



Assessing the Influence of Land Use/Land Cover Changes on Land Surface Temperature by Satellite Data Imagery and Supervised Classification Algorithm

Samira Hemmati ¹ | Kamran Moravej ² | Ahmad Golchin ³ | Mohammad Sadegh Askari ⁴

1. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: s.hemmati@znu.ac.ir

2. Corresponding Author, Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: kmoravej@znu.ac.ir

3. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: agolchin2011@yahoo.com

4. Department of Soil Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail: askari@znu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: June. 30, 2024

Revised: Oct. 12, 2024

Accepted: Nov. 2, 2024

Published online: Feb. 2025

Keywords:

Google Earth Engine,
LST,
LULC Classification,
Machine Learning Algorithm,
Satellite Imagery.

ABSTRACT

This research aims to evaluate the abilities of four non-parametric machine learning algorithms, including Support Vector Machine (SVM), Random Forest (RF), Classification and Regression Tree (CART), and Minimum Distance (MD), to produce LULC maps. Utilizing multi-temporal data from Sentinel-2 and Landsat-8 sensors, the investigation was conducted within the Google Earth Engine (GEE) framework. The outcomes underscore the superior reliability of Sentinel-2 data compared to Landsat-8 data across all classifiers. The SVM classifier, with an overall accuracy of 92.9% and 92.2% for Sentinel-2 and Landsat-8 images, respectively, provided the best performance compared to other classifiers. The results pertaining to the identification of LULC alterations during the study duration, employing the optimal classifier (SVM), revealed an expansion in the expanse of olive groves, rice paddies, and built-up areas, alongside a contraction in water bodies and barren lands. The evaluation of the implications of LULC variations on Land Surface Temperature (LST) manifested that augmenting vegetation cover corresponded with diminished LST values within the study area. This shift led to LST values ranging from 36.48 to 21.8 Celsius in 2019, which evolved to 33.84 and 19.67 Celsius in 2023. The research concludes that the combination of high-spatial-resolution satellite data and the SVM algorithm presents an accurate and efficient approach for generating LULC maps and assessing environmental transformations.

Cite this article: Hemmati, S., Moravej, K., Golchin, A., & Sadegh Askari, M. (2025) Assessing the Influence of Land Use/Land Cover Changes on Land Surface Temperature by Satellite Data Imagery and Supervised Classification Algorithm, *Iranian Journal of Soil and Water Research*, 55 (12), 2443-2466. <https://doi.org/10.22059/ijswr.2024.378766.669744>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2024.378766.669744>





EXTENDED ABSTRACT

Introduction

The significance of comprehensive Land Use and Land Cover (LULC) mapping is indispensable in environmental monitoring, urban planning, and management of natural resources. The integration of cutting-edge satellite imagery and sophisticated machine-learning algorithms has substantially enhanced the precision and practicality of LULC mapping.

Purpose

In this study, advanced image processing and satellite data analysis methods are used to produce high-precision LULC maps, enabling a more comprehensive investigation of the influence of LULC changes on LST. The principal aims of this study encompass the following:

1. Identify optimal satellite imagery sources and machine learning algorithms for LULC map development.
2. Assessment of temporal LULC changes within the study duration.
3. Examination of the impact of LULC changes on LST.

Research method

To produce image collections and process time-series data for this investigation, the GEE cloud computing platform was utilized. All atmospherically corrected surface reflectance products from Landsat-8 and Sentinel-2 in the research area were employed as the main input for spectral-temporal feature extraction and classification. Then, necessary filters and corrections, such as cloud cover removal, were applied.

Then we evaluated the abilities of four non-parametric machine learning algorithms, including Support Vector Machine (SVM), Random Forest (RF), Classification and Regression Tree (CART), and Minimum Distance (MD), to produce LULC maps.

Results

The outcomes underscore the superior reliability of Sentinel-2 data compared to Landsat-8 data across all classifiers. The SVM classifier, with an overall accuracy of 92.9% and 92.2% for Sentinel-2 and Landsat-8 images, respectively, provided the best performance compared to other classifiers. The results of the identification of LULC alterations during the study duration, employing the optimal classifier (SVM), revealed an expansion in the expanse of olive groves, rice paddies, and built-up areas, alongside a contraction in water bodies and barren lands. The evaluation of the implications of LULC variations on Land Surface Temperature (LST) manifested that augmenting vegetation cover corresponded with diminished LST values within the study area. This shift led to LST values ranging from 36.48 to 21.8 Celsius in 2019, which evolved to 33.84 and 19.67 Celsius in 2023.

Conclusion

The research concludes that classifying land use and land cover (LULC) using high-resolution imagery and the SVM algorithm in the Google Earth Engine platform is an accurate and efficient method for assessing changes in land use and land cover over different periods. Therefore, this method can be used as a useful tool in natural and urban resource planning and management, such as land use planning and water and soil resource management. The ability to analyze changes in land use and land cover over time provides additional management capabilities, and this information can contribute to better and optimal decision-making in natural resource management and regional planning. Using this method, it is possible to monitor and analyze changes in various land use types accurately and comprehensively across different periods.

Author Contributions

Conceptualization, K.M. and A.G.; Methodology, K.M.; software, S.H.; validation, S.H., M.S.A. and K.M.; Formal Analysis, S.H.; Investigation, S.H.; Resources, S.H.; Data Curation, A.G.; Writing—Original Draft Preparation, S.H.; Writing—Review and Editing, A.G.; Visualization, S.H.; Supervision, K.M.; Project Administration, A.G.; Funding Acquisition, S.H. All authors have read and agreed to the published version of the manuscript.”

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors would like to thank all participants of the present study.

Ethical considerations

The study was approved by the Ethics Committee of the University of Zanjan (Ethical code: 14359/S. S, 2022/9/12). The authors avoided data fabrication, falsification, plagiarism, and misconduct

ارزیابی تأثیر تغییرات کاربری و پوشش زمین بر دمای سطح زمین با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های طبقه‌بندی نظارت شده

سمیرا همتی^۱ | کامران مروج^۲ | احمد گلچین^۳ | امجدصادق عسکری^۴۱. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: s.hemmati@znu.ac.ir۲. نویسنده مسئول، گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: kmoravej@znu.ac.ir۳. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: agolchin2011@yahoo.com۴. گروه خاکشناسی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران. رایانامه: askari@znu.ac.ir

