‌بندی شده در کلاس اول، مجموع پیکسل‌های در سطر طبقه اول و x_{+i} مجموع پیکسل‌های در ستون طبقه اول است. سپس از نسبت پیکسل‌های درست طبقه‌بندی شده (x_{ii}) در هر کلاس به تعداد کل پیکسل‌های طبقه‌بندی شده (x_{+i})، دقت کاربر^۳ برای هر طبقه تعیین می‌شود.

دقت کاربر احتمال اینکه یک نقطه در روی نقشه به درستی در طبقه مربوط به خود طبقه‌بندی شده باشد، اشاره دارد. به‌طور مشابه از نسبت پیکسل‌های درست طبقه‌بندی شده (x_{ii}) در هر طبقه به تعداد کل پیکسل‌های طبقه‌بندی شده (x_{+i}) در هر طبقه از داده‌های مرجع، دقت تولیدکننده^۴ مشخص می‌شود. دقت تولیدکننده احتمال اینکه یک نقطه در روی زمین به درستی در طبقه مربوط به خود در نقشه طبقه‌بندی شده باشد را نشان می‌دهد.

قابل اعتمادتر، روش جستجوی شبکه‌ای برای تعریف شاخص‌های هزینه و گاما استفاده می‌شود. این الگوریتم به دلیل قابلیت‌های بالا در حل مسائل غیرخطی و قابلیت گسترش به صورت هسته‌های مختلف (مانند هسته خطی، چندجمله‌ای و شعاعی)، بسیار مورد استفاده قرار می‌گیرد (Zhao et al., 2024). عملکرد هسته خطی در آموزش بر روی مجموعه داده‌های بزرگ بهتر ارزیابی شده است (Loukika et al., 2021).

جنگل تصادفی (RF): رایج‌ترین الگوریتم طبقه‌بندی نظارت شده ناپارامتریک که در مطالعات استفاده می‌شود، الگوریتم RF است. این الگوریتم با ترکیب چندین درخت تصمیم، یک طبقه‌بندی‌کننده تلفیقی را می‌سازد (Breiman, 2001). الگوریتم حاضر با انتخاب تصادفی از داده‌های آموزشی و ویژگی‌ها، چندین درخت تصمیم‌گیری را ایجاد می‌کند. سپس، نتایج نهایی با ترکیب نتایج هر درخت به صورت میانگین یا رأی‌گیری به دست می‌آید (۷۰ درصد درختان تشخیص طبقه مرتع صورت گیرد، آن طبقه مرتع تشخیص داده می‌شود).

تعداد درختان و تعداد ویژگی هر درخت که توسط کاربر تعیین می‌شوند، دو شاخص مهم ورودی برای الگوریتم هستند. طبق مطالعات قبلی، تعداد بهینه درختان برای شمارش بین ۱۰۰ تا ۵۰۰ و تعداد بهینه ویژگی‌های شمارش شده مربع مجموعه متغیرها است (Belgiu et al., 2016). تعداد درختان تصمیم در این مطالعه ۱۰۰ عدد و از جذر مجموعه متغیرها استفاده شد.

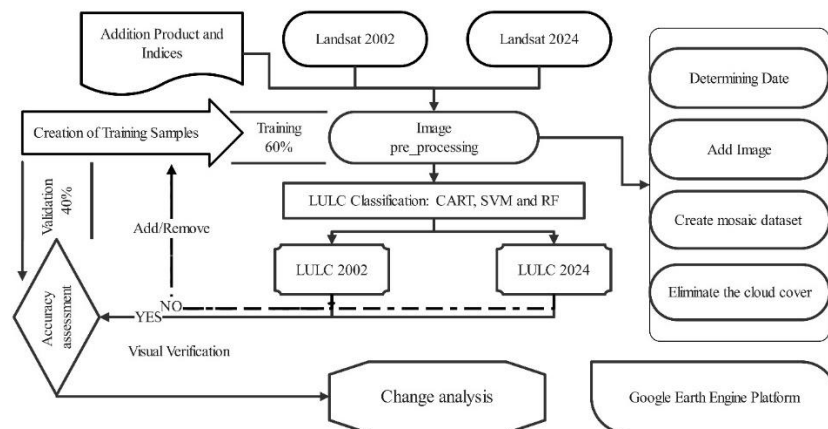
اعتبارسنجی و ارزیابی دقت: پس از اتمام طبقه‌بندی، با استفاده از الگوریتم‌های یادگیری ماشین، یک ارزیابی دقت برای تعیین دقت تصاویر طبقه‌بندی شده انجام شد. جهت اعتبارسنجی و ارزیابی دقت کلی از ۴۰ درصد داده‌ها که وارد مدل نشدند، استفاده شد. روش معمول و استاندارد برای تعیین دقت نقشه‌های طبقه‌بندی شده، استفاده از ماتریس خطا است. پیکسل‌هایی که درست طبقه‌بندی شده‌اند روی

³ User Accuracy (UA)

⁴ Producer's Accuracy (PA)

¹ Overall Accuracy (OA)

² Kappa Coefficient



شکل ۲- نمودار جریان‌ی مراحل انجام مطالعه

Fig. 2. Flowchart of the study steps

نتایج و بحث

مربوط به منابع طبیعی بوده است. الگوریتم‌های یادگیری ماشین به‌طور مداوم در حال بهبود هستند و این مطالعه نشان داد که سامانه GEE محیط مؤثری برای تولید تصاویر ترکیبی است و اجرای پردازش‌های پیچیده تصویری را به‌صورت ساده فراهم می‌آورد.

با استناد به نتایج تحقیق و مطالعات صورت گرفته قبلی، استفاده از داده‌های کمکی و شاخص‌ها موجب بهبود دقت در تشخیص و تولید نقشه‌های کاربری/پوشش زمین می‌شوند. استفاده از داده کمکی DSM به‌دلیل دربرگیری ارتفاع پوشش گیاهی و سازه‌های انسانی، در مناطق شهری و جنگلی عملکرد بهتری نسبت به DEM دارند.

