



Comparison and Evaluation of Different Machine Learning Algorithms in Land Use/Cover Classification Using Satellite Data (Case Study: South of Lake Urmia)

Naser Ahmadi Sani^{1*} , Sohrab Moradi²

1. Associate Professor, Institute of Agriculture, Water, Food, and Nutraceuticals, Mah. C., Islamic Azad University, Mahabad, Iran. E-mail: na.ahmadisani@iau.ir
2. Assistant Prof., Department of Agricultural & Natural Resources Development, Faculty of Engineering, Payame Noor University, Tehran, I.R. Iran. E-mail: moradi_4@pnu.ac.ir

Article Info	ABSTRACT
Article type: Research Article	Objective: Land use/cover has great importance for planning at different spatial scales in order to environmental sustainability. Land use/cover changes affects ecosystem services and products, socio-economic issues, climate change, natural resource and biodiversity. This study aimed to evaluate and compare different machine learning algorithms including classification and regression tree (CART), random forest (RF) and support vector machine (SVM) for land use/cover mapping in the south of Lake Urmia.
Article history: Received: 15 December 2024 Received in revised form: 22 March 2025 Accepted: 05 November 2025 Published online: 5 November 2025	Methods: Sentinel-2A satellite data from 2023 were used within Google Earth Engine platform. Classification was performed using sample points with 70% for training and 30% for validation. The accuracy assessment was evaluated using the overall accuracy and kappa coefficient.
Keywords: Land use/ cover, Machine learning algorithms, Sentinel 2 data.	Results: Based on the land use / cover map, seven category were identified: water bodies, saline and rocky lands, irrigated farming, dry farming, built up areas, orchards, and ranges. The RF algorithm showed the highest overall accuracy (89%) while CART and SVM follow RF with 83% and 80%.
Conclusions: This study proved that RF is the best algorithm for optimal land use/cover classification, particularly in the study area. It also emphasizes the need to conduct similar studies with more advanced algorithms along with secondary data, especially in the Lake Urmia watershed, in order to achieve sustainable development.	
Cite this article: Ahmadi Sani, N., Moradi, S. (2025). Comparison and Evaluation of Different Machine Learning Algorithms in Land Use/Cover Classification Using Satellite Data (Case Study: South of Lake Urmia). <i>Journal of Remote Sensing and GIS Applications in Environmental Sciences</i> , 5 (16), 1-18. http://doi.org/10.22034/rsgi.2025.65022.1116	





Extended Abstract

Introduction

Land use / cover maps are one of the essential data needed by planners for land management (Qu et al., 2021). The dynamic nature of land use/cover maps requires regular updates and, preparing these maps with fieldwork is time-consuming and costly. Using satellite data is a practical option for its preparation (Rujoiu-Mare & Mihai, 2016). In this regard, Sentinel-2 data has been proven to be suitable for preparing land use/cover maps in heterogeneous areas (Phiri et al., 2020). On the other hand, machine learning algorithms have produced reliable results in various satellite imagery classification studies compared to other classification techniques (Zhao et al., 2024). Sharviran Plain is one of the fertile plains of Iran and has historical importance. The type of land use/cover affects the socio-economic status of local people. Given the need for access to timely land use/cover statistics in line with sustainable development, and because no documented study has been conducted to evaluate machine learning algorithms using Sentinel-2A data in preparing land use/cover maps in this area, the present study focuses on this issue.

Materials and Methods

The study area is located on the southern border of Lake Urmia with an area of about 70000 hectares. In this study, seven land use/cover classes were examined, including water bodies, saline and rocky lands, irrigated farming, dry farming, built up areas, orchards and ranges. The Sentinel-2A satellite data cloud-free from 2023 were processed on the GEE platform. Various transformations were applied to the main bands and numerous indices were extracted and used in addition to the main bands. The training and validation datasets were identified and labelled in the GEE platform with the help of Google Earth images and field observations. The validation and training samples were determined in a 70:30 ratio (Aldiansyah & Saputra, 2023) within a systematic network. Three common machine learning classification algorithms were used for classification, including classification and regression trees (CART), random forests (RF), and support vector machine (SVM) for land use/cover classification. The accuracy of the output maps was assessed using overall accuracy and kappa coefficient (Patil & Panhalkar, 2023).

Results

The results showed that the highest overall accuracy (89%) and kappa coefficient (0.87) were related to the RF algorithm. In the study of Oo et al. (2022), this algorithm was also introduced as the best. These coefficients were 86% and 0.83 in the CART algorithm, and 84% and 0.80 in the SVM algorithm. The small area of water bodies (less than 2%) and the relatively large area of saline areas (about 7-9%) indicate the limited water resources and problems of water and soil salinity in the study area. This type of spatial analysis has also been discussed in the study of Patil and Panhalkar (2023). The results of different algorithms did not show significant differences, which is in line with the results of the study of Phiri et al. (2020). Sentinel data-derived indices improved the overall accuracy by about 5%, compared to about 7% in Yimer et al. (2024). There was also spatial variation in the maps produced by different algorithms. For example, when comparing the maps produced by RF and CART, 84% of the area had the same land use/cover type. In Yimer et al. (2024), the same was 80%. Therefore, the type of algorithm should be choice carefully based on the research objectives and the characteristics of the study area (Patil & Panhalkar, 2023).

Conclusion

This study demonstrated the usefulness of machine learning algorithms for preparing land use/cover maps in the southern lands of Lake Urmia. Given the differences in the performance of classifiers and the possibility of errors in land use/cover maps, careful evaluation of classifiers is recommended for sensitive applications such as water use pattern assessment and land use planning. Users should also use remote sensing indices and auxiliary data such as ecological and socio-economic parameters in classification, as they can help improve classification results. It is recommended that in future studies, while using Google Earth Engine, more advanced machine learning and artificial intelligence techniques such as deep learning should be investigated to improve the accuracy of land use/cover classification. The importance of land use/cover in sustainable development cannot be denied; therefore,



such studies not only improve our knowledge about land use/cover, but also play an effective role in land management towards the restoration of Lake Urmia and planning for sustainable development.

References

- Aldiansyah, S., & Saputra, R. A. (2023). Comparison of machine learning algorithms for land use and land cover analysis using Google Earth engine (Case study: Wanggu watershed). *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 19(2), 197-210. <https://doi.org/10.30536/j.ijreses.2022.v19.a3803>.
- Beyer, F., Jarmer, T. and Siegmann, B. (2015). Identification of agricultural crop types using multitemporal rapideye data. *Photogrammetrie-Fernerkundung-Geoinformation*, 1: 21-32. <https://doi.org/10.1127/pfg/2015/0249>.
- Oo, T. K., Arunrat, N., Sereenonchai, S., Ussawarujikulchai, A., Chareonwong, U., & Nutmagul, W. (2022). Comparing four machine learning algorithms for land cover classification in gold mining: A case study of Kyaukpahto Gold Mine, Northern Myanmar. *Sustainability*, 14(17), 10754. <https://doi.org/10.3390/su141710754>.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V.R., Murayama, Y. & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, 12(14), 2291-2291. <https://doi.org/10.3390/rs12142291>.
- Qu, L.A., Li, M., Chen, Z. & Zhi, J. (2021). A modified self-adaptive method for mapping annual 30-m land use/land cover using Google Earth engine: a case study of Yangtze River Delta. *Chinese Geographical Science*, 31, 782–794. <https://doi.org/10.1007/s11769-021-1226-4>.
- Yimer, S. M., Bouanani, A., Kumar, N., Tischbein, B. & Borgemeister, C. (2024). Comparison of different machine-learning algorithms for land use land cover mapping in a heterogenous landscape over the Eastern Nile river basin, Ethiopia. *Advances in Space Research*, 74(5), 2180-2199. <https://doi.org/10.1016/j.asr.2024.06.010>.
- 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., & Hatamleh, W. A. (2024). Comparison of three machine learning algorithms using google earth engine for land use land cover classification. *Rangeland ecology & management*, 92, 129-137. <https://doi.org/10.1016/j.rama.2023.10.007>.



مقایسه و ارزیابی الگوریتم‌های مختلف یادگیری ماشین در طبقه‌بندی نقشه کاربری / پوشش اراضی با استفاده از تصاویر ماهواره‌ای (مطالعه موردی: جنوب دریاچه ارومیه)

ناصر احمدی ثانی^{۱*} ID، سهراب مرادی^۲ ID

۱. دانشیار دانشکده کشاورزی، آب، غذا و فراسودمندها، واحد مهاباد، دانشگاه آزاد اسلامی، مهاباد، ایران. رایانامه: na.ahmadisani@iau.ir
۲. استادیار گروه توسعه کشاورزی و منابع طبیعی، دانشکده فنی و مهندسی، دانشگاه پیام نور، تهران، ایران. رایانامه: moradi_4@pnu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	طبقه‌بندی کاربری / پوشش اراضی برای برنامه‌ریزی در مقیاس‌های مکانی مختلف در راستای پایداری محیط‌زیست اهمیت بسیاری دارد. نظارت بر تغییرات کاربری / پوشش اراضی بر خدمات و محصولات اکوسیستم، مسائل اجتماعی - اقتصادی، تغییر اقلیم، منابع طبیعی و تنوع زیستی تأثیر می‌گذارد. این پژوهش با هدف ارزیابی و مقایسه سه الگوریتم رایج یادگیری ماشین (درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان) برای طبقه‌بندی کاربری / پوشش اراضی در جنوب دریاچه ارومیه انجام شد. در این رابطه از تصاویر سال ۲۰۲۳ ماهواره Sentinel-2A در بستر گوگل ارث انجین استفاده شد. داده‌های نمونه در قالب دو مجموعه داده‌های تعلیمی (۷۰ درصد) و داده‌های آزمون (۳۰ درصد) برای انجام طبقه‌بندی استفاده شد. صحت نقشه‌های حاصل با استفاده از صحت کلی و ضریب کاپا ارزیابی شد. بر اساس نقشه کاربری / پوشش اراضی، هفت کاربری پهنه‌های آبی، اراضی شور و سنگی، اراضی زراعی آبی، اراضی زراعی دیم، مناطق انسان‌ساخت، باغات و مراتع شناسایی شد. صحت کلی برای الگوریتم‌های درخت طبقه‌بندی و رگرسیون (CART)، جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) به ترتیب ۸۶، ۸۹ و ۸۴ درصد و ضریب کاپا به ترتیب برابر ۰/۸۳، ۰/۸۷ و ۰/۸۰ حاصل شد. نتایج نشان داد که الگوریتم جنگل تصادفی از سایر الگوریتم‌ها بهتر عمل می‌کند. بنابراین این پژوهش کارایی و قابلیت بالاتر الگوریتم طبقه‌بندی جنگل تصادفی را در مقایسه با سایر الگوریتم‌ها در تهیه نقشه کاربری / پوشش اراضی اثبات می‌کند. همچنین بر لزوم انجام مطالعات مشابه با الگوریتم‌های پیشرفته‌تر همراه با داده‌های جانبی به‌ویژه در حوضه آبریز دریاچه ارومیه در راستای نیل به توسعه پایدار تأکید می‌کند.
تاریخ دریافت: ۱۴۰۳/۰۹/۲۵ تاریخ بازنگری: ۱۴۰۴/۰۱/۰۲ تاریخ پذیرش: ۱۴۰۴/۰۸/۱۴ تاریخ انتشار: ۱۴۰۴/۰۸/۱۴	
کلیدواژه‌ها: الگوریتم‌های یادگیری ماشین، داده‌های سنتینل ۲، کاربری / پوشش اراضی.	