| اطلاعات مقاله | چکیده |
|----------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| نوع مقاله: مقاله پژوهشی | این مطالعه با هدف اصلی مقایسه توانایی چهار الگوریتم یادگیری ماشین غیرپارامتری از جمله ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF)، درخت طبقه‌بندی و رگرسیون (CART) و حداقل فاصله (MD) برای تولید نقشه‌های کاربری و پوشش زمین انجام شده است. داده‌های چند زمانی سنجنده‌های سنتینل ۲ و لندست ۸، در پلتفرم گوگل ارث انجین (GEE) استفاده شد. نتایج نشان داد که طبقه‌بندی تصاویر سنتینل ۲ با دقت و ضریب کاپای بالاتر برای همه طبقه‌بندی‌کننده‌ها، دقیق‌تر از طبقه‌بندی تصاویر لندست ۸ است. طبقه‌بندی‌کننده SVM با میانگین دقت کلی ۹۲٫۹ و ۹۲٫۲ درصد به ترتیب برای تصاویر سنتینل ۲ و لندست ۸ بهترین عملکرد را نسبت به سایر طبقه‌بندی‌کننده‌ها ارائه داد. نتایج شناسایی تغییرات LULC در طول دوره مطالعه با استفاده از مناسب‌ترین طبقه‌بندی‌کننده نشان داد مساحت کاربری‌های باغ زیتون، شالیزار و مناطق شهری در دوره مورد مطالعه افزایش یافت. در مقابل، مساحت گستره‌های آبی و زمین بایر کاهش یافته است. بررسی تأثیر تغییرات کاربری و پوشش زمین بر دمای سطح زمین بیان می‌کند که با افزایش سطوح پوشش گیاهی در منطقه، مقدار دمای سطح زمین (LST) از حداکثر و حداقل ۳۶٫۴۸ و ۲۱٫۸ درجه سلسیوس در سال ۲۰۱۹ به ۳۳٫۸۴ و ۱۹٫۶۷ درجه سلسیوس در سال ۲۰۲۳ رسیده است. استفاده از داده‌های ماهواره‌ای با وضوح فضایی بالا و الگوریتم SVM، می‌تواند به عنوان یک روش دقیق و کارآمد برای تهیه نقشه کاربری و پوشش زمین و ارزیابی تغییرات محیطی معرفی شود. بنابراین می‌توان از آن به عنوان یک داده ارزشمند برای تصمیم‌گیری‌های مرتبط با مدیریت منابع طبیعی و برنامه‌ریزی شهری در مناطق مشابه استفاده نمود. |
| تاریخ دریافت: ۱۴۰۳/۴/۱۰ | |
| تاریخ بازنگری: ۱۴۰۳/۷/۲۱ | |
| تاریخ پذیرش: ۱۴۰۳/۸/۱۲ | |
| تاریخ انتشار: اسفند ۱۴۰۳ | |
| واژه‌های کلیدی: تصاویر ماهواره‌ای، دمای سطح زمین، یادگیری ماشین، کاربری و پوشش زمین، گوگل ارث انجین. | |

استاد: همتی؛ سمیرا، مروج؛ کامران، گلچین؛ احمد، عسکری؛ محمدصادق، (۱۴۰۳) ارزیابی تأثیر تغییرات کاربری و پوشش زمین بر دمای سطح زمین با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های طبقه‌بندی نظارت شده، *مجله تحقیقات آب و خاک ایران*، ۵۵ (۱۲)، ۲۴۶۶-۲۴۴۳.

<https://doi.org/10.22059/ijswr.2024.378766.669744>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2024.378766.669744>

مقدمه

تغییر کاربری و پوشش زمین^۱ یک عامل مهم در تغییرات محیطی است و ارزیابی آن جهت درک چگونگی توسعه منطقه‌ای و مدیریت کاربری زمین برای دستیابی به توسعه پایدار بسیار مهم است (Daba and You, 2022; Das and Sarkar, 2019). ارزیابی تغییرات کاربری و پوشش زمین در مقیاس‌های مختلف به مطالعات آینده درباره انواع پدیده‌های جهانی مانند خشکسالی، سیل، فرسایش، مهاجرت و تغییرات آب و هوایی کمک خواهد کرد (Khan et al., 2020; Lukas et al., 2023). ماهیت پویای تغییرات کاربری و پوشش زمین مستلزم ارزیابی، تحلیل و نظارت مستمر با استفاده از داده‌های اجتماعی-اقتصادی و جغرافیایی برای دستیابی به نتایج یکپارچه و دقیق است (da Cunha et al., 2021; Yifru et al., 2021). نقشه‌های LULC داده‌های مهمی برای انواع مطالعات علمی شامل اثرات تغییرات آب و هوا بر جریان رودخانه و بودجه آب (Sridhar et al., 2019)، ژئومورفولوژی (Sujatha et al., 2018)، مدیریت آب‌های زیرزمینی (Xiao et al., 2022)، مدیریت دانش اجتماعی طبیعی است (Loukika et al., 2021). روش‌های مختلفی برای تولید نقشه‌های LULC و ردیابی تغییرات در طول زمان وجود دارد که در بین آن‌ها تصویربرداری سنجش از دور^۲ رایج‌ترین روش است (Phan et al., 2020; Loukika et al., 2022).

نقشه‌های کاربری و پوشش اراضی با استفاده از تکنیک‌های سنجش از دور و بررسی روابط بین زمین، خاک و گیاه تهیه می‌شوند. از این نقشه‌ها برای تعیین مکان‌های مناسب برای ساخت سازه‌ها، اقدامات حفاظت از خاک و آب، محاسبات رواناب، برنامه‌ریزی آبیاری و مدیریت کشاورزی، تجزیه و تحلیل نگرانی‌های اجتماعی-اکولوژیکی، کنترل سیل، و مدیریت کلی حوزه آبخیز استفاده می‌شود (Rana et al., 2020; Hassan et al., 2016).

طبقه‌بندی اساس تحقیق در مورد تشخیص تغییرات کاربری و پوشش زمین است (Gibril et al., 2018). امروزه سامانه‌های مدرن (مانند ArcGIS Pro و Google Earth Engine) ما را قادر می‌سازد تا نقشه‌های LULC دقیق‌تری را با استفاده از الگوریتم‌های مختلف طبقه‌بندی ایجاد کنیم (Liping et al., 2018; Basheer et al., 2022). تجزیه و تحلیل انواع مختلف LULC، با استفاده از رویکردهای یادگیری ماشین^۳، می‌تواند در یک پلتفرم مکانی مانند گوگل ارث انجین^۴، توسط مجموعه‌ای از داده‌های سنجش از راه دور انجام شود (Szostak et al., 2021). این تحلیل‌ها می‌توانند به ما در درک روند تغییرات LULC کمک کنند.

گوگل ارث انجین یک پلتفرم مبتنی بر ابر است که با استفاده از خدمات رایانه‌ای با کارایی بالا، داده‌های سنجش از دور از منابع مختلف (مانند تصاویر ماهواره‌ای) را ترکیب نموده و پردازش تصاویر ماهواره‌ای را سریع‌تر و ساده‌تر می‌کند (Tamiminia et al., 2020; Kolloi et al., 2020). GEE حاوی تصاویر ماهواره‌ای از منابع مختلف از جمله لندست^۵، سنتینل^۶، مادیس^۷، و بسیاری دیگر از منابع و مجموعه داده‌هایی است که به صورت رایگان در دسترس هستند (Sidhu et al., 2018; Gorelick et al., 2017). موتور گوگل ارث دسترسی به اکثریت داده‌های سنجش از دور چندزمانی، عمومی و آزاد را فراهم می‌کند و قدرت محاسباتی مبتنی بر ابر رایگان را برای تجزیه و تحلیل داده‌های مکانی ارائه می‌دهد (Wang et al., 2019; Teluguntla et al., 2018).

اخیراً برای شناسایی انواع پوشش زمین، طبقه‌بندی تصاویر ماهواره‌ای در پلتفرم GEE توسط طبقه‌بندی‌کننده‌های یادگیری ماشین غیرپارامتری^۸ صورت می‌گیرد که سبب دستیابی به نتایج طبقه‌بندی بهتری برای LULC می‌شود. از میان این طبقه‌بندی‌کننده‌ها می‌توان به جنگل تصادفی/درخت تصادفی^۹، درخت طبقه‌بندی و رگرسیون^{۱۰}، ماشین بردار پشتیبان^{۱۱}، حداکثر احتمال^{۱۲} و حداقل فاصله^{۱۳} اشاره کرد (Kulithalai Shiyam Sundar et al., 2021; Affonso et al., 2023; Waleed et al., 2023). روش‌های یادگیری ماشین به دلیل

1 Land Use and Land Cover

2 Remote Sensing

3 Machine Learning

4 Google Earth Engine

5 Landsat

6 Sentinel

7 Modis

8 Nonparametric machine learning classifiers

9 RandomForest/ Random Tree

10 Classification And Regression Tree

11 Support vector machine

12 Maximum Likelihood Estimation

13 Minimum Distance



دقت و انعطاف بیشتر نسبت به سایر روش‌ها، این پتانسیل را دارند که با مجموعه داده‌های مربوط به سال‌های گذشته و زمان حال برای تجزیه و تحلیل LULC مورد استفاده قرار بگیرند.