به همین دلیل استفاده از DSM در مدلسازی‌های مرتبط با پوشش سطحی (مثل طبقه‌بندی کاربری/پوشش زمین) توصیه شده است. در حالی که DEM بیشتر برای تحلیل‌های توپوگرافی و هیدرولوژیکی مناسب است (Goyal et al., 2021). شاخص‌های NDWI، NDBI، RVI، NDVI کاربردترین شاخص‌های مورد استفاده در ورودی مدل‌ها هستند. استفاده از این شاخص به‌دلیل بهبود و تشخیص بهتر پوشش سطح زمین از یکدیگر با استفاده از بازتاب طیفی، سبب افزایش دقت و عملکرد بهتر الگوریتم‌ها در طبقه‌بندی کاربری‌های مختلف شدند. مطالعات دیگر همسو با نتایج این تحقیق هستند (Aghababaei et al., 2021؛ Loukika et al., 2021؛ Zhao et al., 2024).

نقشه‌های کاربری/پوشش زمین حوزه کارون ۱ در هفت کلاس کاربری با استفاده از الگوریتم‌های CART، SVM و RF در سامانه GEE برای سال‌های ۲۰۰۲ و ۲۰۲۴ کدنویسی و تهیه شدند. جهت بهبود دقت نقشه‌ها چهار شاخص (NDWI، NDBI، RVI، NDVI) از داده‌های ماهواره لندست ۷ و ۸ استخراج و به همراه داده‌های ارتفاعی (DSM) به‌عنوان ورودی‌های کمکی به مدل‌ها اضافه شدند.

شکل‌های ۵ تا ۷ نتایج طبقه‌بندی کاربری/پوشش زمین را با استفاده از الگوریتم‌های یادگیری ماشین نشان می‌دهند. پس از تهیه نقشه‌ها، این نقشه‌ها از نظر دقت کلی و ضریب کاپا مورد بررسی قرار گرفتند (جدول ۲). نتایج نشان داد که الگوریتم‌های مورد مطالعه، نقشه‌های طبقه‌بندی را با دقت کلی و ضریب کاپای عالی ایجاد کردند. بالاترین دقت کلی و ضریب کاپا مربوط به الگوریتم SVM به میزان ۹۳ درصد و ۹۱/۵ درصد در سال ۲۰۰۲ و همچنین ۹۳ درصد و ۹۲ درصد در سال ۲۰۲۴ بود. کم‌ترین میزان دقت کلی و ضریب کاپا مربوط به الگوریتم CART به مقدار ۹۰ درصد و ۸۸ درصد در سال ۲۰۰۲ و همچنین ۸۸ درصد و ۸۵ درصد در سال ۲۰۲۴ مشخص شد.

بهبود دقت طبقه‌بندی نقشه‌های کاربری/پوشش زمین و تهیه آنها در کمترین زمان ممکن، همیشه یکی از چالش‌های اصلی در حوزه سنجش از دور و مطالعات

جدول ۲- نتایج اعتبار سنجی الگوریتم‌های CART، RF و SVM در طول دوره مورد مطالعه
 Table 2. Validation results of CART, RF, and SVM algorithms during the study period

| Classification algorithms | Parameter | Raw bands of Landsat 8 and 7 images with indices and products | |
|---------------------------|-------------------|---|----------|
| | | (%) 2002 | (%) 2024 |
| CART | Kappa coefficient | 88 | 85 |
| | Overall Accuracy | 90 | 88 |
| RF | Kappa coefficient | 91 | 89 |
| | Overall Accuracy | 92 | 91 |
| SVM | Kappa coefficient | 91.5 | 92 |
| | Overall Accuracy | 93 | 93 |

مهمی در افزایش دقت طبقه‌بندی ایفا می‌کند. بنابراین، استفاده از SVM در تولید نقشه‌های کاربری/پوشش زمین نه تنها موجب بهبود نتایج طبقه‌بندی می‌شود، بلکه امکان تحلیل دقیق‌تر تغییرات کاربری را نیز فراهم می‌سازد.

چندین پژوهش عملکرد و دقت الگوریتم SVM را بالاتر از الگوریتم RF و CART برآورد کرده‌اند (Sellami and Rhinane, Kamran et al., 2021). بر اساس نتایج به دست آمده، الگوریتم RF (2023). در اساس نتایج به دست آمده، الگوریتم RF کارایی خوبی از خود نشان داد و کمترین دقت محاسبه شده برای آن ۹۰ درصد بود. با این حال، در مقایسه با الگوریتم SVM دقت طبقه‌بندی پایین‌تری داشت. علی‌رغم این نتایج، برخی مطالعات دیگر نشان می‌دهند که دقت الگوریتم RF از SVM بیشتر است (Zhao Loukika et al., 2021; Talukdar et al., 2020). (et al., 2024).

در این مطالعه، الگوریتم CART دقت پایین‌تری نسبت به الگوریتم‌های SVM و RF نشان داد. همان‌طور که قبلاً بیان شد، الگوریتم CART از قواعد درخت تصمیم برای طبقه‌بندی استفاده می‌کند که اگرچه برای طبقه‌بندی‌های ساده با تعداد طبقه محدود می‌تواند مؤثر باشد، اما طبق نتایج این تحقیق، برای وظایف پیچیده مانند تهیه نقشه‌ی تغییرات کاربری/پوشش زمین مناطق کوهستانی با شباهت طیفی زیاد، کارایی بالایی ندارد. بررسی و مرور منابع نشان می‌دهد که تحت تأثیر انواع تصاویر ماهواره‌ای، نوع سنجنده، نوع الگوریتم طبقه‌بندی کننده، منطقه مورد مطالعه، دقت موضوعی، کیفیت داده‌های آموزشی، هدف تهیه نقشه و کاربر، نتایج و خروجی‌های متفاوتی به دست می‌آید. بنابراین بهترین رویکرد، استفاده از روشی است که در سریعترین حالت ممکن مدل‌های با بیشینه پیچیدگی را با کمترین

الگوریتم‌های مختلف یادگیری ماشین به‌وضوح نشان می‌دهند که هر روش مزایا و معایب خاص خود را دارد و به‌واسطه تنوع در قواعد تصمیم‌گیری و کاربرها باید قبل از اجرای طبقه‌بندی در سامانه GEE مورد بررسی قرار گیرند. از منظر روش‌شناسی، الگوریتم SVM کارآمدترین روش شناخته شده در تولید نقشه‌های کاربری/پوشش زمین از نظر دقت کلی و ضریب کاپا در منطقه حوضه کارون ۱ بود (جدول ۲). می‌توان بیان داشت که این الگوریتم با تمرکز بر تعداد محدودی از نمونه‌های مرزی (بردارهای پشتیبان)، ساختار تصمیم‌گیری را شکل می‌دهد و برخلاف برخی الگوریتم‌های دیگر، قادر به ارائه مستقیم احتمال تعلق نمونه‌ها به طبقه‌ها (کاربری‌ها) نیست. علاوه بر این، SVM در آموزش و ارزیابی داده‌های سنجش از دور عملکرد بسیار مطلوبی دارد و برای پردازش مجموعه داده‌های بزرگ مانند تصاویر چندزمانه یا چندطیفی کاملاً مناسب است.