استناد: احمدی ثانی، ناصر و مرادی، سهراب (۱۴۰۴). مقایسه و ارزیابی الگوریتم‌های مختلف یادگیری ماشین در طبقه‌بندی نقشه کاربری / پوشش اراضی با استفاده از تصاویر ماهواره‌ای (مطالعه موردی: جنوب دریاچه ارومیه). کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی، ۵ (۱۶)، ۱-۱۸

<http://doi.org/10.22034/rsgi.2025.65022.1116>



© نویسندگان.

ناشر: دانشگاه تبریز.

مقدمه

اصطلاح‌های کاربری اراضی^۱ (LU) و پوشش زمین^۲ (LC) اغلب به‌طور یکسان برای توصیف رابطه پیچیده‌ای که بین مردم و محیط اطراف آن‌ها وجود دارد، استفاده می‌شود (فام و همکاران، ۲۰۲۴؛ رسول و همکاران، ۲۰۲۱). کاربری اراضی به نحوه استفاده از زمین اشاره دارد، درحالی‌که پوشش زمین بر ویژگی‌های واقعی مناظر زمین دلالت دارد (محمودی و همکاران، ۱۳۹۷؛ پاندی و همکاران، ۲۰۲۱). معمولاً برای اجتناب از اشتباه در به‌کارگیری این دو اصطلاح از اصطلاح ترکیبی کاربری/پوشش اراضی^۳ (LULC) استفاده می‌کنند (محمودی و همکاران، ۱۳۹۷). تغییرات کاربری/پوشش اراضی مانند توسعه اراضی شهری، جنگل‌زدایی، از بین رفتن تالاب‌ها و تخریب خاک و توسعه زمین‌های کشاورزی نگرانی‌هایی را در سراسر جهان ایجاد کرده است (روی و همکاران، ۲۰۲۲) زیرا به‌طور قابل توجهی بر خدمات و محصولات اکوسیستم (ژانگ و همکاران، ۲۰۱۷)، مسائل اجتماعی-اقتصادی (سرا و همکاران، ۲۰۱۴)، تغییرات آب و هوایی (لی و همکاران، ۲۰۱۷) و مدیریت منابع طبیعی و تنوع زیستی (بیسواس و همکاران، ۲۰۲۳) تأثیر می‌گذارد. اطلاعات دقیق و نقشه‌های به‌روز کاربری/پوشش اراضی یکی از داده‌های ضروری مورد نیاز مدیران محلی، برنامه‌ریزان و سیاست‌گذاران برای انجام فعالیت‌های مختلف به‌منظور مدیریت زمین، حفاظت از تنوع زیستی، توسعه راهبردها و سیاست‌های حفاظتی، برنامه‌ریزی منابع زیستی، پژوهش‌های خدمات اکولوژیکی و نظارت بر کشاورزی است (مالارویژی و همکاران، ۲۰۱۶؛ فالک و همکاران، ۲۰۲۰؛ کیو و همکاران، ۲۰۲۱). همچنین ماهیت پویای کاربری/پوشش اراضی، مستلزم به‌روزرسانی منظم نقشه‌های کاربری/پوشش اراضی است (شفیع‌زاده مقدم و همکاران، ۲۰۲۱).

تهیه نقشه طبقات کاربری/پوشش اراضی با کار میدانی زمان‌بر و پرهزینه است. استفاده از داده‌های سنجنش‌ازدور ماهواره‌ای یک گزینه عملی برای شناسایی و تهیه نقشه کاربری/پوشش اراضی است (روجیو-ماره و میهای، ۲۰۱۶) و برای غلبه بر فقدان آمارها و داده‌های زمینی، امروزه به‌طور فزاینده‌ای از سنجنش‌ازدور و تصاویر ماهواره‌ای برای تهیه نقشه کاربری/پوشش اراضی استفاده می‌شود (جین و همکاران، ۲۰۱۷). اگرچه، هدف از به‌کارگیری سنجنش‌ازدور، فراهم کردن اطلاعات سطح زمین در مقیاس‌های متفاوت زمانی و مکانی با صحت بالا و هزینه کم (بسته به قدرت تفکیک داده‌ها) است، تهیه نقشه کاربری/پوشش اراضی با استفاده از فناوری سنجنش‌ازدور همچنان به دلیل هزینه بالای برخی تصاویر، ضمانت دسترسی به آن‌ها، تنوع چشم‌اندازها و آنالیز تصاویر چالش‌برانگیز است (بین و همکاران، ۲۰۲۰).

پژوهشگران در حال تغییر به سمت پلت‌فرم‌های ابری^۴ برای برنامه‌های سنجنش‌ازدور هستند، زیرا کارآمدتر از روش طبقه‌بندی بعد از دانلود یک مجموعه داده بزرگ و پردازش دستی آن‌ها است (بیسواس و همکاران، ۲۰۲۳). گوگل ارث انجین^۵ (GEE) یک پلت‌فرم پردازش مکانی قدرتمند و کاربرپسند مبتنی بر ابر برای پردازش تصاویر ماهواره‌ای و ارائه داده‌های مکانی در مقیاس جهانی است (شفیع‌زاده مقدم و همکاران، ۲۰۲۱؛ قوش و همکاران، ۲۰۲۲). GEE به‌عنوان یک پایگاه داده ذخیره‌سازی بسیار بزرگ، مدل‌های پردازش پیشرفته و ابزارهای تجزیه و تحلیل و تجسم داده‌های مکانی را نیز فراهم می‌کند و کاربران می‌توانند تصاویر سنجنش‌ازدور موجود را برای تهیه نقشه کاربری/پوشش اراضی در بستر آن تجزیه و تحلیل کنند (گولیک و همکاران، ۲۰۱۷؛ بوتروید و همکاران، ۲۰۲۱). گزارش شده است که GEE در حوزه‌های مختلف کشاورزی، جنگلداری، بوم‌شناسی، اقتصاد و پزشکی استفاده شده است و در این میان، بیشترین کاربرد را در مطالعات کاربری زمین و پوشش گیاهی داشته است (تامیمینا و همکاران، ۲۰۲۰).

^۱ Land use

^۲ Land cover

^۳ Land use/Land cover (LULC)

^۴ Cloud-based platforms

^۵ Google Earth Engine (GEE)

داده‌های ماهواره‌های مختلف مانند لندست^۱ و سنتینل^۲ در یک مکان در پلت‌فرم GEE تجمع می‌شوند (بیسواس و همکاران، ۲۰۲۳). ثابت شده است که تصاویر ماهواره‌ای سنتینل-۲ به دلیل تفکیک طیفی و مکانی نسبتاً بالا برای تهیه نقشه کاربری/پوشش اراضی در مناظر ناهمگن و تکه‌تکه مناسب است (فیری و همکاران، ۲۰۲۰؛ کلریچی و همکاران، ۲۰۱۷). پلت‌فرم GEE همچنین به پژوهشگران اجازه می‌دهد تا از الگوریتم‌های مختلف یادگیری ماشین مانند درخت طبقه‌بندی و رگرسیون (CART)^۳، جنگل تصادفی (RF)^۴ و ماشین بردار پشتیبان (SVM)^۵ برای طبقه‌بندی تصاویر استفاده کنند که در این میان، جنگل تصادفی رایج‌ترین روش طبقه‌بندی مورد استفاده است (تامیمینیا و همکاران، ۲۰۲۰). استفاده از GEE برای کاربردهای مختلف سنجش‌ازدور مانند تعیین محدوده تالاب‌ها (امینی و همکاران، ۲۰۱۹؛ مهدیان‌پری و همکاران، ۲۰۲۰)، استخراج نقشه کاربری/پوشش اراضی (زرقانی و همکاران، ۲۰۱۸؛ قربانیان و همکاران، ۲۰۲۰) و تهیه نقشه محصولات کشاورزی (الیفانت و همکاران، ۲۰۱۹؛ گوما و همکاران، ۲۰۲۰) در سال‌های اخیر رایج شده است.