در دهه‌های اخیر از دست دادن تنوع زیستی، تغییرات آب و هوایی و آلودگی منابع طبیعی مانند خاک، آب و هوا سبب ایجاد تغییرات محسوسی در کاربری زمین شده است. این تغییرات در کاربری و پوشش زمین به طور قابل توجهی دمای سطح زمین^۱ را تغییر می‌دهد. دمای سطح زمین، یکی از پارامترهای مهم در ارزیابی تغییرات پوشش زمین است که به‌عنوان ابزاری بسیار مهم برای بررسی تأثیر تغییرات اقلیمی و فعالیت‌های انسانی بر محیط زیست استفاده می‌شود (Zhao et al., 2016; Guha and Govil, 2023).

با توجه به افزایش سرعت تغییرات محیطی در سراسر جهان، تقاضا برای داده‌های قابل اعتماد و دقیق در زمینه‌ی تغییرات کاربری و پوشش اراضی با استفاده از تصاویر ماهواره‌ای افزایش یافته است. از آنجا که تغییرات کاربری و پوشش زمین یکی از مهم‌ترین عوامل موثر بر تغییرات دمای سطح زمین است، این پژوهش می‌تواند به شناخت بهتر تغییرات زمین و تأثیر آن‌ها بر دمای سطح زمین کمک کند و در تدوین سیاست‌های مناسب برای حفاظت از محیط زیست و کاهش تغییرات اقلیمی موثر باشد. در این پژوهش، از روش‌های پیشرفته پردازش تصویر و تحلیل داده‌های ماهواره‌ای استفاده می‌شود که باعث تولید نقشه‌های کاربری و پوشش زمین با دقت بالا شده و این امکان را فراهم می‌کند تا تأثیرات تغییرات کاربری و پوشش زمین بر دمای سطح زمین با دقت بیشتری مورد بررسی قرار گیرد. اهداف اصلی این مطالعه عبارت‌اند از:

۱. تعیین بهترین منبع تصویر ماهواره‌ای و الگوریتم یادگیری ماشینی برای تهیه نقشه‌ی کاربری و پوشش اراضی

۲. ارزیابی تغییرات کاربری و پوشش اراضی در طول دوره مورد مطالعه

۳. بررسی تأثیر تغییرات کاربری و پوشش اراضی بر دمای سطح زمین

نتایج این پژوهش می‌تواند به عنوان ابزاری موثر در مدیریت منابع طبیعی و برنامه‌ریزی شهری به کار گرفته شود. در این پژوهش فرض بر این است که استفاده از الگوریتم SVM و داده‌های سنتینل ۲ برای دستیابی به نقشه‌های دقیق‌تر، پتانسیل بالایی برای تصمیم‌گیری‌های بهتر در حوزه‌های مرتبط با محیط زیست و توسعه پایدار دارد. بنابراین استفاده از فناوری‌های پیشرفته در تحلیل داده‌های محیطی می‌تواند به کاهش اثرات منفی تغییرات اقلیمی و بهبود مدیریت منابع طبیعی منجر شود.

پیشینه پژوهش

مطالعات نشان داده‌اند که نتایج طبقه‌بندی کاربری و پوشش زمین با استفاده از تصاویر مبتنی بر سنجنش از دور و با بهره‌گیری از روش‌های یادگیری ماشینی غیرپارامتری بسیار دقیق هستند (Tassi and Vizzari, 2020; Aldiansyah and Saputra, 2023). به همین دلیل در حال حاضر این روش‌ها به طور فزاینده‌ای در تولید نقشه‌های کاربری و پوشش زمین استفاده می‌شوند (Loukika et al; 2022; Mollick et al., 2023). به عنوان مثال لوکیکا و همکاران (۲۰۲۲) در پژوهشی در حوزه Munneru هند به بررسی و مقایسه طبقه‌بندی LULC با استفاده از ماهواره‌های سنتینل ۲ و لندست ۸ و سه الگوریتم SVM، CART، RF پرداختند. آن‌ها میانگین دقت کلی^۲ برای طبقه‌بندی کننده‌های SVM، RF و CART را به ترتیب ۹۰٫۸۸٪، ۹۴٫۸۵٪ و ۸۲٫۸۸٪ برای ماهواره لندست و ۹۳٫۸٪، ۹۵٫۸٪ و ۸۶٫۴٪ برای ماهواره سنتینل اعلام نمودند.

زنگنه اسدی و همکاران (۱۳۹۵) در تحقیقی با هدف بررسی و ارزیابی روند تغییرات سطوح جنگل‌های حراء بندرعباس با استفاده از تکنیک‌های سنجنش از دور از اطلاعات و نقشه‌های توپوگرافی، تصاویر ماهواره‌ای منطقه و الگوریتم‌های حداکثر احتمال، حداقل فاصله و ماشین بردار پشتیبان استفاده نمودند. نتایج تحقیق آن‌ها نشان داد روش حداکثر احتمال با دقت کلی ۹۸/۳۲٪ و ضریب کاپا ۰/۹۷۸ نسبت به روش ماشین بردار پشتیبان و حداقل فاصله روش دقیق‌تری در تهیه نقشه تغییرات پوشش زمین و روندیابی تغییرات جنگلی می‌باشد.

کولی و همکاران (۲۰۲۰) با استفاده از الگوریتم RF و به دست آوردن دقت کلی ۹۵.۹ با ضریب کاپا 0.94 توانایی GEE را در تجزیه و تحلیل نرخ تغییر کاربری زمین در اطراف دریاچه کلرو^۳ هند نشان دادند.

در تحقیق دیگری آلدیانسیا و ساپوترا (۲۰۲۳) نقشه طبقه‌بندی LULC منطقه WANGGU در شمال تایوان را با استفاده از

1 Land Surface Temperature

2 Overall Accuracy

3 Kolleru

ماهواره‌های لندست ۸ و سنتینل ۲ تولید نموده و به مقایسه عملکرد دقت سه الگوریتم RF، SVM و CART پرداختند. نتایج نشان داد ماهواره سنتینل ۲ از نظر دقت کلی و ضریب کاپا^۱ بهتر از لندست ۸ است. همچنین الگوریتم RF در هر دو نوع تصویر ماهواره‌ای بهتر از SVM و CART عمل کرد. ولید و همکاران (۲۰۲۳) نیز به بررسی و مقایسه ۴ الگوریتم طبقه‌بندی SVM، RF، MD و CART برای تهیه نقشه LULC تالاب‌ها در پاکستان پرداختند. نتایج این تحقیق نشان داد RF با تولید دقت ۹۹ درصد در تمام دوره‌ها، کارآمدترین و دقیق‌ترین الگوریتم برای نقشه‌برداری تالاب‌ها است.

احدی و همکاران (۲۰۲۲) برای نظارت و ارزیابی دقیق تغییرات کاربری اراضی در کابل، منطقه شهری را با استفاده از تصاویر ماهواره‌ای لندست-۸ و سنتینل-۲ طبقه‌بندی کرده و نتایج آن‌ها را مقایسه نمودند. نتایج این مطالعه نشان داد که دقت کلی برای سنتینل-۲ برابر با ۹۴٫۲۶٪ بود، در حالی که برای لندست-۸ این مقدار ۸۵٫۰۴٪ بود. به همین ترتیب، ضریب کاپا برای سنتینل-۲ برابر با ۹۱٫۷٪ و برای لندست-۸ برابر با ۷۸٫۳٪ محاسبه شد.

تغییرات کاربری و پوشش زمین به‌عنوان یکی از عوامل کلیدی در تغییرات دمای سطح زمین شناخته می‌شود. این تغییرات می‌توانند تأثیرات چشمگیری بر توزیع دما در مناطق مختلف داشته باشند، به ویژه زمانی که زمین‌های بایر به اراضی کشاورزی یا سایر کاربری‌های تبدیل می‌شوند.