بهره‌گیری از نظریه یادگیری آماری در طراحی این الگوریتم، موجب افزایش دقت طبقه‌بندی و کاهش وابستگی به تجربه کاربر می‌شود (Van-Camp et al., 2004). مزایای کلیدی این الگوریتم شامل توانایی بالا در طبقه‌بندی با تعداد محدود نمونه آموزشی، قابلیت حل مسائل غیرخطی و پیچیده با استفاده از توابع کرنل و سازگاری با اصل بهینه‌سازی ریسک ساختاری است (Kamran et al., 2021). همچنین الگوریتم SVM به دلیل توانایی بالا در مدیریت پیکسل‌های مختلط و مقابله با مشکل داده‌های ناقص، به‌ویژه در طبقه‌بندی تصاویر ماهواره‌ای با وضوح متوسط مانند لندست، عملکرد قابل توجهی دارد. این ویژگی در محیط‌های پیچیده و ناهمگن، مانند بوم‌سازگان‌های طبیعی کوهستانی نظیر حوضه کارون ۱، که در آن اختلاط طیفی بین پوشش‌های مختلف زمین رایج است، نقش

کاسته شده است. همچنین کاربری‌های جنگل و پوشش یخ و برف با کاهش سطح مساحت رو به رو بودند. بر اساس الگوریتم‌های CART و RF مساحت کاربری پهنه‌های آبی حوضه کارون ۱ در سال ۲۰۰۲ به ترتیب برابر ۹۸/۴۷ و ۱۰۲/۸۹ کیلومتر مربع تخمین زده شدند و در سال ۲۰۲۴ برابر با ۵۳۷/۲۶ و ۲۷۱/۸۳ کیلومتر مربع است (جدول ۳).

افزایش پهنه‌های آبی در طی دوره ۲۰۰۲ تا ۲۰۲۴ برای الگوریتم‌های فوق به ترتیب ۴۳۸/۷۹ و ۱۶۸/۹۵ کیلومتر مربع بوده است. بررسی روند تغییرات در حوضه کارون ۱ نشان می‌دهد که بر اساس الگوریتم SVM طی دوره ۲۰۰۲ تا ۲۰۲۴ مساحت پهنه‌های آبی ۸۹/۱۵ کیلومتر مربع کاهش پیدا می‌کند (شکل ۳). الگوریتم SVM از نظر میانگین دقت تولیدکننده و کاربر، دقت بالاتری از سایر الگوریتم‌های مورد مطالعه داشت (شکل ۴).

حساسیت استخراج کند (Congalton and Green, 2019).

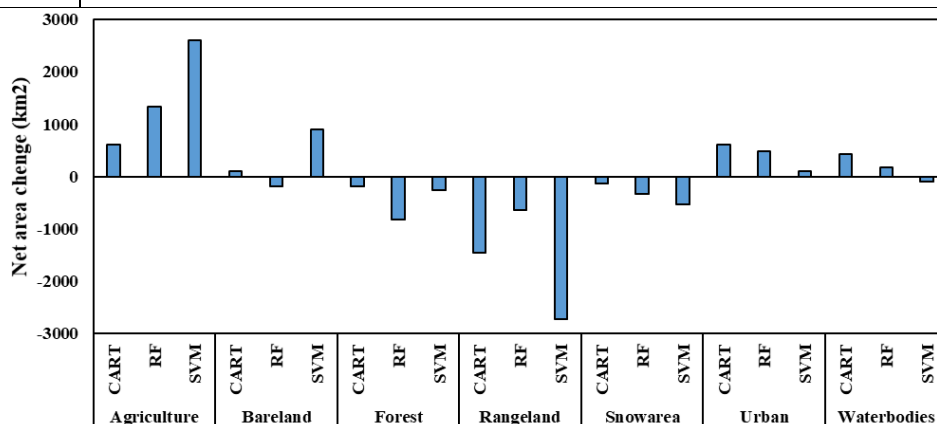
مقایسه کاربری‌های مختلف بین سال‌های ۲۰۰۲ و ۲۰۲۴ بر اساس الگوریتم‌های CART، RF و SVM در حوضه کارون ۱ نشان می‌دهد که تغییرات گسترده‌ای در آنها رخ داده است. برخی از این تغییرات افزایشی و برخی دیگر با کاهش رو به رو هستند. مشخصات و مساحت هر یک از کاربری‌ها برای دو بازه زمانی و الگوریتم‌های مورد مطالعه در جدول ۳ نمایش داده شده است.