از آنجاکه شناسایی و تفکیک پدیده‌های زمینی و قرار دادن آن‌ها در گروه‌ها و طبقه‌های مشخص، هدف اصلی در تهیه نقشه‌های کاربری/پوشش اراضی است، می‌توان طبقه‌بندی تصاویر ماهواره‌ای را به‌عنوان مهم‌ترین بخش تفسیر اطلاعات ماهواره‌ای به شمار آورد (محمودی و همکاران، ۱۳۹۷). طبقه‌بندی‌های متعددی برای تولید نقشه‌های کاربری/پوشش اراضی توسعه یافته و مورد استفاده قرار گرفته است، اما عملکرد فردی آن‌ها ممکن است با داده‌های ورودی، تعریف کلاس مرجع و شرایط محیطی متفاوت باشد. دقت طبقه‌بندی‌های کاربری/پوشش اراضی به الگوریتم‌های مورد استفاده برای تجزیه و تحلیل الگوهای منظر مکانی و زمانی با بهره‌گیری از اطلاعات تولیدشده توسط سامانه‌های سنجش‌ازدور بستگی دارد (لاور، ۲۰۲۴). از میان روش‌های مختلفی که برای طبقه‌بندی تصاویر وجود دارند، عموماً روش‌های نظارت‌شده برای طبقه‌بندی تصاویر ماهواره‌ای استفاده شده است (محمودی و همکاران، ۱۳۹۷). الگوریتم‌های یادگیری ماشین نتایج طبقه‌بندی قابل اعتماد، دقیق و معتبری را در مقایسه با سایر روش‌های طبقه‌بندی کاربری/پوشش اراضی ایجاد کرده‌اند (ژائو و همکاران، ۲۰۲۴). پژوهش‌های مختلف طبقه‌بندی‌های ماشین یادگیری مانند درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان را برای طبقه‌بندی تصاویر ماهواره‌ای استفاده کرده‌اند و بر کارایی و سودمندی نتایج آن‌ها تأکید شده است (فیری و همکاران، ۲۰۲۰).

الگوریتم درخت طبقه‌بندی و رگرسیون، یک الگوریتم درخت تصمیم^۶ است که برای اولین بار توسط بریمن در سال ۱۹۸۴ میلادی ارائه شد (بریمن، ۲۰۱۷) و جزء محبوب‌ترین و در عین حال ساده‌ترین الگوریتم‌های یادگیری ماشین نظارت‌شده است که کاربردهای زیادی در طبقه‌بندی و رگرسیون دارد. درخت تصمیم یک ابزار قدرتمند برای طبقه‌بندی کارآمد یک مجموعه داده بر اساس متمایزترین ویژگی‌های آن است. استفاده از الگوریتم درخت طبقه‌بندی و رگرسیون در پژوهش‌های مختلف با موفقیت در پردازش و تجزیه و تحلیل تصاویر (پانده و همکاران، ۲۰۲۴) استفاده شده است. پژوهش‌ها نشان داده است که الگوریتم درخت طبقه‌بندی و رگرسیون می‌تواند حجم زیادی داده را در زمان اندکی مدیریت کند (هارتفیلد و همکاران، ۲۰۱۱).

الگوریتم جنگل تصادفی یکی از انواع الگوریتم‌های یادگیری ماشین از زیرمجموعه هوش مصنوعی است که به دلیل دقت و صحت بالای نتایج طبقه‌بندی حاصل از آن، از پرکاربردترین روش‌ها برای تهیه نقشه کاربری/پوشش اراضی با استفاده از تصاویر ماهواره‌ای است (جی و همکاران، ۲۰۲۰؛ ساها و همکاران، ۲۰۲۰؛ ژائو و همکاران، ۲۰۲۴). این الگوریتم می‌تواند برای تجزیه و تحلیل سنجش‌ازدور به منظور پیش‌بینی و طبقه‌بندی استفاده شود و نوع مدرن روش‌های درخت تصمیم است که شامل انبوهی از درخت‌های

^۱ Landsat

^۲ Sentinel

^۳ Classification and Regression Trees

^۴ Random forest

^۵ Support Vector Machine

^۶ Decision Tree

کلاس‌بندی و رگرسیون هستند (بريمن، ۲۰۰۱). الگوریتم جنگل تصادفی می‌تواند به‌طور مؤثر روی پایگاه داده‌های بزرگ اجرا شود و مقادیر زیادی داده را با صدها متغیر مختلف مدیریت کند (علی و همکاران، ۲۰۲۲). در الگوریتم جنگل تصادفی، ابتدا تعدادی درخت تصمیم‌گیری که نسبت به هم بیشترین تمایز دارند، تشکیل شده و سپس در مورد هر یک از این درخت‌ها روند تصمیم‌گیری به‌صورت جداگانه انجام می‌شود. با توجه به نتایج، طبقه برنده طبقه‌ای است که بیشترین رأی به آن تعلق گیرد.


ماشین بردار پشتیبان یکی از مدل‌های ماشین یادگیری نظارت شده است که جهت طبقه‌بندی و تفکیک گروه‌ها به کار می‌رود (گریناند و همکاران، ۲۰۲۰). پس از مشخص شدن عوامل محیطی اثرگذار، مدل ماشین بردار پشتیبان به تجزیه و تحلیل روابط میان آن‌ها پرداخته و داده‌ها را به گروه‌های متمایزی تقسیم می‌کند. اساس کار دسته‌بندی کردن داده‌ها در الگوریتم ماشین بردار پشتیبان، یافتن ابرصفحه^۱ بهینه‌ای است که با داشتن بیشترین حاشیه، دو گروه داده را از هم جدا کند (بوعزیز و همکاران، ۲۰۱۷). در پژوهش‌های مختلف از الگوریتم ماشین بردار پشتیبان نیز برای طبقه‌بندی تصاویر ماهواره‌ای و تهیه نقشه کاربری/ پوشش اراضی استفاده شده است (محمودی و همکاران، ۱۳۹۷؛ بوعزیز و همکاران، ۲۰۱۷؛ هاشم و همکاران، ۲۰۲۱).

دشت شرویران (شارویران) از دشت‌های حاصلخیز آذربایجان غربی به شمار می‌آید و در دوران مختلف تاریخی مهد تمدن بشری بوده و به همین دلیل دارای اهمیت تاریخی است. نوع کاربری و پوشش زمین شارویران، به‌طور مستقیم بر وضعیت اجتماعی- اقتصادی مردم محلی تأثیر می‌گذارد. بررسی توزیع و وضعیت فعلی انواع کاربری/ پوشش اراضی در این منطقه برای مطالعات زیست‌محیطی و مدیریت آبخیز ضروری است. با توجه به این موضوع و ضرورت دسترسی به آمارهای به‌هنگام کاربری/ پوشش زمین در راستای توسعه پایدار و نظر به اینکه مطالعه مستندی برای ارزیابی داده‌های Sentinel-2A برای تهیه نقشه پوشش زمین در منطقه مورد مطالعه انجام نشده است، پژوهش حاضر بر این موضوع تمرکز نموده است. اهداف اصلی این مطالعه تهیه نقشه کاربری/ پوشش اراضی با وضوح بالا برای یک محیط ناهمگن در مناطقی از جنوب دریاچه ارومیه (دشت شارویران) با استفاده از قابلیت‌های بستر GEE و به‌کارگیری تصاویر Sentinel-2A و ارزیابی و مقایسه عملکرد سه الگوریتم طبقه‌بندی‌کننده پرکاربرد درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین‌برداری پشتیبان برای طبقه‌بندی کاربری/ پوشش اراضی است.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه با مساحت حدود ۷۰ هزار هکتار در مرز جنوبی دریاچه ارومیه قرار دارد. بخش‌های مسطح منطقه شامل مناطق انسان‌ساخت (عمدتاً روستاها و شهرستان مهاباد)، باغات، اراضی زراعی، مراتع و شوره‌زارها است. اقلیم منطقه سرد و مرطوب، ارتفاع متوسط از سطح دریا ۱۳۱۰ متر و متوسط بارندگی سالیانه حدود ۳۵۰ میلی‌متر است.



شکل ۱. تصویر سنتینل منطقه مورد مطالعه و موقعیت آن در ایران

Fig. 1- Sentinel image of the study area and its location in Iran

روش پژوهش

در این پژوهش، داده‌های Sentinel-2A مربوط به سال ۲۰۲۳ در پلتفرم GEE برای تهیه نقشه کاربری/ پوشش اراضی مورد استفاده قرار گرفت. سنتینل دو شامل دو ماهواره است: Sentinel-2A در سال ۲۰۱۵ و Sentinel-2B در سال ۲۰۱۷ در مدار قرار گرفتند. Sentinel-2 ترکیبی منحصربه‌فرد از پوشش جهانی با میدان دید وسیع (۲۹۰ کیلومتر)، قابلیت تکرار بالا (۵ روز با دو ماهواره)، وضوح بالا (۱۰ متر، ۲۰ متر و ۶۰ متر) و تصاویر چند طیفی ارائه می‌دهد (۱۳ باند طیفی در حوزه مرئی، مادون قرمز نزدیک (VNIR) و مادون قرمز با طول موج کوتاه (SWIR)). (ریول و همکاران، ۲۰۱۹؛ ژائو و همکاران، ۲۰۲۴).

الگوریتم‌های طبقه‌بندی متعددی برای طبقه‌بندی داده‌های سنجش‌ازدور در تهیه نقشه‌های کاربری/ پوشش اراضی استفاده می‌شود (وینگیت و همکاران، ۲۰۱۶). الگوریتم‌های یادگیری ماشین در بستر GEE یکی از پیشرفته‌ترین روش‌ها برای تهیه نقشه‌های کاربری/ پوشش اراضی از داده‌های ماهواره‌ای مختلف با نتایج قابل اعتماد است (ژائو و همکاران، ۲۰۲۴). الگوریتم‌های یادگیری ماشین از یک رویکرد استقرایی (مبتنی بر داده‌های تجربی) برای تشخیص الگو در داده‌ها استفاده می‌کنند. پس از یادگیری، روابط الگو برای سایر داده‌های مشابه به‌منظور پیش‌بینی در طبقه‌بندی اعمال می‌شود. این الگوریتم‌ها در پیش‌بینی طبقات از داده‌های آموزشی پراکنده مکانی به‌ویژه در مواردی که فرآیند مورد بررسی پیچیده و چندبعدی است، به‌خوبی عمل می‌کنند (کرکزل و ری‌دینگ، ۲۰۱۴).

در این پژوهش برای انجام طبقه‌بندی از سه الگوریتم طبقه‌بندی رایج یادگیری ماشین شامل درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان برای طبقه‌بندی کاربری/ پوشش اراضی استفاده شد (تیان و همکاران، ۲۰۱۶؛ شولز و همکاران، ۲۰۲۱). سه روش مذکور از روش‌های طبقه‌بندی غیر پارامتریک هستند که به توزیع آماری داده‌ها وابسته نیستند و لذا محدودیت‌های روش‌های پارامتریک نظیر روش حداکثر تشابه را ندارند. از مزایای دیگر روش‌های طبقه‌بندی غیر پارامتریک آن است که برای توصیف ریاضی پدیده‌ها به ارتباط از پیش تعیین‌شده بین داده‌های ورودی و خروجی نیاز ندارد (محمودی و همکاران، ۱۳۹۷). شکل ۲ روندنمای اجرائی پژوهش را نشان می‌دهد.