تأثیر تغییرات کاربری و پوشش زمین بر توزیع LST توسط چندین مطالعه تایید شده است. هوآ و پینگ (۲۰۱۸) در نتیجه تحقیق خود بر روی اثر تغییر کاربری بر LST در کوالامپور نشان دادند افزایش مناطق شهری و کاهش سطح پوشش گیاهی باعث افزایش دمای سطح زمین می‌شود. به‌طور خاص، تحلیل آماری و مدل‌سازی می‌تواند به ما کمک کند تا تأثیرات پوشش زمین و سایر مشخصات سطح زمین بر LST را به‌صورت دقیق‌تر و کم‌هزینه‌تری بررسی کنیم. همچنین، استفاده از داده‌های ماهواره‌ای و سنسورهای حساس به دمای سطحی زمین، می‌تواند به‌عنوان یکی از ابزارهای مهم در تحلیل تغییرات پوشش زمین و سایر مشخصات سطح زمین بر LST، مورد استفاده قرار گیرد (Pandey et al., 2023; Hasan et al., 2023). در این زمینه گوها و همکاران (۲۰۲۲) اثرات تغییر LULC بر NDVI و LST را در هند بررسی کردند و عملی بودن تخمین LST را با استفاده از تصاویر ماهواره‌ای نشان دادند.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه به وسعت ۴۰۰۰ هکتار مشتمل بر منطقه لوشان از توابع شهرستان رودبار در استان گیلان واقع در شمال ایران است. این منطقه در سامانه مختصاتی UTM، در زون ۳۹ بین نقاط 36° 36' و 36° 42' متر شمالی و 49° 32' و 49° 32' متر شرقی قرار دارد (شکل ۱). براساس اطلاعات ایستگاه‌های هواشناسی، میانگین سالیانه بارندگی منطقه به مقدار ۲۷۳ میلی‌متر و میانگین سالیانه دما حدود ۱۷ درجه سلسیوس و متوسط رطوبت نسبی ۶۰ درصد است. ارتفاع منطقه بین ۲۷۰ تا ۵۸۰ متر از سطح دریا متغیر است. اقلیم منطقه لوشان از نوع نیمه خشک است که مهم‌ترین ویژگی آن بارش کم و خشکی هوا است. خاک منطقه در دو رده اریدی سول و انتی سول قرار دارد.

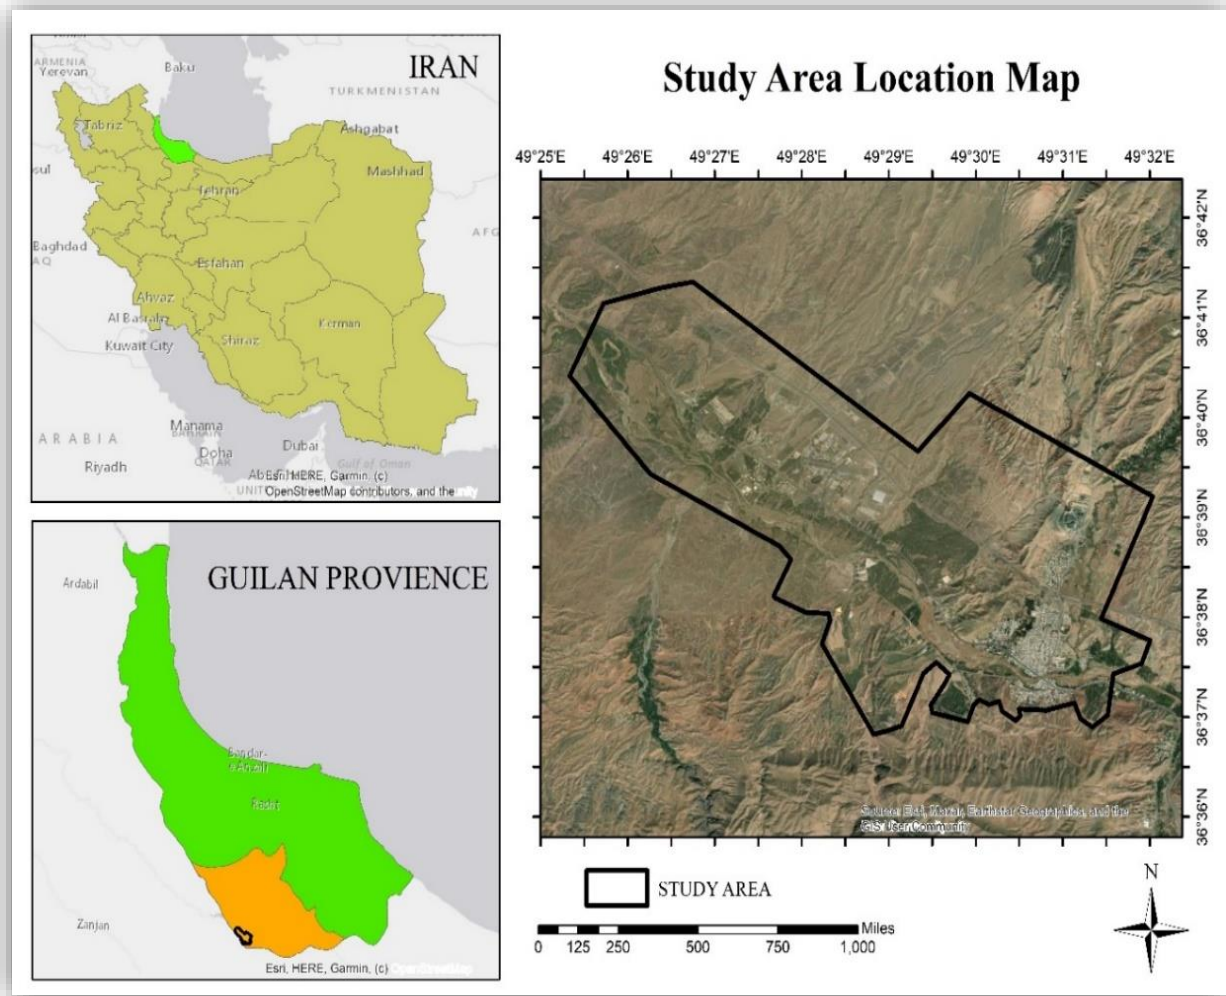
الگوی کاربری اراضی در این منطقه تحت تأثیر ویژگی‌های اقلیمی، توپوگرافی و فعالیت‌های انسانی قرار دارد. به‌طور کلی، الگوی کاربری اراضی در لوشان به شکل زیر است (جدول ۲):

اراضی کشاورزی: بخش بزرگی از اراضی لوشان به کشاورزی اختصاص دارد. در این منطقه، محصولات دیمی مانند گندم و جو کشت می‌شوند. به دلیل محدودیت منابع آبی، کشاورزی آبی کمتر رواج دارد، ولی در برخی نواحی در اطراف رود سپیدرود شالیزار مشاهده می‌شوند.

اراضی بایر: در برخی نقاط به ویژه در مناطق مرتفع‌تر و خشک‌تر، اراضی بایر وجود دارد که به دلیل کمبود آب و خاک ضعیف، برای کشاورزی مناسب نیستند.

مناطق مسکونی و شهری: شهر لوشان و روستاهای اطراف آن، به‌عنوان مناطق مسکونی و شهری بخش کوچکی از الگوی کاربری اراضی را تشکیل می‌دهند. این مناطق عمدتاً در دشت‌های کوچک و دامنه‌های کوهستانی قرار دارند.