تحلیل جدول ۳ مشخص می‌کند که کاربری مراتع بیشتر سطح حوضه کارون ۱ را شامل می‌شود (تقریباً ۴۰ درصد). بر اساس الگوریتم‌های CART، RF و SVM در حوضه کارون ۱ در طول بازه زمانی مورد مطالعه بیشینه تخریب و کاهش مساحت مربوط به کاربری مرتع است؛ به طوری که به‌صورت میانگین ۱۶۰۷/۲۹ کیلومتر مربع در یک دوره ۲۲ ساله از مساحت مراتع

جدول ۳- مساحت هر یک از کاربری‌ها در الگوریتم‌های CART، RF و SVM در طول دوره مورد مطالعه


Table 3. Area of each land use in CART, RF and SVM algorithms during the study period

| Classification algorithms | CART | | RF | | SVM | |
|---------------------------|-------------------------|----------|-------------------------|----------|-------------------------|---------|
| | Year | 2002 | 2024 | 2002 | 2024 | 2002 |
| LULC Class | Area (km ²) | | Area (km ²) | | Area (km ²) | |
| Waterbodies | 98.47 | 537.26 | 102.89 | 271.83 | 314.14 | 224.99 |
| Snowarea | 691.80 | 557.47 | 756.92 | 418.89 | 1058.44 | 524.11 |
| Bareland | 1876.00 | 1970.92 | 2047.99 | 1859.62 | 4088.27 | 4996.33 |
| Agriculture | 3519.39 | 4133.36 | 2734.11 | 4074.92 | 2361.05 | 4960.61 |
| Forest | 6827.56 | 6645.03 | 7648.36 | 6820.52 | 7730.92 | 7471.37 |
| Rangeland | 13442.85 | 11995.92 | 13484.62 | 12839.87 | 11301.21 | 8571.03 |
| Urban | 620.57 | 1236.70 | 301.76 | 790.99 | 222.62 | 328.21 |



شکل ۳- تغییرات خالص مساحت هر یک از کاربری‌ها در الگوریتم‌های CART، RF و SVM در طول دوره مورد مطالعه

Fig. 3. Net area changes of each land use class under CART, RF, and SVM algorithms during the study period



شکل ۴- درصد میانگین دقت کاربر و دقت تولیدکننده هر کاربری در الگوریتم‌های CART، RF و SVM در طول دوره مورد مطالعه
Fig. 4. Average user accuracy and producer accuracy percentages for each LULC class under CART, RF, and SVM algorithms during the study period

زمین‌های بدون پوشش و بایر در تصاویر ماهواره لندست ۸ با وضوح ۳۰ متر به دلیل پیکسل‌های ترکیبی توسط الگوریتم‌های RF و CART دشوار باشد اما الگوریتم SVM به دلیل برآورد کمتر مناطق مسکونی و دقت بالاتر در مشخص کردن پهنه‌های آبی عملکرد بهتری در طبقه‌بندی مناطق ساخته شده و پهنه‌های آبی داشته باشد (Ouma et al., 2022؛ Loukika et al., 2021؛ Zhao et al., 2024).

الگوریتم SVM کاهش پهنه‌های آبی را به میزان ۸۹/۱۵ کیلومترمربع تخمین زد. کاربری‌های مراتع و جنگل از نظر دقت تولیدکننده و کاربر، با کمترین دقت طبقه‌بندی شدند (شکل ۴). طبق الگوریتم‌های ذکر شده، بیشینه مساحت حوضه کارون ۱ به‌طور میانگین به مراتع (۴۰ درصد) و جنگل‌ها (۲۷ درصد) اختصاص دارد. همچنین نتایج حاصل از ارزیابی این الگوریتم‌ها نشان‌دهنده روند کاهشی در مساحت اراضی مرتعی و جنگلی طی دوره مورد مطالعه است (شکل ۳). الگوریتم‌های SVM و CART بیشینه تخریب را در اراضی مرتعی نمایان کردند. در صورتی که، الگوریتم RF بیشینه روند تخریب را در اراضی جنگلی (۸۲۷/۸۳ کیلومترمربع) در طول مطالعه را نشان می‌دهد.

با بررسی بصری نقشه‌های تولیدی و مقایسه با تصاویر گوگل ارث مشخص شد که اختلاف برآورد مساحت و روند کاهشی برای کاربری‌های مراتع و جنگل توسط الگوریتم‌ها ناشی از خطای رخ داده به‌دلیل

نتایج مطالعه حاضر نشان داد که هر سه الگوریتم CART، SVM و RF عملکردی با دقت و قابل اعتماد داشتند و طبقه‌بندی‌های مختلف کاربری/پوشش زمین را در سامانه GEE شناسایی و طبقه‌بندی کردند. بر اساس نتایج شکل ۴ و طبق بررسی مطالعات، الگوریتم‌های گوناگون در طبقه‌بندی طبقه‌های مختلف نقشه‌های کاربری/پوشش زمین، برای داده‌ها و سال مطالعه مشابه عملکرد متفاوتی دارند (Abdi, 2020).

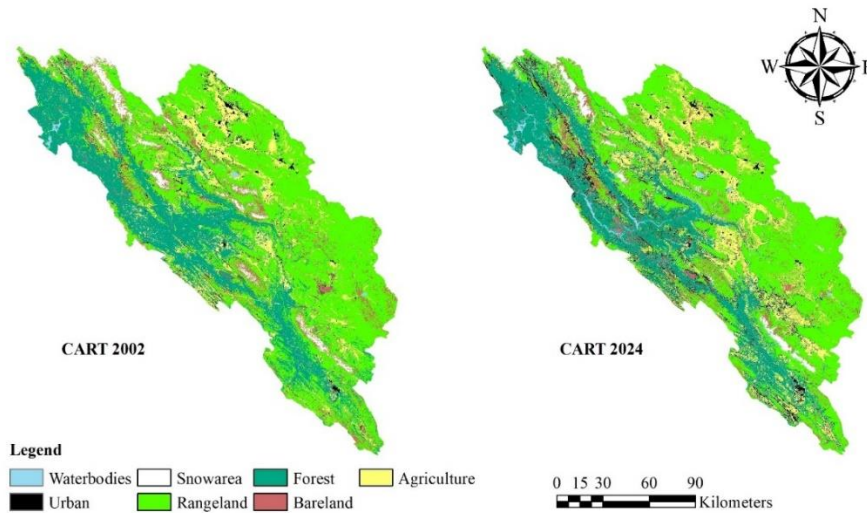
از نظر میانگین درصد دقت کاربر و تولید کننده، SVM از سایر الگوریتم‌ها بهتر عمل کرد. همچنین با توجه به شکل ۷ این الگوریتم از نظر دقت و توزیع مکانی پوشش سطح زمین عملکرد قابل قبولی ارائه داد. کاربری مناطق برفی بالاترین میانگین دقت تولید کننده (۹۹ درصد) و کاربر (۹۷ درصد) را در هر سه الگوریتم مورد مطالعه را داشت. طیف بازتابی یکنواخت و سفید رنگ مناطق برفی می‌تواند دلیل دقت بالای طبقه‌بندی این کاربری باشد. الگوریتم‌های RF و CART بخش عمده‌ای از مناطق بدون پوشش و بایر و کشاورزی را به اشتباه در کاربری مناطق ساخته شده و پهنه‌های آبی طبقه‌بندی کردند.