طبقات کاربری/ پوشش اراضی


هفت طبقه کاربری/ پوشش زمین شامل پهنه‌های آبی، اراضی شور و سنگی، اراضی زراعی آبی، اراضی زراعی دیم، مناطق انسان‌ساخت، باغات و مراتع بر اساس کار میدانی، تصاویر گوگل ارث و نظر کارشناسان مورد بررسی قرار گرفت (جدول ۱).

جدول ۱. توصیف طبقات کاربری/ پوشش اراضی

Table 1. Description of land use/ land cover classes

نوع کاربری/ پوشش اراضی	توصیف کاربری/ پوشش اراضی
پهنه‌های آبی	استخرها، کانال‌های آب، رودخانه‌ها، سدها و تالاب‌ها
اراضی شور و سنگی	زمین‌های شور (خشک و مرطوب)، مناطق سنگلاخی
اراضی زراعی آبی	کشت‌های آبی عمدتاً یونجه، چغندر، گندم و جو
اراضی زراعی دیم	کشت‌های مبتنی بر آب باران عمدتاً گندم، جو و نخود
مناطق انسان‌ساخت	جاده‌ها، روستاها، صنایع و کارخانه‌ها و سایر بناهای مسکونی
باغات	باغات میوه مختلف عمدتاً سیب و هلو
مراتع	مراتع طبیعی شامل پوشش‌های گیاهی باریک‌برگ، پهن‌برگ و بوته‌ای‌ها

پردازش تصاویر



شکل ۲. فلوچارت مراحل اجرای تحقیق

Fig. 2- Research implementation flowchart

تصاویر بدون پوشش ابری سال ۲۰۲۳ ماهواره Sentinel-2 Level 2A، که از نظر هندسی و اتمسفری تصحیح شده هستند (ریول و همکاران، ۲۰۱۹) در پلت فرم GEE مورد پردازش قرار گرفت. باندهای داده‌های ماهواره‌ای به‌تنهایی ممکن است کیفیت مناسبی از تهیه نقشه کاربری/پوشش اراضی را در یک چشم‌انداز ناهمگن ارائه ندهند. شاخص‌های مستخرج از سنجش‌ازدور می‌تواند صحت تهیه نقشه کاربری/پوشش اراضی را بهبود بخشد (یمر و همکاران، ۲۰۲۴؛ نیگار و همکاران، ۲۰۲۴). بنابراین در این پژوهش هم تبدیل‌های مختلفی روی باندهای اصلی اعمال شد و شاخص‌های متعددی علاوه بر باندهای اصلی استخراج شد و مورد استفاده قرار گرفت که به برخی از مهم‌ترین آن‌ها در جدول ۲ اشاره شده است.

جدول ۲. شاخص‌های مورد استفاده در پژوهش

Table 2. Indicators used in the research

منبع	شاخص/تبدیل
چن و همکاران، (۲۰۱۷)	شاخص تفاضل نرمال آب (NDWI)
شولز و همکاران، (۲۰۲۱)	تبدیل تسلدکپ (TCT)
جی و همکاران، (۲۰۲۰)	شاخص گیاهی توسعه‌یافته تعدیل‌کننده اثرات خاک (MSAVI)
مودیکا و همکاران، (۲۰۲۰)	شاخص گیاهی کلروفیل (CVI)
مودیکا و همکاران، (۲۰۲۰)	شاخص تفاضل نرمال شده لبه قرمز گیاهی (NDRE)
موهارانا و همکاران، (۲۰۲۱)	شاخص نسبت پوشش گیاهی (RVI)
پسینا و همکاران، (۲۰۲۱)	شاخص اختلاف پوشش گیاهی (DVI)
تان و همکاران، (۲۰۲۱)	شاخص تفاضلی نرمال مناطق انسان‌ساخت (NDBI)
وانگ و همکاران، (۲۰۲۱)	تجزیه مؤلفه‌های اصلی (PCA)
ژانگ و همکاران، (۲۰۲۱)	شاخص نرمال تفاوت پوشش گیاهی (NDVI)

نمونه‌های تعلیمی و اعتبارسنجی

مجموعه داده‌های آموزشی و اعتبارسنجی در بستر GEE و با کمک تصاویر گوگل ارث و برداشت‌های میدانی، شناسایی و نشانه‌گذاری شدند. نمونه‌های اعتبارسنجی و آموزشی با نسبت ۷۰ به ۳۰ (زرقانی و همکاران، ۲۰۱۸؛ آلدینسیاه و ساپوترا، ۲۰۲۳؛ امین و همکاران، ۲۰۲۴) در قالب یک شبکه سیستماتیک تعیین شدند.

تعداد داده‌های واقعیت زمینی (نمونه‌های تعلیمی و اعتبارسنجی) برای طبقات مختلف کاربری/ پوشش زمین حاصل از تفسیر تصاویر در بستر GEE و با کمک برداشت‌های زمینی و نظر کارشناسان شامل ۱۰۴۴ نقطه با توزیع سامان مند (۷۳۰ نقطه تعلیمی و ۳۱۴ نقطه اعتبارسنجی) در جدول ۳ آورده شده است.

جدول ۳. داده‌های واقعیت زمینی در طبقات مختلف کاربری/ پوشش اراضی
Table 3. Ground truth data in different land use/land cover classes

نوع کاربری/ پوشش اراضی	نمونه‌های تعلیمی	نمونه‌های اعتبارسنجی
باغات	۸۵	۳۷
مناطق شور و سنگی	۵۱	۲۱
پهنه‌های آبی	۳۶	۱۵
اراضی زراعی آبی	۷۳	۳۵
مناطق انسان‌ساخت	۴۵	۲۲
مراتع	۲۱۱	۹۰
اراضی زراعی دیم	۲۲۹	۹۴
مجموع	۷۳۰	۳۱۴

ارزیابی صحت

ارزیابی صحت تصاویر طبقه‌بندی‌شده، یکی از مراحل و کارهای اساسی در طبقه‌بندی تصویر کاربری/ پوشش اراضی، آشکارسازی تغییرات و پیش‌بینی آینده است (وانگ و همکاران، ۲۰۲۱؛ فام و همکاران، ۲۰۲۴). به‌منظور مقایسه نقشه کاربری/ پوشش اراضی حاصل از طبقه‌بندی‌ها با نقشه واقعیت زمینی، ارزیابی صحت برای خروجی طبقه‌بندی‌ها با استفاده از شاخص‌های صحت کاربر (UA)^۱، صحت تولیدکننده (PA)^۲، صحت کلی (OA)^۳ و ضریب کاپا (Kc)^۴ انجام شد (پاتیل و پانهالکار، ۲۰۲۳). این شاخص‌ها که از روش متداول ماتریس خطا^۵ به دست می‌آیند در پژوهش‌های مختلف به‌منظور ارزیابی صحت الگوریتم‌های استفاده‌شده برای طبقه‌بندی تصاویر ماهواره‌ای استفاده شده‌اند (بیسواس و همکاران، ۲۰۲۳؛ ژائو و همکاران، ۲۰۲۴). برای حذف پیکسل‌های پراکنده و بهبود صحت طبقه‌بندی یک فیلتر اکثریت^۶ نیز روی نقشه طبقه‌بندی‌شده اعمال شد. صحت کلی و ضریب کاپا بعد از اعمال فیلتر، از ماتریس خطا محاسبه و استخراج شد. به‌منظور ارزیابی صحت هر کلاس اطلاعاتی به‌طور جداگانه، صحت کاربر و صحت تولیدکننده برای طبقات مختلف نقشه کاربری/ پوشش اراضی محاسبه شد. مساحت و درصد سطح طبقات مختلف و تغییرات مکانی طبقات در نقشه‌های طبقه‌بندی‌شده حاصل از الگوریتم‌های مختلف نیز مورد محاسبه و ارزیابی قرار گرفت.

^۱ User's Accuracy

^۲ Producer's Accuracy

^۳ Overall Accuracy

^۴ Kappa coefficient

^۵ Confusion Matrix

^۶ Majority Filter

نتایج

در این پژوهش کارآیی سه روش طبقه‌بندی یادگیری ماشین شامل الگوریتم‌های درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان برای طبقه‌بندی کاربری/ پوشش اراضی در مرز جنوبی دریاچه ارومیه مورد ارزیابی قرار گرفت. نتایج حاصل از این الگوریتم‌ها با استفاده از ترکیب باندهای اصلی و شاخص‌های مختلف استخراج شد. نقشه کاربری/ پوشش اراضی منطقه مورد مطالعه تهیه‌شده توسط الگوریتم‌های درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان در شکل ۳ نشان داده شده است. نتایج طبقه‌بندی نشان داد که مساحت کاربری زراعی دیم در الگوریتم درخت طبقه‌بندی و رگرسیون ۳۴/۸۹ درصد (۲۴۲۸۲/۶۹ هکتار)، در الگوریتم جنگل تصادفی ۳۶/۹۰ درصد (۲۵۷۱۶/۹ هکتار) و در الگوریتم ماشین بردار پشتیبان ۳۳/۵۱ درصد (۲۳۳۵۲/۹۵ هکتار) از منطقه مورد مطالعه را به خود اختصاص داده است. مساحت کاربری مرتع در الگوریتم درخت طبقه‌بندی و رگرسیون ۳۱/۲۲ درصد (۲۱۷۵۹/۸۸ هکتار)، در الگوریتم جنگل تصادفی ۲۹/۹۴ درصد (۲۰۸۶۵/۳۸ هکتار) و در الگوریتم ماشین بردار پشتیبان ۲۹/۵۷ درصد (۲۰۶۰۸/۷۲ هکتار) از منطقه مورد مطالعه را به خود اختصاص داده است. مساحت سایر کاربری‌ها به تفکیک توسط الگوریتم‌های مختلف در جدول ۴ آورده شده است. همچنین به‌منظور تسهیل در مقایسه، مساحت کاربری‌های مختلف حاصل از الگوریتم‌های درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان در شکل ۴ با هم نشان داده شده است.