باغات زیتون: زیتون کاری یکی از فعالیت‌های اقتصادی مهم در لوشان است. باغات زیتون در مناطق کم‌شیب‌تر و در حاشیه رودخانه‌ها و مناطق با دسترسی به آب زیرزمینی دیده می‌شود. آب و هوای مناسب این منطقه و حمایت دولت و سازمان‌های کشاورزی شرایط بسیار مطلوبی برای کشت زیتون در این منطقه ایجاد کرده‌اند. بنابراین، این منطقه تغییرات قابل توجهی در کاربری زمین داشته است و بسیاری از زمین‌های بایر به باغ‌های زیتون پربار تبدیل شده‌اند. این روند رشد زیتون کاری نشان‌دهنده تغییرات در کاربری و پوشش منطقه است. با توجه به این شبکه پیچیده از استفاده از زمین و تحولات اخیر در کاربری و پوشش زمین، این منطقه محل مطالعه مناسبی برای دستیابی به اهداف مطالعه حاضر است.



شکل ۱. منطقه مورد مطالعه

مجموعه داده‌ها

در این مطالعه از تصاویر ماهواره‌های لندست ۸ و سنتینل ۲ برای سال‌های ۲۰۱۹ و ۲۰۲۳ به منظور تهیه نقشه‌های LULC استفاده شد. در جدول (۱) مشخصات تصاویر مورد استفاده آورده شده است. علاوه بر این، داده‌های مرجع مورد استفاده در این تحقیق شامل تصاویر ماهواره‌ای با وضوح مکانی بسیار بالا است که برای سال‌های مورد مطالعه در نرم افزار گوگل ارث پرو^۱ در دسترس هستند.

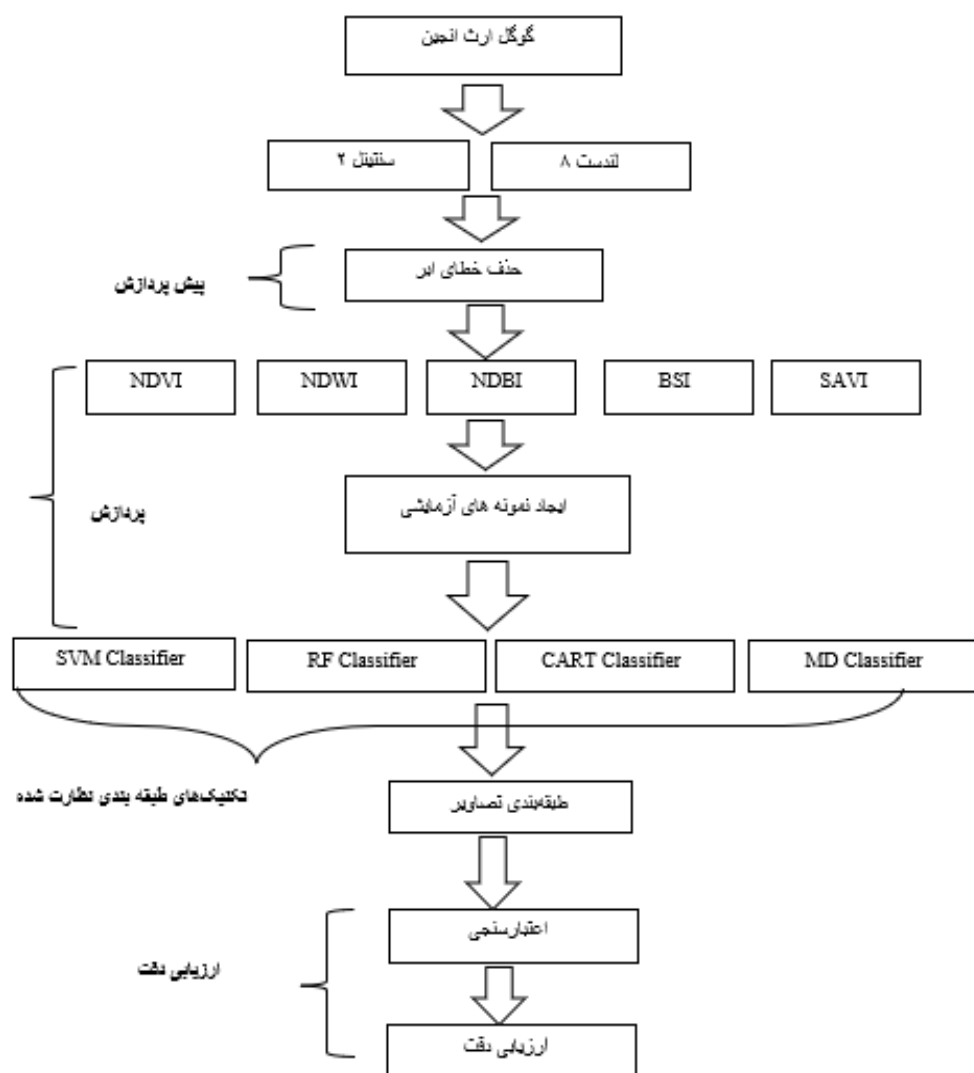
روش شناسی طبقه‌بندی کاربری و پوشش زمین

گردش کار کلی این مطالعه در شکل ۲ توضیح داده شده است. بر اساس این روش، مراحل کار به چهار مرحله تقسیم می‌شود: پیش پردازش، پردازش، طبقه‌بندی نظارت شده و ارزیابی دقت طبقه‌بندی.

جدول ۱. ویژگی‌های ماهواره‌های سنتینل ۲ و لندست ۸

| Sentinel-2A | | | Landsat-8 | | |
|-------------|----------------|-----------------|-----------|----------------|-----------------|
| Bands | Pixel Size (m) | Wavelength (nm) | Bands | Pixel Size (m) | Wavelength (nm) |
| B1 | ۶۰ | ۴۴۳/۹ | B1 | ۳۰ | ۴۵۱-۴۳۵ |
| B2 | ۱۰ | ۴۹۶/۶ | B2 | ۳۰ | ۵۱۲-۴۵۲ |
| B3 | ۱۰ | ۵۶۰ | B3 | ۳۰ | ۵۹۰-۵۳۳ |
| B4 | ۱۰ | ۶۶۴/۵ | B4 | ۳۰ | ۶۷۳-۶۳۶ |
| B5 | ۲۰ | ۷۰۳/۹ | B5 | ۳۰ | ۸۷۹-۸۵۱ |
| B6 | ۲۰ | ۷۴۰/۲ | B6 | ۳۰ | ۱۶۶۱-۱۵۶۶ |
| B7 | ۲۰ | ۷۸۲/۵ | B7 | ۳۰ | ۲۲۹۴-۲۱۰۷ |
| B8 | ۱۰ | ۸۳۵/۱ | B8 | ۱۵ | |
| B8A | ۲۰ | ۸۶۴/۸ | | | |
| B9 | ۶۰ | ۹۴۵ | B9 | ۱۵ | ۱۱۱۹۰-۱۰۶۰۰ |
| B10 | ۶۰ | ۱۳۷۵ | B10 | ۳۰(۱۰۰) | |
| B11 | ۲۰ | ۱۶۱۳/۷ | B11 | ۳۰(۱۰۰) | ۱۲۵۱۰-۱۱۵۰۰ |
| B12 | ۲۰ | ۲۲۰۲/۴ | | | |

Source: Earth Observing System (<https://eos.com>)



شکل ۲. فلوجارت (نمای کلی) روش تحقیق

پیش پردازش

در این مطالعه از پلتفرم محاسبات ابری GEE برای ایجاد مجموعه‌های تصویری و پردازش سری‌های زمانی استفاده شد. همه محصولات بازتاب سطحی سنتینل ۲ و لندست ۸ در منطقه مورد مطالعه برای استخراج معیارهای طیفی-زمانی به‌عنوان ورودی اصلی برای طبقه‌بندی، استفاده شدند. سپس فیلترها و تصحیحات مورد نیاز از جمله حذف پوشش ابر اعمال گردید. در این پژوهش حذف پوشش ابر درسامانه GEE به‌وسیله تکنیکی که توسط سیمونتی و همکاران (۲۰۱۵) پیشنهاد شده است صورت گرفت و پیکسل‌های آلوده به دلیل شرایط ابری یا بدون داده با استفاده از ماسک ابری، از تمام تصاویر موجود حذف شدند.