همین عامل موجب شد که برآورد مساحت کاربری‌های مناطق ساخته شده و پهنه‌های آبی نسبت به الگوریتم SVM خیلی بیشتر باشد. مطالعات نشان می‌دهد که تمایز بین کاربری‌های پهنه‌های آبی، مناطق ساخته‌شده، اراضی کشاورزی (تازه آبیاری شده) و

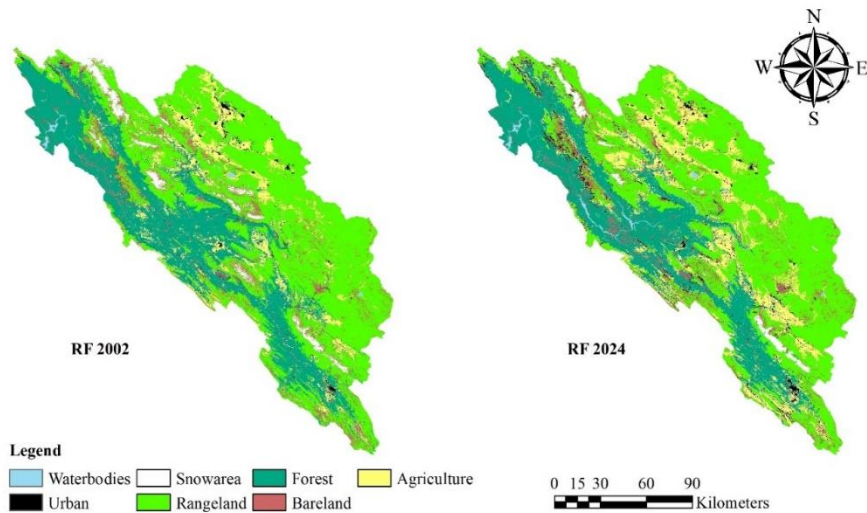
که توزیع ناهمگن مکانی و درهم دارند، محدودیت دارد (Alencar et al., 2020).

با این حال نتایج مطالعات حاکی از عملکرد بهتر الگوریتم‌های SVM و CART نسبت به الگوریتم RF در طبقه‌بندی پوشش گیاهی و جنگل‌ها است (Loukika et al., 2021). از طرفی، برخی دیگر از مطالعات اذعان دارند که الگوریتم RF در طبقه‌بندی پوشش گیاهی و جنگل بهتر عمل می‌کند (Zhao et al., 2024; Kazemi and Jafarpour, 2024).

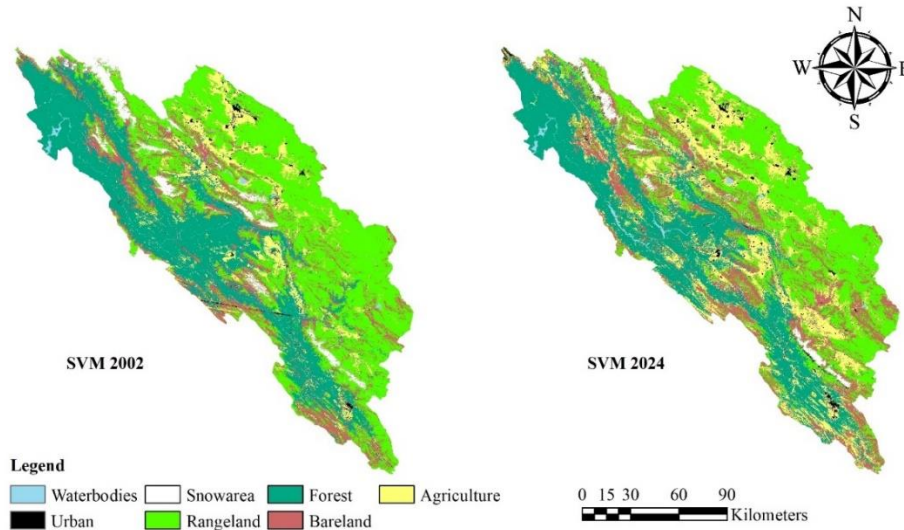
همخوانی بازتاب طیفی اراضی مرتعی، کشاورزی و جنگل با یکدیگر است. در مناطق زیادی از حوضه کارون ۱ اقدام به کشت مراتع و زیر اشکوب جنگلی شده است. همین امر موجب شده است که بخش قابل توجهی از پوشش گیاهی طبیعی به اشتباه در اراضی کشاورزی یا جنگلی و بالعکس طبقه‌بندی شوند. به عبارت دیگر، می‌توان بیان داشت که داده‌های لندست به علت وضوح مکانی متوسط (۳۰ متر) در پوشش‌های طبیعی مرتع و جنگل با اراضی کشاورزی



شکل ۵- نقشه‌های کاربری/پوشش زمین طبقه‌بندی شده توسط الگوریتم CART
Fig. 5. LULC maps classified using the CART algorithm



شکل ۶- نقشه‌های کاربری/پوشش زمین طبقه‌بندی شده توسط الگوریتم RF
Fig. 6. LULC maps classified using the RF algorithm



شکل ۷- نقشه‌های کاربری/پوشش زمین طبقه‌بندی شده توسط الگوریتم SVM

Fig. 7. LULC maps classified using the SVM algorithm

برداشت از منابع زیرزمینی و سطحی به شدت افزایش یافته است. مطالعه‌ای در حوضه کارون بزرگ واقع در کوه‌های زاگرس نشان می‌دهد که از سال ۲۰۰۷ به بعد دبی پایه جریان‌های آبی رو به کاهش است.