ارزیابی صحت الگوریتم‌های درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان با استفاده از معیارهای صحت کلی، ضریب کاپا، صحت کاربر و صحت تولیدکننده صورت گرفت. بیشترین صحت کلی (۸۹ درصد) و ضریب کاپا (۰/۸۷) مربوط به الگوریتم جنگل تصادفی است. این ضرایب برای الگوریتم‌های دیگر پایین‌تر بود. این ضرایب در الگوریتم درخت طبقه‌بندی و رگرسیون به‌ترتیب برابر ۸۶ درصد و ۰/۸۳ و در الگوریتم ماشین بردار پشتیبان برابر ۸۴ درصد و ۰/۸۰ بود. طبقات اراضی زراعی دیم و مراتع بیشترین درصد پوشش زمین در منطقه مورد پژوهش را شامل می‌شود، بنابراین صحت‌های وزنی مساحت آن‌ها باعث تأثیر نسبتاً بیشتری روی صحت کلی شده است. الگوریتم‌ها برای انواع مختلف کاربری‌ها، عملکردهای متفاوتی داشتند. به‌طور نمونه صحت کاربر و صحت تولیدکننده برای کاربری اراضی زراعی دیم در الگوریتم درخت طبقه‌بندی و رگرسیون به‌ترتیب برابر ۸۸ درصد و ۸۸ درصد است درحالی‌که صحت کاربر و صحت تولیدکننده برای این کاربری در الگوریتم جنگل تصادفی به‌ترتیب ۹۱ درصد و ۹۲ درصد حاصل شده است و در الگوریتم ماشین بردار پشتیبان به‌ترتیب ۸۹ درصد و ۸۵ درصد است.

در الگوریتم درخت طبقه‌بندی و رگرسیون، بیشترین صحت کاربر (۹۴ درصد) برای کاربری باغات و کمترین صحت کاربر (۶۵ درصد) برای کاربری اراضی شور و سنگی است. در الگوریتم جنگل تصادفی، بیشترین صحت کاربر (۹۴ درصد) برای کاربری مناطق انسان‌ساخت و کمترین صحت کاربر (۷۹ درصد) برای کاربری اراضی شور و سنگی است. در الگوریتم ماشین بردار پشتیبان نیز، بیشترین صحت کاربر (۹۲ درصد) برای پهنه‌های آبی و کمترین صحت کاربر (۶۶ درصد) برای اراضی شور و سنگی است.


در الگوریتم درخت طبقه‌بندی و رگرسیون، بیشترین صحت تولیدکننده (۹۷ درصد) برای کاربری باغات و کمترین صحت تولیدکننده (۷۵ درصد) برای مناطق انسان‌ساخت است. در الگوریتم جنگل تصادفی، بیشترین صحت تولیدکننده (۹۳ درصد) برای کاربری‌های پهنه‌های آبی و باغات و کمترین صحت تولیدکننده (۷۷ درصد) برای اراضی زراعی آبی است. در الگوریتم ماشین بردار پشتیبان، بیشترین صحت تولیدکننده (۹۱ درصد) برای باغات و کمترین صحت کاربر (۶۷ درصد) برای اراضی زراعی آبی است. نتایج کامل صحت کاربر و صحت تولیدکننده برای کاربری‌های مختلف در جدول ۴ آورده شده است.

به‌طور کلی بهترین صحت کاربر (۹۴ درصد) و تولیدکننده (۹۷ درصد) مربوط به کاربری باغات با استفاده از الگوریتم درخت طبقه‌بندی و رگرسیون است. کمترین صحت کاربر (۶۵ و ۶۶ درصد) مربوط به اراضی شور و سنگی به‌ترتیب با استفاده از الگوریتم درخت طبقه‌بندی و رگرسیون و ماشین بردار پشتیبان است. کمترین صحت تولیدکننده (۶۷ درصد) مربوط به اراضی زراعی آبی با استفاده از الگوریتم ماشین بردار پشتیبان است.

جدول ۴. ارزیابی صحت نقشه کاربری / پوشش اراضی در الگوریتم‌های مختلف یادگیری ماشین


Table 4. Accuracy assessment of land use/Land cover map in different machine learning algorithms

الگوریتم طبقه‌بندی	کاربری / پوشش اراضی	مساحت (هکتار)	مساحت (درصد)	صحت کاربر	صحت تولیدکننده	صحت کلی	ضریب کاپا
درخت رگ‌سیون	پهنه‌های آبی	۱۱۰۰/۳۸	۱/۵۸	۸۱	۸۷	۸۶	۰/۸۳
	اراضی شور و سنگی	۴۸۱۵/۷۷	۶/۹۱	۶۵	۷۷		
	اراضی زراعی آبی	۷۱۰۱/۹۲	۱۰/۱۹	۷۹	۸۴		
	اراضی زراعی دیم	۲۴۲۸۲/۶۹	۳۴/۸۴	۸۸	۸۸		
	مناطق انسان‌ساخت	۲۶۲۹/۳۸	۳/۷۷	۸۸	۷۵		
	باغات	۸۰۰۵/۰۸	۱۱/۴۹	۹۴	۹۷		
	مراتع	۲۱۷۵۹/۸۸	۳۱/۲۲	۹۲	۸۶		
جنگل تصادفی	پهنه‌های آبی	۱۱۶۲/۰۹	۱/۶۷	۸۸	۹۳	۸۹	۰/۸۷
	اراضی شور و سنگی	۵۳۷۴/۱۷	۷/۷۱	۷۹	۸۸		
	اراضی زراعی آبی	۶۲۹۳/۳۴	۹/۰۳	۸۳	۷۷		
	اراضی زراعی دیم	۲۵۷۱۶/۹۱	۳۶/۹۰	۹۱	۹۲		
	مناطق انسان‌ساخت	۱۷۶۲/۹۷	۲/۵۳	۹۴	۸۰		
	باغات	۸۵۲۰/۲۴	۱۲/۲۳	۹۲	۹۲		
	مراتع	۲۰۸۶۵/۳۸	۲۹/۹۴	۹۳	۹۳		
ماشین بردار پشتیبان	پهنه‌های آبی	۱۰۷۷/۹۹	۱/۵۵	۹۲	۸۰	۸۴	۰/۸۰
	اراضی شور و سنگی	۶۷۰۰/۹۸	۹/۶۱	۶۶	۸۸		
	اراضی زراعی آبی	۶۱۹۴/۰۴	۸/۸۹	۸۴	۶۷		
	اراضی زراعی دیم	۲۳۳۵۲/۹۵	۳۳/۵۱	۸۴	۸۵		
	مناطق انسان‌ساخت	۲۴۲۹/۷۵	۳/۴۹	۸۹	۸۵		
	باغات	۹۳۳۰/۶۶	۱۳/۳۹	۸۹	۹۱		
	مراتع	۲۰۶۰۸/۷۲	۲۹/۵۷	۸۹	۸۷		



شکل ۳. نقشه کاربری / پوشش اراضی حاصل از الگوریتم‌های مختلف یادگیری ماشین

Fig. 3- Land use/ cover map resulting from different machine learning algorithms



شکل ۴. مساحت (هکتار) طبقات مختلف کاربری / پوشش اراضی حاصل از الگوریتم‌های مختلف

Fig. 4- Area (hectares) of different land use/ cover classes resulting from different algorithms

بحث

در این پژوهش داده‌های بدون پوشش ابر سال ۲۰۲۳ ماهواره Sentinel-2 Level 2A و شاخص‌های مختلف، برای تهیه نقشه کاربری/ پوشش زمین در مناطقی از جنوب دریاچه ارومیه (دشت شارویران) در پلت فرم GEE مورد پردازش قرار گرفت و کارایی سه الگوریتم درخت طبقه‌بندی و رگرسیون، جنگل تصادفی و ماشین بردار پشتیبان برای طبقه‌بندی کاربری/ پوشش زمین در یک چشم‌انداز ناهمگن مورد ارزیابی قرار گرفت.

همچنان که از جدول ۴ پیداست، هر کدام از کاربری‌های مرتع و دیم حدود ۲۹ تا ۳۳ درصد (با الگوریتم‌های مختلف) از سطح منطقه مورد مطالعه را تشکیل می‌دهند و مجموعاً با اختصاص بیش از ۶۰ درصد از منطقه به خود، کاربری‌های غالب در منطقه مورد مطالعه هستند. حدود ۲۰ درصد از سطح منطقه هم به کاربری‌های وابسته به منابع آب (باغات و زراعت آبی) اختصاص داده شده است. سطوح زیاد کاربری‌های مرتع، زراعت و باغ در مجموع نشان از رونق فعالیت‌های دامداری، باغداری و زراعت در منطقه مورد مطالعه می‌باشد. اما از سوی دیگر مساحت کم پهنه‌های آبی (کمتر از ۲ درصد سطح منطقه مورد مطالعه) و سطح نسبتاً زیاد مناطق شور (حدود ۷-۹ درصد سطح) نشان از محدودیت منابع آب و مشکلات شوری آب و خاک در منطقه مورد مطالعه می‌باشد. این نوع تجزیه و تحلیل‌های مکانی در مطالعات مشابهی مانند پژوهش پاتیل و پانهالکار (۲۰۲۳) نیز بحث و بررسی شده است. بنابراین توجه به این واقعیت‌ها و وجود باغات و زراعت‌های وابسته به آب در سطح وسیع و از سوی دیگر مشکلات تغییر اقلیم، خشکسالی و روند افزایش خشک شدن دریاچه ارومیه، ضرورت و اهمیت نقشه کاربری اراضی منطقه مورد مطالعه در مدیریت منابع آب و خاک برای رونق کشاورزی و همچنین احیای دریاچه ارومیه در راستای توسعه پایدار بیشتر نمایان و مشخص می‌شود.