ماسک ابری یک روش کلیدی در پردازش تصاویر ماهواره‌ای است که به شناسایی و حذف پیکسل‌هایی که تحت پوشش ابر قرار دارند، کمک می‌کند. در این روش ابتدا از الگوریتم‌های تشخیص ابر برای شناسایی پیکسل‌هایی که تحت پوشش ابر قرار دارند استفاده می‌شود. این الگوریتم‌ها معمولاً بر اساس ویژگی‌های طیفی و مقادیر بازتابش در باندهای مختلف تصویر کار می‌کنند. در مرحله بعد نقشه ماسک ابری ایجاد می‌شود. به‌منظور تولید نقشه‌های ماسک ابری، پیکسل‌های تحت پوشش ابر با مقدار صفر (پیکسل‌های آسیب‌دیده) و بقیه با مقدار یک (پیکسل‌های سالم) علامت‌گذاری می‌شوند. در آخر برای تصحیح یا حذف پیکسل‌های آلوده، از روش‌های مختلفی مانند میانگین‌گیری از پیکسل‌های همسایه یا استفاده از داده‌های تاریخی استفاده می‌شود.

پردازش

بازدیدهای میدانی نشان داد منطقه شامل پنج کلاس LULC است که عبارتند از: زیتون کاری، مناطق شهری، شالیزار، گستره‌های آبی و زمین بایر (جدول ۲). برای دستیابی به دقت بالاتر در نتایج طبقه‌بندی تصویر، علاوه بر باندهای طیفی، از تعدادی شاخص‌های طیفی از جمله: شاخص پوشش گیاهی تفاضلی نرمال شده^۱ (NDVI)، شاخص آب تفاضلی نرمال شده^۲ (NDWI)، شاخص ساخت و ساز تفاضلی نرمال شده^۳ (NDBI)، شاخص خاک برهنه^۴ (BSI) و شاخص گیاهی سازگار با خاک^۵ (SAVI) استفاده شد. سپس برای ایجاد یک تصویر ترکیبی، شاخص‌های طیفی با داده‌های لندست ۸ و سنتینل ۲ از هر سال ترکیب شدند و با استفاده از فیلتر میانه به یک تصویر واحد تبدیل شدند (Abdia et al., 2022, Loukika et al., 2021). در مرحله بعد داده‌های مرجع (n=250) در نقاط تصادفی توسط تصاویر با وضوح بالا از Google Earth Pro تهیه شده و از آن‌ها برای برای طبقه‌بندی LULC استفاده شد. از میان داده‌های مرجع ۷۰٪ آن‌ها (n=175) به‌عنوان نمونه‌های آموزشی برای طبقه‌بندی تصاویر ماهواره‌ای و ۳۰٪ بقیه (n=75) برای اعتبارسنجی نتایج طبقه‌بندی تصاویر استفاده شد. سپس با استفاده از تکنیک‌های طبقه‌بندی نظارت شده، تصاویر ماهواره‌های سنتینل ۲ و لندست ۸ برای تولید نقشه‌های LULC برای سال‌های ۲۰۱۹ و ۲۰۲۳ طبقه‌بندی شدند.

جدول ۲. ویژگی‌های کلاس‌های کاربری اراضی

| نام کلاس کاربری | مساحت (هکتار) | تعداد نمونه‌ها |
|-----------------|---------------|----------------|
| باغ زیتون | ۱۴۰۰ | ۵۰ |
| شالیزار | ۴۵۰ | ۵۰ |
| گستره‌های آبی | ۵۰ | ۵۰ |
| مناطق شهری | ۵۰۰ | ۵۰ |
| زمین بایر | ۱۶۰۰ | ۵۰ |

تکنیک‌های طبقه‌بندی نظارت شده

در این مطالعه از چهار طبقه‌بندی‌کننده پرکاربرد و محبوب یعنی الگوریتم‌های RF، SVM، CART و MD، استفاده شد.

جنگل تصادفی

الگوریتم جنگل تصادفی یکی از روش‌های یادگیری ماشین نظارت‌شده است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. RF مجموعه‌ای از درختان تصمیم‌گیری^۶ است که به‌طور مستقل ساخته می‌شوند. هر درخت تصادفی با انتخاب مجموعه‌ای تصادفی از داده‌ها

1 Normalized Difference Vegetation Index

2 Normalized Difference Water Index

3 Normalized Difference Built-up Index

4 Bare Soil Index

5 Soil Adjusted Vegetation Index

6 Decision Trees

و ویژگی‌ها ساخته می‌شود. سپس، نتایج نهایی با ترکیب نتایج هر درخت به صورت میانگین یا رأی‌گیری به دست می‌آید. این الگوریتم به دلیل کاهش نوسانات و افزایش دقت، به ویژه در مسائل پیچیده با ابعاد بالا، بسیار پرکاربرد است. (Belgiu et al. 2016).

ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از الگوریتم‌های نظارت‌شده است که برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود SVM سعی می‌کند یک مرز (هایپرپلن) را پیدا کند که داده‌ها را به بهترین شکل ممکن از هم جدا کند. این الگوریتم به دنبال بیشینه‌سازی فاصله بین نقاط داده و مرز تصمیم‌گیری است، به گونه‌ای که داده‌های هر کلاس به درستی طبقه‌بندی شوند. SVM به دلیل قابلیت‌های بالا در حل مسائل غیرخطی و قابلیت گسترش به صورت کرنل‌های مختلف (مانند کرنل خطی، چندجمله‌ای و گاوسی)، بسیار مورد استفاده قرار می‌گیرد (Talukdar et al. 2020).

درخت طبقه‌بندی و رگرسیون

درخت طبقه‌بندی و رگرسیون یکی از روش‌های یادگیری ماشین نظارت‌شده است که به طور گسترده برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. CART با استفاده از مجموعه‌ای از قوانین ساده برای تجزیه داده‌ها به زیرمجموعه‌های کوچک‌تر عمل می‌کند. این الگوریتم درختی را ایجاد می‌کند که در هر گره آن، داده‌ها بر اساس یک ویژگی به دو دسته تقسیم می‌شوند. این فرایند تا زمانی ادامه می‌یابد که همه گره‌ها خالص شوند (یعنی تنها یک کلاس را شامل شوند) یا دیگر هیچ تقسیم قابل بهبودی وجود نداشته باشد (Shetty 2019).

حداقل فاصله

الگوریتم حداقل فاصله یک روش ساده و کارآمد برای طبقه‌بندی داده‌ها است. در این روش، فاصله هر نقطه داده‌ای تا مرکز هر کلاس (میانگین ویژگی‌های کلاس) محاسبه می‌شود. سپس، هر نقطه داده‌ای به کلاسی اختصاص داده می‌شود که نزدیک‌ترین فاصله را دارد. این الگوریتم به دلیل سادگی و سرعت اجرا، به ویژه در مسائل طبقه‌بندی با تعداد زیاد ویژگی‌ها، کاربرد دارد (Romshoo & Murtaza, 2014).