این نتیجه گواه این است که جریان‌های رودخانه‌ای کوهستانی نسبت به تغییرات اقلیمی و آشفتگی‌های انسانی (از جمله آلودگی آب، توسعه نیروگاه‌های برق آبی، برداشت آب برای مصرف انسان و کشاورزی، از دست دادن تنوع زیستی و تغییرات بوم‌سازگان) حساس و تحت تأثیر آنها قرار می‌گیرند (Rahimi et al., 2025). علاوه بر این خشکسالی‌های بلند مدت، افزایش دما و رخداد‌های شدید آب و هوایی، تأمین آب برای مصارف مختلف در حوضه کارون ۱ را با چالش روبه‌رو کرده است. یافته‌های پژوهش حاضر همسو با نتایج مطالعه‌ای در منطقه فندقلو (Jahdi, 2023) نشان می‌دهند که توسعه کشاورزی و افزایش مناطق انسان ساخت، محرک‌های اصلی تغییر کاربری/پوشش زمین بوده و پیامد آن کاهش مساحت مراتع و جنگل‌ها و تهدید خدمات بوم‌سازگان است. همچنین مطالعه دیگری در یکی از زیر حوضه‌های کارون ۱ (Nabizadeh et al., 2019)، نیز همانند پژوهش حاضر نشان داد که روند تغییر کاربری/پوشش زمین عمدتاً در قالب کاهش مراتع و افزایش اراضی کشاورزی و انسان ساخت رخ داده است.

به‌طور کلی حوزه آبخیز کارون ۱ با قرار گرفتن در ناحیه اقلیمی خشک و نیمه‌خشک و دارا بودن وسعت زیاد مراتع و جنگل، بیشینه تخریب را در این مناطق مشاهده می‌کند. دلایل صورت گرفتن این حجم از تخریب را می‌توان به رشد جمعیت و تکنولوژی در دهه‌های اخیر در حوضه کارون ۱ همراه با جنگل‌زدایی، تغییرات اقلیمی، تغییرات کاربری/پوشش زمین و چرای بیش از حد نسبت داد. مطالعات زیادی این امر را تأیید می‌کنند (Kamran et al., 2019; Tiscornia et al., 2021).

گسترش اراضی مسکونی، برداشت از منابع و تخریب صورت گرفته در پوشش طبیعی حوزه آبخیز کارون ۱ باعث افزایش اراضی بدون پوشش می‌شود. افزایش اراضی بدون پوشش باعث کاهش دسترسی به منابع آب زیرزمینی، کاهش حاصلخیزی خاک و افت بهره‌وری کشاورزی می‌شود (Kamran et al., 2021). در حوزه آبخیز کارون ۱ به‌دلیل رشد سریع جمعیت و دسترسی به منابع آبی و ایجاد چندین سد در این منطقه، وسعت اراضی کشاورزی برای تأمین غذا و بهره‌وری اقتصادی در طی دوره ۲۲ ساله به شدت افزایش یافت (به طور میانگین ۱۵۱۸/۱۱ کیلومترمربع) اما پهنه‌های آبی رو به کاهش گزارش شد. علاوه بر این، به‌دلیل تغییرات اقلیمی یعنی افزایش دما و کاهش بارندگی‌ها طی دو دهه اخیر سطح پوشش یخ و برف به شدت کاهش یافته است (به صورت میانگین ۳۳۵/۵۶ کیلومترمربع). با این وجود

اراضی، مدیریت منابع طبیعی، پایش تخریب پوشش گیاهی، کنترل تغییرات کاربری و تصمیم‌سازی‌های مدیریتی در حوزه آبخیز کارون ۱ مورد استفاده قرار گیرند. با این حال، محدودیت وضوح مکانی تصاویر لندست و بروز خطاهای ناشی از اختلاط پیکسلی، به‌ویژه در مرز بین طبقات کاربری/پوشش زمین، از جمله چالش‌های اصلی این پژوهش به شمار می‌رود. همچنین وابستگی پردازش‌ها به کیفیت اتصال اینترنت در محیط GEE می‌تواند در برخی شرایط سرعت انجام تحلیل‌ها را تحت تأثیر قرار دهد.

بر این اساس، پیشنهاد می‌شود در پژوهش‌های آتی از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالاتر مانند داده‌های سنتینل ۲ برای بهبود دقت طبقه‌بندی، به‌ویژه در پوشش‌های گیاهی، استفاده شود. همچنین به‌کارگیری داده‌های کمکی متنوع‌تر، شاخص‌های طیفی پیشرفته‌تر و الگوریتم‌های یادگیری عمیق می‌تواند به کاهش عدم قطعیت‌ها و ارتقای کیفیت نتایج طبقه‌بندی کاربری/پوشش زمین در منطقه مورد مطالعه کمک کند.

تشکر و قدردانی

نویسندگان از تمامی افرادی که در انجام این پژوهش همکاری داشتند، تشکر می‌نمایند.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسأله مورد تأیید همه نویسندگان قرار دارد.

این مطالعه علاوه بر تغییرات کاربری، به کاهش پهنه‌های آبی نیز اشاره دارد که به‌عنوان عاملی تشدیدکننده، فشار مضاعفی بر بوم‌سازگان‌های طبیعی و پایداری معیشت جوامع محلی وارد کرده است. مطالعات پیشین نشان می‌دهد که این روند تغییرات، چرخه‌های هیدرولوژیکی و کیفیت منابع آبخیز را به‌شدت تحت تأثیر قرار داده است. این تغییرات با افزایش رواناب، فرسایش خاک، کاهش تغذیه سفره‌های زیرزمینی و افت منابع آبی، توان بوم‌سازگان در تنظیم جریان‌ها و ارائه خدمات را تضعیف می‌کند (Shiferaw et al., 2025).

اهمیت این موضوع در حوزه آبخیز کارون ۱ به‌دلیل بحث انتقال آب بین حوضه‌ای، ایجاد سدهای متعدد و تأمین بخش عمده‌ای از نیاز آبی فلات مرکزی ایران دو چندان می‌شود. تغییر کاربری/پوشش زمین همراه با کاهش منابع آبی در این حوضه، چرخه‌های طبیعی آبخیز را مختل کرده است. بنابراین، رویکرد مدیریت یکپارچه، مشارکتی و فناورانه آبخیزداری ضروری است تا بتوان همزمان با حفاظت منابع طبیعی، پایداری معیشت و امنیت آبی جوامع محلی را تضمین کرد.