اگرچه نقشه‌های دقیق کاربری/ پوشش اراضی حاصل از تصاویر ماهواره‌ای نقش مهمی در ارزیابی‌های منطقه‌ای و ملی ایفا می‌کنند (کنورن و همکاران، ۲۰۰۹)، اما کیفیت داده‌ها، ناهمگنی محیط و نوع الگوریتم، تنها برخی از فاکتورهایی هستند که ممکن است بر دقت تهیه نقشه‌های مذکور تأثیر بگذارند. مشابه با پژوهش یمر و همکاران (۲۰۲۴)، نتایج مطالعه حاضر در به کارگیری الگوریتم‌های مختلف طبقه‌بندی نشان داد که نقشه کاربری/ پوشش طبقه‌بندی شده تحت الگوریتم‌های طبقه‌بندی مختلف، اختلاف قابل توجهی را نشان نداده است. اما در هر صورت بهترین نتیجه مربوط به الگوریتم جنگل تصادفی در مقایسه با الگوریتم‌های درخت طبقه‌بندی و رگرسیون و ماشین بردار پشتیبان است که در راستای نتایج حاصل از پژوهش بیبر و همکاران (۲۰۱۵)، فیری و همکاران (۲۰۲۰) و ژائو و همکاران (۲۰۲۴) است. در پژوهش تالوکدار و همکاران (۲۰۲۰)، او و همکاران (۲۰۲۲) و آلدیانسیاه و ساپوترا (۲۰۲۳) نیز که به طبقه‌بندی کاربری/ پوشش اراضی تصاویر ماهواره‌ای با استفاده از الگوریتم‌های مختلف ماشین یادگیری پرداخته‌اند، الگوریتم جنگل تصادفی در بین الگوریتم‌های مختلف ماشین یادگیری به عنوان بهترین طبقه‌بندی کننده کاربری/ پوشش اراضی معرفی شده است؛ زیرا به پارامترهای تنظیم کمی نیاز دارد، داده‌های با ابعاد بالا را به خوبی مدیریت و الگوهای پیچیده را با دقت بالایی کشف می‌کند (بین و همکاران، ۲۰۲۰).

در پژوهش حاضر شاخص‌های صحت کلی و ضریب کاپا برای الگوریتم جنگل تصادفی به ترتیب ۸۹ درصد و ۰/۸۷ است که از نتایج الگوریتم درخت طبقه‌بندی و رگرسیون (صحت کلی ۸۶ درصد و ضریب کاپا ۰/۸۳) و ماشین بردار پشتیبان (صحت کلی ۸۴ درصد و ضریب کاپا ۰/۸۰) بهتر عمل کرده است اما در هر صورت نسبت به پژوهش ژائو و همکاران (۲۰۲۴) صحت و ضریب کاپای حدود ۷-۱۰ درصد کمتر حاصل شده است. الگوریتم طبقه‌بندی کننده، تعداد طبقات، کیفیت نمونه‌های تعلیمی، پیچیدگی و عدم یکنواختی منطقه مورد مطالعه، نوع داده‌ها و نقشه‌های مرجع تنها چند عاملی هستند که ممکن است بر صحت تأثیر بگذارند (نیگار و همکاران، ۲۰۲۴). کارایی و عملکرد هر الگوریتم نیز به شرایط مختلفی بستگی دارد (سارکر، ۲۰۲۱)، چنانچه در مطالعه حاضر نیز الگوریتم ماشین بردار پشتیبان نسبت به دو الگوریتم دیگر (درخت طبقه‌بندی و رگرسیون و جنگل تصادفی) ضعیف‌تر عمل نمود. استفاده از شاخص‌های مشتق شده از داده‌های سنتینل، صحت کلی و ضریب کاپا را حدود ۵ درصد بهبود بخشید که میزان این بهبود در پژوهش یمر و همکاران (۲۰۲۴) نیز حدود ۷ درصد بوده است. علاوه بر این، در نقشه‌های طبقه‌بندی شده

حاصل از الگوریتم‌ها به صورت مکانی در سطح پیکسل اختلاف وجود داشت؛ اما این اختلاف کمتر از نتایج پژوهش مشابه یمر و همکاران (۲۰۲۴) بود. به عنوان مثال، وقتی نقشه حاصل از جنگل تصادفی و درخت طبقه‌بندی و رگرسیون مقایسه می‌شود، ۸۴ درصد از منطقه دارای وضعیت کاربری/ پوشش یکسان است. در حالی که در پژوهش یمر و همکاران (۲۰۲۴) این رقم معادل ۸۰ درصد بوده است. این نتیجه منعکس‌کننده اختلاف احتمالی است که می‌تواند در نقشه‌های کاربری/ پوشش حاصل از طبقه‌بندی‌کننده‌های مختلف وجود داشته باشد. این تغییرات در طبقه‌بندی پوشش زمین در میان الگوریتم‌ها را می‌توان به تفاوت‌های ذاتی آن‌ها از جمله تفاوت در رویکردهای مدل‌سازی و تنظیمات پارامترها نسبت داد. بنابراین، انتخاب الگوریتم باید به دقت بر اساس اهداف پژوهش و ویژگی‌های منطقه مورد مطالعه صورت گیرد (پاتیل و پانهالکار، ۲۰۲۳).

با توجه به دامنه صحت کلی (۸۹ - ۸۴ درصد) و ضریب کاپا ($0.87 - 0.80$)، می‌توان نتیجه گرفت که هر سه الگوریتم در طبقه‌بندی کاربری/ پوشش اراضی منطقه مورد مطالعه عملکرد خوبی داشتند و کلاس‌های مختلف را در فرآیند طبقه‌بندی در پلت فرم GEE به خوبی ترسیم کردند. اما تجزیه و تحلیل صحت طبقات نشان می‌دهد که طبقه‌بندی‌کننده‌ها از نظر قدرت در تشخیص ویژگی‌های پوشش زمین در هر طبقه متفاوت هستند. الگوریتم جنگل تصادفی مناطق انسان‌ساخت را از سایر کلاس‌ها با دقت بیشتری (صحت کاربر ۹۴ درصد و صحت تولیدکننده ۸۰ درصد) نسبت به الگوریتم‌های ماشین بردار پشتیبان (صحت کاربر ۸۹ درصد و صحت تولیدکننده ۸۵ درصد) و درخت طبقه‌بندی و رگرسیون (صحت کاربر ۸۸ درصد و صحت تولیدکننده ۷۵ درصد) متمایز می‌کند. در پژوهش‌های مختلف (اوما و همکاران، ۲۰۲۲؛ ژائو و همکاران، ۲۰۲۴) نیز الگوریتم جنگل تصادفی مناطق ساخته‌شده را با دقت بالایی متمایز کرده است. همچنین الگوریتم جنگل تصادفی در طبقه اراضی شور و سنگی، دقت بالای تولیدکننده (۸۸ درصد) در ترکیب با دقت کمتر کاربر (۷۹ درصد) نشان‌دهنده برآورد بیش‌ازحد این مناطق است، در حالی که مناطق انسان‌ساخت را کم برآورد کرده است که با توجه به ناهمگنی و تشابه طیفی زیاد مناطق شور و سنگی با مناطق انسان‌ساخت این میزان صحت بسیار مطلوب است. اختلاط طیفی بین مناطق انسان‌ساخت و خاک‌های برهنه در پژوهش رسول و همکاران (۲۰۱۸) نیز به عنوان یک محدودیت شناخته‌شده در سنجش‌ازدور اشاره شده است.

نتیجه‌گیری

این پژوهش با هدف ارزیابی الگوریتم‌های مختلف یادگیری ماشین برای طبقه‌بندی کاربری/ پوشش اراضی در مناطقی از جنوب دریاچه ارومیه (دشت شاوریران) با استفاده از قابلیت‌های بستر GEE و به کارگیری تصاویر Sentinel-2A سال ۲۰۲۳ انجام شد. هفت طبقه کاربری/ پوشش زمین شامل پهنه‌های آبی، اراضی شور و سنگی، اراضی زراعی آبی، اراضی زراعی دیم، مناطق انسان‌ساخت، باغات و مراتع شناسایی شد. این پژوهش سودمندی الگوریتم‌های یادگیری ماشین و تکنیک‌های سنجش‌ازدور برای تهیه نقشه کاربری/ پوشش اراضی در مرز جنوبی دریاچه ارومیه را نشان داد. با این حال، محدودیت‌ها و چالش‌های شناسایی‌شده در این پژوهش نیاز به تکنیک‌های پیشرفته‌تر برای تهیه نقشه کاربری/ پوشش اراضی در آینده را برجسته می‌کند. با توجه به تفاوت قابل توجه در عملکرد طبقه‌بندی‌کننده‌ها و احتمال خطا در نقشه‌های کاربری/ پوشش، برای کاربردهای حساس مانند ارزیابی تخریب منابع طبیعی، ارزیابی الگوی مصرف آب و آمایش سرزمین، ارزیابی دقیق طبقه‌بندی‌کننده‌ها به شدت توصیه می‌شود. کاربران همچنین باید از شاخص‌های سنجش‌ازدوری و مجموعه داده‌های جانبی و کمکی مانند متغیرهای بوم‌شناختی و اجتماعی-اقتصادی در طبقه‌بندی کاربری/ پوشش اراضی استفاده کنند. چراکه درک پارامترهایی که بر صحت الگوریتم تأثیر می‌گذارند؛ می‌تواند به بهبود نتایج طبقه‌بندی کمک کند. بنابراین، توصیه می‌شود که در پژوهش‌های آینده ضمن به کارگیری گوگل ارث انجین که در حال حاضر نوآورانه‌ترین پلتفرم منبع باز بین‌المللی برای تجزیه و تحلیل سطح پیشرفته داده‌های سنجش‌ازدوری به‌ویژه در سطح وسیع جغرافیایی است، تکنیک‌های پیشرفته‌تر یادگیری ماشین و هوش مصنوعی مانند یادگیری عمیق برای بهبود صحت طبقه‌بندی بررسی شود. اهمیت تهیه نقشه کاربری/ پوشش اراضی در توسعه پایدار قابل انکار نیست؛ بنابراین چنین مطالعاتی نه تنها دانش ما را در مورد کاربری/ پوشش اراضی در منطقه بهبود می‌بخشد، در مدیریت اراضی در راستای احیای دریاچه ارومیه و استراتژی‌های برنامه‌ریزی برای توسعه پایدار نقش مؤثری ایفا می‌کند.