ارزیابی دقت

ارزیابی صحت داده‌های سنجش از دور آخرین و یکی از ضروری‌ترین مراحل برای یافتن ارزش اطلاعاتی داده‌های نتیجه برای کاربر نهایی است (Tilahun & Teferie, 2015; Rwanga et al., 2017). استفاده از روش‌های آماری مختلف برای ارزیابی دقت طبقه‌بندی LULC می‌تواند به درک اطمینان از نتایج و تعیین اینکه آیا اهداف تحقیق محقق شده‌اند یا خیر کمک کند (Wang et al., 2021). دقت LULC با مقایسه نقشه طبقه‌بندی شده توسط طبقه‌بندی کننده‌های مختلف با داده‌های مختلف تأیید صحت واقعی ارزیابی می‌شود (Zhang et al., 2016; Daba & You, 2022). در این مطالعه، تأیید صحت طبقه‌بندی نقشه‌های LULC تولید شده در گوگل ارث انجین، با استفاده از تصاویر گوگل ارث به عنوان منبع داده صورت گرفت. ارزیابی دقت با استفاده از ۳۰ درصد از داده‌های مرجع که به صورت تصادفی انتخاب شدند، با استفاده از فرآیندهای آماری مختلف ماتریس خطا از جمله: دقت کلی و ضریب کاپا انجام شد. معادلات (۱) و (۲) روش محاسبه دقت کلی و ضریب کاپا را نشان می‌دهد (Basheer et al., 2022).

$$\text{Overall Accuracy} = \frac{\text{TC.P}}{\text{TS.P}} \times 100 \quad (\text{رابطه ۱})$$

که در آن TC.P تعداد کل پیکسل‌های به درستی طبقه بندی شده و TS.P تعداد کل پیکسل‌های نمونه است.

$$\text{kappa coefficient} = \frac{O.A - C.A}{1 - C.A} \quad (\text{رابطه ۲})$$

که در آن O.A دقت کلی و C.A توافق شانس است.

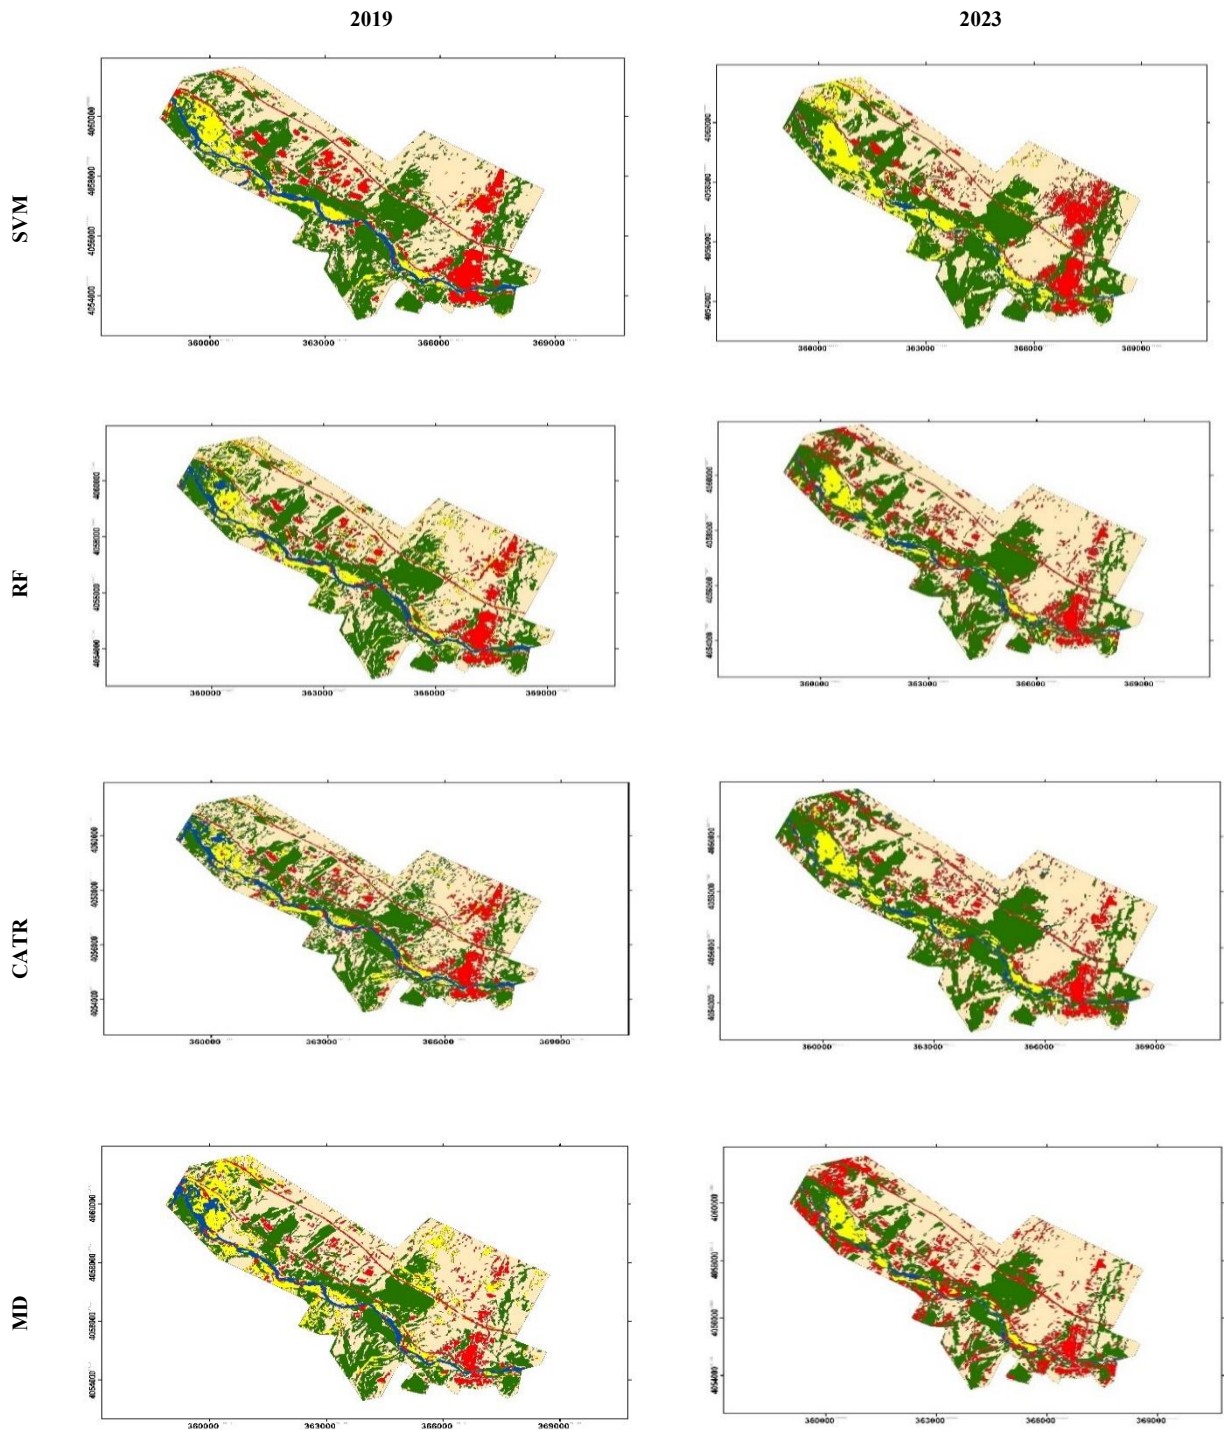
نتایج و بحث

نقشه‌های طبقه‌بندی LULC


شکل ۳ خروجی طبقه‌بندی تصاویر سنتینل ۲ را نشان می‌دهد. همان‌طور که مشاهده می‌شود، در مواردی SVM، در سال ۲۰۲۳، باغ زیتون را به اشتباه به عنوان شالیزار طبقه‌بندی کرد. طبقه‌بندی کننده RF، برای سال ۲۰۱۹، زمین بایر را به اشتباه به عنوان شالیزار طبقه‌بندی کرده است. طبقه‌بندی کننده CART در سال ۲۰۱۹ زمین‌های بایر و باغ‌های زیتون را به صورت لکه‌های شالیزار طبقه‌بندی کرده است.