نتیجه‌گیری

نتایج این پژوهش نشان داد که به‌کارگیری الگوریتم‌های یادگیری ماشین در بستر GEE، امکان تولید نقشه‌های دقیق کاربری/پوشش زمین و پایش کارآمد تغییرات محیطی را در یک حوزه آبخیز وسیع و ناهمگن فراهم می‌سازد. نقشه‌ها و تحلیل‌های حاصل می‌توانند به‌عنوان ابزاری مؤثر در برنامه‌ریزی کاربری

منابع مورد استفاده

- Abdi, A.M., 2020. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GISci. Remote Sens.* 57(1), 1-20.
- Aghababaei, M., Ebrahimi, A., Naghipour, A.A., Asadi, E., Verrelst, J., 2021. Vegetation types mapping using multi-temporal landsat images in the google earth engine platform. *Remote Sens.* 13(22), 4683.
- Alencar, A., Z. Shimbo, J., Lenti, F., Balzani Marques, C., Zimbres, B., Rosa, M., Arruda, V., Castro, I., Fernandes Marcico Ribeiro, J.P., Varela, V., Alencar, I., 2020. Mapping three decades of changes in the brazilian savanna native vegetation using landsat data processed in the google earth engine platform. *Remote Sens.* 12(6), 924.
- Amin, A., Fazal, S., 2012. Land transformation analysis using remote sensing and GIS techniques (a case study). *J. Geogr. Inf. Syst.* 4(3), 229-236.
- Anderson, J.R., 1976. A land use and land cover classification system for use with remote sensor data (Vol. 964). US Government Printing Office.
- Armenteras, D., Murcia, U., González, T.M., Barón, O.J., Arias, J.E., 2019. Scenarios of land use and land cover change for NW Amazonia: Impact on forest intactness. *Glob. Ecol. Conserv.* 17, e00567.

- Ballabio, C., Sterlacchini, S., 2012. Support vector machines for landslide susceptibility mapping: the Staffora River Basin case study, Italy. *Math. Geosci.* 44(1), 47-70.
- Belgiu, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* 114, 24-31.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45(1), 5-32.
- Brieman, L., Friedman, J.H., Olshen, R.A., Stone, C.J. 1984. *Classification and Regression Trees*, 1st ed.; Routledge: London, UK, 45, 5-32.
- Congalton, R.G., Green, K., 2019. *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press.
- Feizizadeh, B., Blaschke, T., Tiede, D., Rezaei Moghaddam, H.M., 2017. Evaluation of fuzzy operators within an object-based image analysis approach for landslide change detection analysis. *Geomorphol.* 293, 240-254.
- Feizizadeh, B., Omarzadeh, D., Kazemi Garajeh, M., Lakes, T., Blaschke, T., 2023. Machine learning data-driven approaches for land use/cover mapping and trend analysis using Google Earth Engine. *J. Environ. Plan. Manag.* 66(3), 665-697.
- Goyal, R., Featherstone, W.E., Dikshit, O., Balasubramania, N., 2021. Comparison and validation of satellite-derived digital surface/elevation models over India. *J. Indian Soc. Remote Sens.* 49(4), 971-986.
- He, L., Yue, P., 2015. July. Moving towards intelligent giservices. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 1373-1376). IEEE.
- Hsu, C.W., Chang, C.C., Lin, C.J., 2003. *A practical guide to support vector classification*.
- Inglada, J., Vincent, A., Arias, M., Tardy, B., Morin, D., Rodes, I., 2017. Operational high resolution land cover map production at the country scale using satellite image time series. *Remote Sens.* 9(1), 95.
- Jahdi, R., 2023. Land Use/Cover Change and Its Driving Forces in the Fandoghlo Region. *Ext. Dev. Watershed Manag.* 11(42), 40-42 (in Persian)
- Japelaghi, M., Hajian, F., Gholamalifard, M., Pradhan, B., Maulud, K.N.A., Park, H.J., 2022. Modelling the impact of land cover changes on carbon storage and sequestration in the central zagros region, Iran using ecosystem services approach. *Land* 11(3), 423.
- Jordan, C.F., 1969. Derivation of leaf-area index from quality of light on the forest floor. *Ecol.* 50(4), 663-666.
- Kamran, K.V., Feizizadeh, B., Khorrami, B., Ebadi, Y., 2021. A comparative approach of support vector machine kernel functions for GIS-based landslide susceptibility mapping. *Appl. Geomat.* 13(4), 837-851.
- Kazemi, M., Jafarpoor, A., 2024. Multi Temporal Land use/Land cover using Spectral indices, Sentinel-2 Imagery and Migrated Training Samples in Google Earth Engine. *Iran. J. Watershed Manag. Sci.* 18(67), 1-15 (in Persian).
- Khan, S., Qasim, S., Ambreen, R., Syed, Z.U.H., 2016. Spatio-temporal analysis of landuse/landcover change of district pishin using satellite imagery and GIS. *J. Geogr. Inf. Syst.* 8(3), 361-368.
- Kollert, A., Bremer, M., Löw, M., Rutzinger, M., 2021. Exploring the potential of land surface phenology and seasonal cloud free composites of one year of Sentinel-2 imagery for tree species mapping in a mountainous region. *Int. J. Appl. Earth Obs. Geoinf.* 94, 102208.
- Kriegler, F., Malila, W., Nalepka, R., Richardson, W., 1969. Preprocessing transformations and their effect on multispectral recognition. In *Proceedings of the Sixth International Symposium on Remote Sensing of Environment*, Ann Arbor, MI, USA, 13-16.
- Lambin, E.F., Meyfroidt, P., 2011. Global land use change, economic globalization, and the looming land scarcity. *Proc. Natl. Acad. Sci.* 108(9), 3465-3472.
- Liu, X., He, J., Yao, Y., Zhang, J., Liang, H., Wang, H., Hong, Y., 2017. Classifying urban land use by integrating remote sensing and social media data. *Int. J. Geogr. Inf. Sci.* 31(8), 1675-1696.
- Loukika, K.N., Keesara, V.R., Sridhar, V., 2021. Analysis of land use and land cover using machine learning algorithms on google earth engine for Munneru River Basin, India. *Sustain.* 13(24), 13758.
- McFeeters, S.K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Int. J. Remote Sens.* 17(7), 1425-1432.
- Minaei, M., Boulaghi, S., Sheikh, B., Rezaalizadeh, M., Najafi Deh Jalali, A., 2025. Monitoring and simulation of land use and land cover changes in the Great Karun Basin. *Sci.-Res. Q. Geogr. Data (SEPEHR)*, 34(133), 65-87.
- Nabizadeh, S., Ebrahimi, A., Aghababaei, M. and Rahimi, I., 2019. Monitoring and predicting of land use changes in Farsan Watershed Using LCM. *J. Range Watershed Manage.* 72(1), 263-278 (in Persian).
- Nedd, R., Light, K., Owens, M., James, N., Johnson, E., Anandhi, A., 2021. A synthesis of land use/land cover studies: Definitions, classification systems, meta-studies, challenges and knowledge gaps on a global landscape. *Land* 10(9), 994.