منابع

محمودی، محمدعلی، مومینی، سهیلا و داوری، مسعود. (۱۳۹۷). کاربرد ماشین‌های بردار پشتیبان برای تهیه نقشه پوشش / کاربری اراضی از تصاویر ماهواره لندست. آب و خاک. ۳۳(۶)، ۱۱۹۰ – ۱۱۷۹.

<https://doi.org/10.22067/jsw.v32i6.72967>

References

- Aldiansyah, S., & Saputra, R. A. (2023). Comparison of machine learning algorithms for land use and land cover analysis using Google Earth engine (Case study: Wanggu watershed). *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 19(2), 197-210. <https://doi.org/10.30536/j.ijreses.2022.v19.a3803>.
- Ali, S.A., Parvin, F., Pham, Q.B., Khedher, K.M., Dehbozorgi, M., Rabby, Y.W., Anh, D.T. & Nguyen, D.H. (2022). An ensemble random forest tree with SVM, ANN, NBT, and LMT for landslide susceptibility mapping in the Rangit River watershed, India. *Natural Hazards*. 113(3), 1601–1633. <https://doi.org/10.1007/s11069-022-05360-5>.
- Amani, M., Mahdavi, S., Afshar, M., Brisco, B., Huang, W., Mirzadeh, S.M.J., White, L., Banks, S., Montgomery, J. & Hopkinson, C. (2019). Canadian Wetland Inventory Using Google Earth Engine: The First Map and Preliminary Results, *Remote Sensing*, 11(7), 842. <https://doi.org/10.3390/rs11070842>.
- Amin, G., Imtiaz, I., Haroon, E., Saqib, N. U., Shahzad, M. I., & Nazeer, M. (2024). Assessment of machine learning algorithms for land cover classification in a complex mountainous landscape. *Journal of Geovisualization and Spatial Analysis*, 8(2), 34. <https://doi.org/10.1007/s41651-024-00195-z>.
- Beyer, F., Jarmer, T. and Siegmann, B. (2015). Identification of agricultural crop types using multitemporal rapideye data. *Photogrammetrie-Fernerkundung-Geoinformation*, 1: 21-32. <https://doi.org/10.1127/pfg/2015/0249>.
- Biswas, J., Jobaer, M.A., Haque, S.F., Islam Shozib, M.S. & Limon, Z.A. (2023). Mapping and monitoring land use land cover dynamics employing Google Earth Engine and machine learning algorithms on Chattogram, Bangladesh. *Heliyon*. 9(11), e21245. [10.1016/j.heliyon.2023.e21245](https://doi.org/10.1016/j.heliyon.2023.e21245).
- Boothroyd, R.J., Williams, R.D., Hoey, T.B., Barrett, B. & Prasajo, O.A. (2021). Applications of Google Earth Engine in fluvial geomorphology for detecting river channel change. *Wiley Interdisciplinary Reviews Water*. 8(1), e21496. <https://doi.org/10.1002/wat2.1496>.
- Bouaziz, M., Eisold, S. & Guermazi, E. (2017). Semiautomatic approach for land cover classification: a remote sensing study for arid climate in southeastern Tunisia. *Euro-Mediterranean Journal of Environmental Integration*. 2, 1–7. <https://doi.org/10.1007/s41207-017-0036-7>.
- Breiman, L. (2017). *Classification and regression trees*. Routledge, 368p.
- Breiman, L., (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>.
- Chen, B., Xiao, X., Li, X., Pan, L., Doughty, R., Ma, J., Dong, J., Qin, Y., Zhao, B., Wu, Z., Sun, R., Lan, G., Xie, G., Clinton, N. & Giri, C. (2017). A mangrove forest map of China in 2015: Analysis of time series Landsat 7/8 and Sentinel-1A imagery in Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 104-120. <https://doi.org/10.1016/j.isprsjprs.2017.07.011>.
- Clerici, N., Valbuena Calderon, C.A. & Posada, J.M. (2017) Fusion of sentinel-1A and sentinel-2A data for land cover mapping: A case study in the lower Magdalena region, Colombia. *Journal of Maps*. 13(2), 718–726. <https://doi.org/10.1080/17445647.2017.1372316>.
- Cracknell, M.J. & Reading, A.M. (2014). Geological mapping using remote sensing data: A comparison

- of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Computers and Geosciences*. 63, 22-33. <https://doi.org/10.1016/j.cageo.2013.10.008>.
- Ge, G., Shi, Z., Zhu, Y., Yang, X. & Hao, Y. (2020). Land use/cover classification in an arid desert-oasis mosaic landscape of China using remote sensed imagery: Performance assessment of four machine learning algorithms. *Global Ecology and Conservation*. 22, e00971. <https://doi.org/10.1016/j.gecco.2020.e00971>.
- Ghorbanian, A., Kakooei, M., Amani, M., Mahdavi, S., Mohammadzadeh, A. & Hasanlou, M. (2020). Improved Land Cover Map of Iran Using Sentinel Imagery within Google Earth Engine and a Novel Automatic Workflow for Land Cover Classification Using Migrated Training Samples. *ISPRS Journal of Photogrammetry and Remote Sensing*. 167, 276-288. <https://doi.org/10.1016/j.isprsjprs.2020.07.013>.
- Ghosh, S., Kumar, D. & Kumari, R. (2022). Cloud-based large-scale data retrieval, mapping, and analysis for land monitoring applications with google earth engine (GEE). *Environmental Challenges*. 9, 100605. <https://doi.org/10.1016/j.envc.2022.100605>.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*. 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>.
- Grinand, C., Vieilledent, G., Razafimbelo, T., Rakotoarijaona, J. R., Nourtier, M. & Bernoux, M. (2020). Landscape-scale spatial modelling of deforestation, land degradation and regeneration using machine learning tools. *Land Degradation and Development*. 31(13), 1699-1712. <https://doi.org/10.1002/ldr.3526>.
- Gumma, M.K., Thenkabail, P.S., Teluguntla, P.G., Oliphant, A., Xiong, J., Giri, C., Whitbread, A.M., Dixit, S. & Whitbread, A.M. (2020). Agricultural Cropland Extent and Areas of South Asia Derived Using Landsat Satellite 30-m Time-series Big-data Using Random Forest Machine Learning Algorithms on the Google Earth Engine Cloud. *GIScience & Remote Sensing*. 57(3), 302-322. <https://doi.org/10.1080/15481603.2019.1690780>.
- Hartfield, K.A., Landau, K.I. & Leeuwen, W.J.D.v. (2011). Fusion of High Resolution Aerial Multispectral and LiDAR Data: Land Cover in the Context of Urban Mosquito Habitat. *Remote Sensing*. 3(11), 2364-2383. <https://doi.org/10.3390/rs3112364>.
- Hashim, F., Dibs, H. & Jaber, H.S. (2021). Applying Support Vector Machine Algorithm on Multispectral Remotely sensed satellite image for Geospatial Analysis. *Journal of Physics: Conference Series*, 1963. <https://doi.org/10.1088/1742-6596/1963/1/012110>.
- Jain, M., Mondal, P., Galford, G.L., Fiske, G. & Fries, R.S. (2017). An approach to map winter cropped area of smallholder farms across large scales using MODIS imagery. *Remote Sensing Journal*. 9(6), 566-566. <https://doi.org/10.3390/rs9060566>.
- Knorn, J., Rabe, A., Radeloff, C.V., Kuemmerle, T., Kozak, J. & Hostert, P., 2009. Land cover mapping of large areas using chain classification of neighboring Landsat satellite images. *Remote Sensing of Environment*, 113: 957- 964. <https://doi.org/10.1016/j.rse.2009.01.010>.
- Lawer, E.A. (2024). An evaluation of single and multi-date Landsat image classifications using random forest algorithm in a semi-arid savanna of Ghana, West Africa, *Scientific African*, 26, e02434. <https://doi.org/10.1016/j.sciaf.2024.e02434>.
- Li, Z., Wu, W., Liu, X., Fath, B.D., Sun, H., Liu, X., Xiao, X. & Cao, J. (2017). Land use/cover change and regional climate change in an arid grassland ecosystem of Inner Mongolia, China. *Ecological Modelling*. 353, 86-94. <https://doi.org/10.1016/j.ecolmodel.2016.07.019>.
- Mahdianpari, M., Brisco, B., Granger, J.E., Mohammadimanesh, F., Salehi, B., Banks, S., Weng, Q.,

- Bourgeau-Chavez, L. & Weng, Q. (2020). The Second Generation Canadian Wetland Inventory Map at 10 Meters Resolution Using Google Earth Engine. *Canadian Journal of Remote Sensing*. 46(3), 360–375. <https://doi.org/10.1080/07038992.2020.1802584>.
- Mahmoodi, M. A., Momeni, S., & Davari, M. (2019). Application of Support Vector Machines for Land Use and Land Cover Classification from Landsat ETM Imagery. *Water and Soil*, 32(6), 1179-1190. <https://doi.org/10.22067/jsw.v32i6.72967>. (In Persian)
- Malarvizhi, K., Kumar, S.V. & Porchelvan, P. (2016). Use of high resolution Google Earth satellite imagery in land use map preparation for urban related applications. *Procedia Technology Journal*, 24, 1835-1842. <https://doi.org/10.1016/j.protcy.2016.05.231>.
- Modica, G., Messina, G., De Luca, G., Fiozzo, V. & Pratico, S. (2020). Monitoring the vegetation vigor in heterogeneous citrus and olive orchards. A multiscale object-based approach to extract trees' crowns from UAV multispectral imagery. *Computers and Electronics in Agriculture*. 175, 105500. <https://doi.org/10.1016/j.compag.2020.105500>.
- Moharana, S., Kambhammettu, B.V.N.P., Chintala, S., Rani, A.S. & Avtar, R. (2021). Spatial distribution of inter-and intra-crop variability using time-weighted dynamic time warping analysis from Sentinel-1 datasets. *Remote Sensing Applications: Society and Environment*. 24, 100630. <https://doi.org/10.1016/j.rsase.2021.100630>.
- Nigar, A., Li, Y., Jat Baloch, M. Y., Alrefaei, A. F., & Almutairi, M. H. (2024). Comparison of machine and deep learning algorithms using Google Earth Engine and Python for land classifications. *Frontiers in Environmental Science*, 12, 1378443. <https://doi.org/10.3389/fenvs.2024.1378443>.
- Oliphant, A.J., Thenkabail, P.S., Teluguntla, P., Xiong, J., Gumma, M.K., Congalton, R.G. & Yadav, K. (2019). Mapping Cropland Extent of Southeast and Northeast Asia Using Multi-year Time-series Landsat 30-m Data Using a Random Forest Classifier on the Google Earth Engine Cloud. *International Journal of Applied Earth Observation and Geoinformation*. 81, 110–124. <https://doi.org/10.1016/j.jag.2018.11.014>.
- Oo, T. K., Arunrat, N., Sereenonchai, S., Ussawarujikulchai, A., Chareonwong, U., & Nutmagul, W. (2022). Comparing four machine learning algorithms for land cover classification in gold mining: A case study of Kyaukpahto Gold Mine, Northern Myanmar. *Sustainability*, 14(17), 10754. <https://doi.org/10.3390/su141710754>.
- 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. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3, 681–689. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-681-2022>.
- Pande, C.B., Diwate, P., Orimoloye, I.R., Sidek, L.M., Pratap Mishra, A., Moharir, K.N., Pal, S.C., Alshehri, F. and Tolche, A.D. (2024). Impact of land use/land cover changes on evapotranspiration and model accuracy using Google Earth engine and classification and regression tree modeling. *Geomatics, Natural Hazards and Risk*. 15(1). 2290350. <https://doi.org/10.1080/19475705.2023.2290350>.
- 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 International*, 36(9), 957–988. <https://doi.org/10.1080/10106049.2019.1629647>.
- Patil, A. & Panhalkar, S. (2023). Comparative analysis of machine learning algorithms for land use and land cover classification using google earth engine platform. *Journal of Geomatics*. 17(2), 226-233. <https://doi.org/10.58825/jog.2023.17.2.96>.
- Pecina, M.V., Bergamo, T.F., Ward, R.D., Joyce, C.B. & Sepp, K. (2021). A novel UAV-based approach for biomass prediction and grassland structure assessment in coastal meadows. *Ecological*

- Indicators. 122, 107227. <https://doi.org/10.1016/j.ecolind.2020.107227>.
- Phalke, A.R., Ozdogan, M., Thenkabail, P.S., Erickson, T., Gorelick, N., Yadav, K. & Congalton, R.G. (2020). Mapping croplands of Europe, Middle East, Russia, and Central Asia using Landsat, random Forest, and Google earth engine. *ISPRS Journal of Photogrammetry and Remote Sensing*. 167, 104–122. <https://doi.org/10.1016/j.isprsjprs.2020.06.022>.
- Pham, Q. B., Ali, S.A., Parvin, F., Van On, V., Sidek, L.M., Durin, B., ... & Minh, N.N. (2024). Multi-spectral remote sensing and GIS-based analysis for decadal land use land cover changes and future prediction using random forest tree and artificial neural network. *Advances in space research*, 74(1), 17-47. <https://doi.org/10.1016/j.asr.2024.03.027>.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V.R., Murayama, Y. & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*. 12(14), 2291-2291. <https://doi.org/10.3390/rs12142291>.
- Qu, L.A., Li, M., Chen, Z. & Zhi, J. (2021). A modified self-adaptive method for mapping annual 30-m land use/land cover using Google Earth engine: a case study of Yangtze River Delta. *Chinese Geographical Science*. 31, 782–794. <https://doi.org/10.1007/s11769-021-1226-4>.
- Rasool, R., Fayaz, A., ul Shafiq, M., Singh, H. & Ahmed, P. (2021). Land use land cover change in Kashmir Himalaya: Linking remote sensing with an indicator based DPSIR approach. *Ecological Indicators*. 125, 107447. <https://doi.org/10.1016/j.ecolind.2021.107447>.
- Rasul, A., Balzter, H., Ibrahim, G., Hameed, H., Wheeler, J., Adamu, B., Ibrahim, S.A. & Najmaddin, P. (2018). Applying built-up and bare-soil indices from Landsat 8 to cities in dry climates. *Land Journal*, 7(3): 81-81. <https://doi.org/10.3390/land7030081>.
- Revel, C., Lonjou, V., Marcq, S., Desjardins, C., Fougny, B., Coppolani-Delle Luche, C., Guillemint, N., Lacamp, A., Lourme, E., Miquel, Ch., & Lenot, X. (2019). Sentinel-2A and 2B absolute calibration monitoring. *European Journal of Remote Sensing*, 52(1), 122–137. <https://doi.org/10.1080/22797254.2018.1562311>.
- Roy, P.S., Ramachandran, R.M., Paul, O., Thakur, P.K., Ravan, Sh., Behera, M.D., Sarangi, Ch. & Kanawade, V.P. (2022). Anthropogenic Land Use and Land Cover Changes—A Review on Its Environmental Consequences and Climate Change. *Journal of the Indian Society of Remote Sensing*. 50, 1615–1640. <https://doi.org/10.1007/s12524-022-01569-w>.
- Rujoiu-Mare, M.R. & Mihai, B.A. (2016). Mapping land cover using remote sensing data and GIS techniques: A case study of Prahova Subcarpathians. *Procedia Environmental Sciences*. 32, 244-255. <https://doi.org/10.1016/j.proenv.2016.03.029>.
- Saha, S., Saha, M., Mukherjee, K., Arabameri, A., Ngo, P.T.T., Paul, G.C. (2020). Predicting the deforestation probability using the binary logistic regression, random forest, ensemble rotational forest, REPTree: A case study at the Gumani River Basin, India. *Science of the Total Environment*. 730, 139197. <https://doi.org/10.1016/j.scitotenv.2020.139197>.
- Sarker, I.H., (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2, 160. <https://doi.org/10.1007/s42979-021-00592-x>.
- Schulz, D., Yin, H., Tischbein, B., Verleysdonk, S., Adamou, R. & Kumar, N. (2021). Land use mapping using Sentinel-1 and Sentinel-2 time series in a heterogeneous landscape in Niger, Sahel. *ISPRS Journal of Photogrammetry and Remote Sensing*. 178, 97-111. <https://doi.org/10.1016/j.isprsjprs.2021.06.005>.
- Serra, P., Vera, A., Tulla, A.F. & Salvati, L. (2014). Beyond Urban–rural Dichotomy: Exploring Socioeconomic and Land-use Processes of Change in Spain (1991–2011). *Applied Geography*. 55, 71–81. <https://doi.org/10.1016/j.apgeog.2014.09.005>.
- Shafizadeh-Moghadam, H., Khazaei, M., Alavipanah, S.K., & Weng, Q. (2021). Google Earth Engine

- for large-scale land use and land cover mapping: an object-based classification approach using spectral, textural and topographical factors, *GIScience & Remote Sensing*, 58(6), 914–928. <https://doi.org/10.1080/15481603.2021.1947623>.
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y-A., & Rahman, A. (2020). Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. *Remote Sensing*, 12(7), 1135. <https://doi.org/10.3390/rs12071135>.
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S. & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152-170. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>.
- Tan, J., Zuo, J., Xie, X., Ding, M., Xu, Z. & Zhou, F. (2021). MLAs land cover mapping performance across varying geomorphology with Landsat OLI-8 and minimum human intervention. *Ecological Informatics*, 61, 101227. <https://doi.org/10.1016/j.ecoinf.2021.101227>.
- Tian, S., Zhang, X., Tian, J. & Sun, Q. (2016). Random forest classification of wetland land covers from multi-sensor data in the arid region of Xinjiang. China. *Remote Sensing*, 8(11), 954-954. <https://doi.org/10.3390/rs8110954>.
- Wang, J., Chen, J., Wen, Y., Fan, W., Liu, Q. & Tarolli, P. (2021). Monitoring the coastal wetlands dynamics in Northeast Italy from 1984 to 2016. *Ecological Indicators*, 129, 107906. <https://doi.org/10.1016/j.ecolind.2021.107906>.
- Wingate, V.R., Phinn, S.R., Kuhn, N., Bloemertz, L. & Dhanjal-Adams, K.L. (2016) Mapping decadal land cover changes in the woodlands of north eastern Namibia from 1975 to 2014 using the Landsat satellite archived data. *Remote Sensing*, 8(8), 681-681. <https://doi.org/10.3390/rs8080681>.
- Yimer, S. M., Bouanani, A., Kumar, N., Tischbein, B. & Borgemeister, C. (2024). Comparison of different machine-learning algorithms for land use land cover mapping in a heterogenous landscape over the Eastern Nile river basin, Ethiopia. *Advances in Space Research*, 74(5), 2180-2199. <https://doi.org/10.1016/j.asr.2024.06.010>.
- Yin, H., Brandao, A., Buchner, J., Helmers, D., Iuliano, B.G., Kimambo, N.E., Lewinska, K.E., Razenkova, E., Rizayeva, A., Rogova, N., Spawn, S.A., Xie, Y. & Radeloff, V.C. (2020). Monitoring cropland abandonment with Landsat time series. *Remote Sensing of Environment Journal*, 246, 111873. <https://doi.org/10.1016/j.rse.2020.111873>.
- Zhang, C., Di, L., Hao, P., Yang, Z., Lin, L., Zhao, H. & Guo, L. (2021). Rapid in-season mapping of corn and soybeans using machine-learned trusted pixels from Cropland Data Layer. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102374. <https://doi.org/10.1016/j.jag.2021.102374>.
- Zhang, Y., Balzter, H., Liu, B. & Chen, Y. (2017). Analyzing the impacts of urbanization and seasonal variation on land surface temperature based on subpixel fractional covers using Landsat images, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(4), 1344–1356. <https://doi.org/10.1109/JSTARS.2016.2608390>.
- 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., & Hatamleh, W. A. (2024). Comparison of three machine learning algorithms using google earth engine for land use land cover classification. *Rangeland ecology & management*, 92, 129-137. <https://doi.org/10.1016/j.rama.2023.10.007>.
- Zurqani, H.A., Post, C.J., Mikhailova, E.A., Schlautman, M.A. & Sharp, J.L. (2018). Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International journal of applied earth observation and Geoinformation*, 69, 175-185. <https://doi.org/10.1016/j.jag.2017.12.006>.