- Ouma, Y., Nkwae, B., Moalafhi, D., Odirile, P., Parida, B., Anderson, G., Qi, J., 2022. Comparison of machine learning classifiers for multitemporal and multisensor mapping of urban LULC features. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 43, 681-689.
- Pandey, P.C., Koutsias, N., Petropoulos, G.P., Srivastava, P.K., Ben Dor, E., 2021. Land use/land cover in view of earth observation: Data sources, input dimensions, and classifiers—A review of the state of the art. *Geocarto Int.* 36(9), 957-988.
- Patino, J.E., Duque, J.C., 2013. A review of regional science applications of satellite remote sensing in urban settings. *Comput. Environ. Urban Syst.* 37, 1-17.
- Rahimi, D., Hasheminasab, S., Bashirian, F., 2025. Impact of climate change on river flow in the Zagros Mountain Region, Iran. *J. Mt. Sci.* 22(7), 2527-2540.
- Roy, S.K., Alam, M.T., Mojumder, P., Mondal, I., Kafy, A.A., Dutta, M., Ferdous, M.N., Al Mamun, M.A., Mahtab, S.B., 2024. Dynamic assessment and prediction of land use alterations influence on ecosystem service value: A pathway to environmental sustainability. *Environ. Sustain. Indic.* 21, 100319.
- Rwanga, S.S., Ndambuki, J.M., 2017. Accuracy assessment of land use/land cover classification using remote sensing and GIS. *Int. J. Geosci.* 8(04), 611.
- Santillan, J.R., Makinano-Santillan, M., 2016. Vertical accuracy assessment of 30-M resolution ALOS, ASTER, and SRTM global DEMS over Northeastern Mindanao, Philippines. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 41, 149-156.
- Sellami, E.M., Rhinane, H., 2023. A new approach for mapping land use/land cover using google earth engine: a comparison of composition images. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 48, 343-349.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., Homayouni, S., 2020. Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 13, 6308-6325.
- Shiferaw, N., Habte, L., Waleed, M., 2025. Land use dynamics and their impact on hydrology and water quality of a river catchment: a comprehensive analysis and future scenario. *Environ. Sci. Pollut. Res.* 32(7), 4124-4136.
- Tadono, T., Ishida, H., Oda, F., Naito, S., Minakawa, K., Iwamoto, H., 2014. Precise global DEM generation by ALOS PRISM. *ISPRS Annals of the Photogrammetry, Remote Sens. Spat. Inf. Sci.* 2, 71-76.
- Talukdar, S., Singha, P., Mahato, S., Praveen, B., Rahman, A., 2020. Dynamics of ecosystem services (ESs) in response to land use land cover (LU/LC) changes in the lower Gangetic plain of India. *Ecol. Indic.* 112, 106121.
- Tiscornia, G., Jaurena, M., Baethgen, W., 2019. Drivers, process, and consequences of native grassland degradation: Insights from a literature review and a survey in Río de la Plata grasslands. *Agron.* 9(5), 239.
- Torahi, A.A., Rai, S.C., 2013. Modeling for prediction of land cover changes based on bio-physical and human factors in Zagros Mountains, Iran. *J. Indian Soc. Remote Sens.* 41(4), 845-854.
- United Nations Department of Economic and Social Affairs, Population Division., 2022. World Population Prospects 2022: Summary of Results. UN DESA/POP/2022/TR/NO. 3.
- Van-Camp, L., Bujarrabal, B., Gentile, A.R., Jones, R.J., Montanarella, L., Olazabal, C., Selvaradjou, S.K., 2004. Reports of the technical working groups. Established under the Thematic Strategy for Soil Protection, 162.
- Vapnik, V., 1995. *The Nature of Statistical Learning Theory* Springer New York Google Scholar. New York: Springer.
- Wahap, N.A., Shafri, H.Z., 2020, July. Utilization of Google earth engine (GEE) for land cover monitoring over Klang Valley, Malaysia. In *IOP Conference Series: Earth Environ. Sci.* 540(1), 012003.
- Winkler, K., Fuchs, R., Rounsevell, M., Herold, M., 2021. Global land use changes are four times greater than previously estimated. *Nat. Commun.* 12(1), 2501.
- Wu, K., Wang, Y., Liu, Z., Huo, W., Cao, J., Zhao, G., Zhang, F.G., 2024. Prediction of potential invasion of two weeds of the genus *Avena* in Asia under climate change based on Maxent. *Sci. Total Environ.* 950, 175192.
- Zha, Y., Gao, J., Ni, S., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *Int. J. Remote Sens.* 24(3), 583-594.
- Zhang, C., Di, L., Yang, Z., Lin, L., Hao, P., 2020. AgKit4EE: A toolkit for agricultural land use modeling of the conterminous United States based on Google Earth Engine. *Environ. Model. Softw.* 129, 104694.

- Zhao, Z., Islam, F., Waseem, L.A., Tariq, A., Nawaz, M., Islam, I.U., Bibi, T., Rehman, N.U., Ahmad, W., Aslam, R.W., Raza, D., 2024. Comparison of three machine learning algorithms using google earth engine for land use land cover classification. *Rangel. Ecol. Manag.*, 92, 129-137.
- Zheng, Q.H., Chen, W., Li, S.L., Yu, L., Zhang, X., Liu, L.F., Singh, R.P., Liu, C.Q., 2021. Accuracy comparison and driving factor analysis of LULC changes using multi-source time-series remote sensing data in a coastal area. *Ecol. Inform.* 66, 101457.