همچنین طبقه‌بندی کننده MD در سال ۲۰۱۹ کاربری‌های بایر و باغ زیتون را به‌عنوان شالیزار در نظر گرفته و در سال ۲۰۲۳ باغ‌های زیتون را به‌عنوان مناطق شهری طبقه‌بندی کرده است.

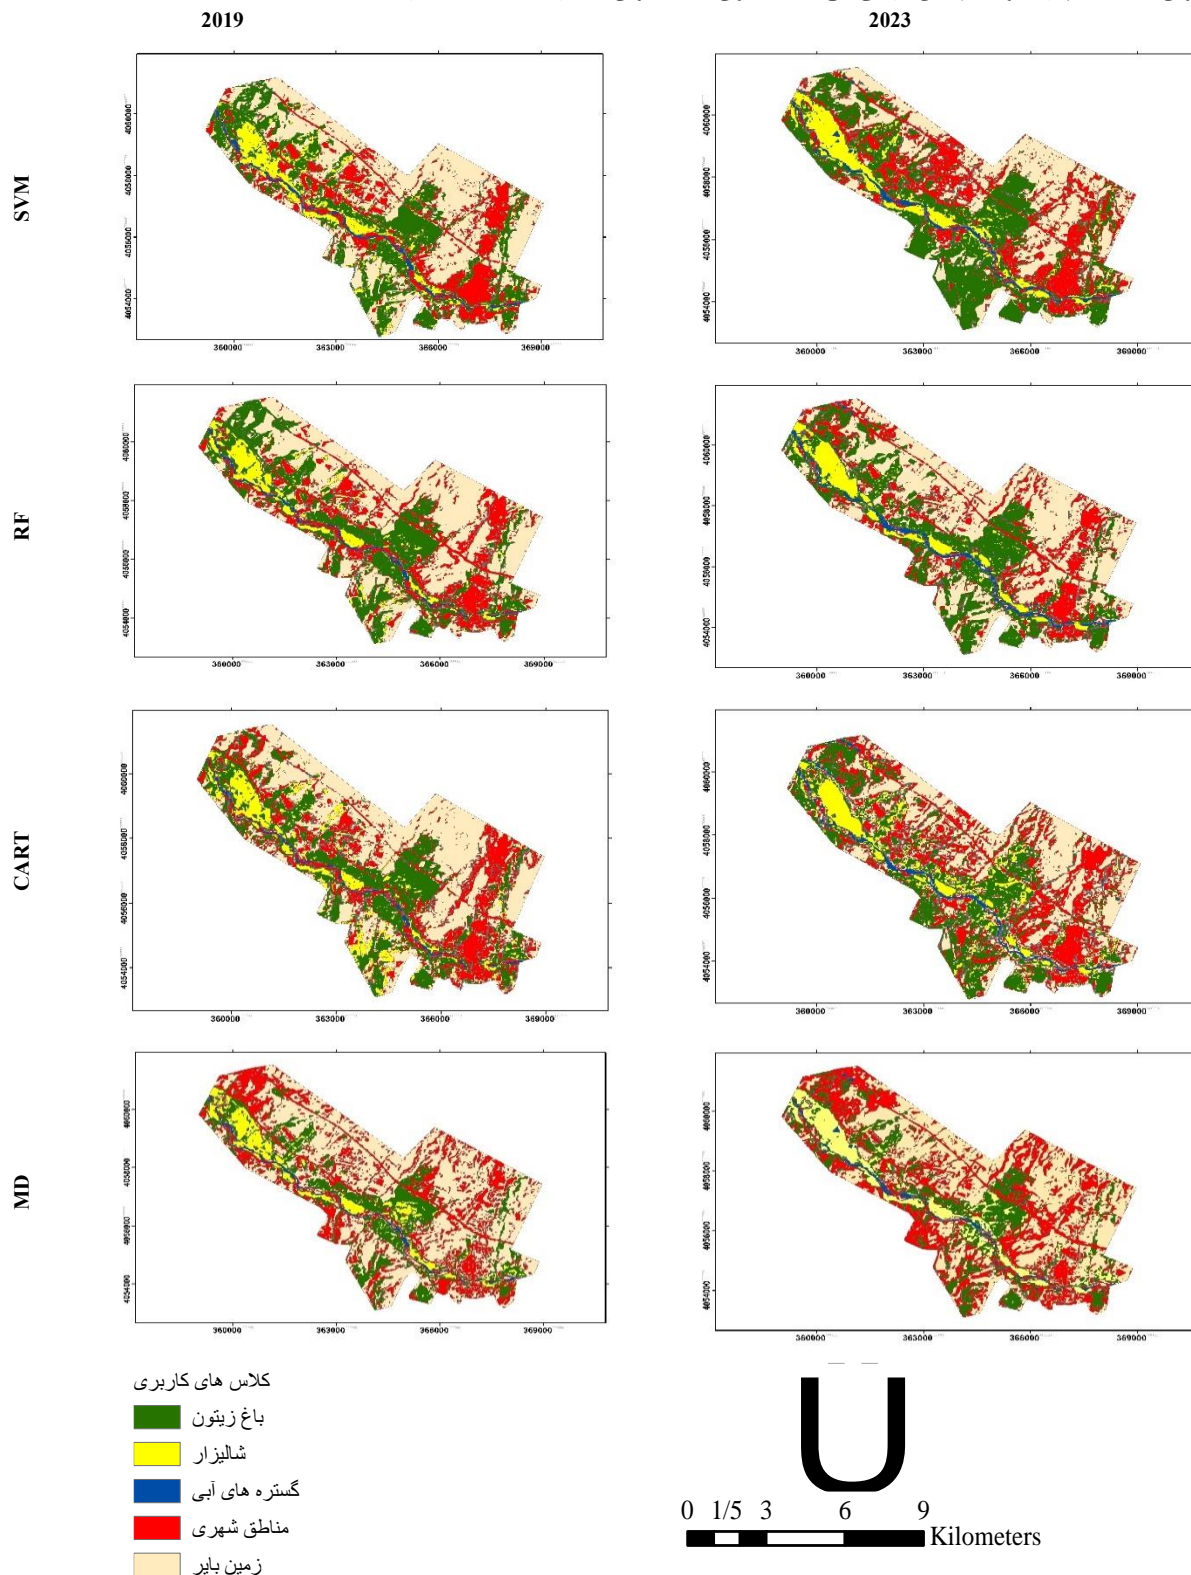


- کلاس‌های کاربری
- باغ زیتون
 - شالیزار
 - گستره‌های آبی
 - مناطق شهری
 - زمین بایر



شکل ۳. نقشه‌های طبقه‌بندی LULC توسط داده‌های سنتینل ۲ از ۲۰۱۹ تا ۲۰۲۳

شکل ۴ نیز نقشه‌های طبقه‌بندی LULC را با استفاده از تصاویر لندست ۸ نشان می‌دهد. همان‌طور که مشاهده می‌شود، طبقه‌بندی‌کننده RF برای هر دو سال ۲۰۱۹ و ۲۰۲۳، زمین بایر را به‌عنوان مناطق شهری طبقه‌بندی اشتباهی کرد. طبقه‌بندی‌کننده CART زمین‌های بایر و برخی از باغ‌های زیتون را به‌عنوان شالیزار طبقه‌بندی کرده است و طبقه‌بندی‌کننده MD برخی از زمین‌های بایر را به‌عنوان منطقه شهری و همچنین برخی باغ‌های زیتون را به‌عنوان شالیزار طبقه‌بندی کرده است.



شکل ۴. نقشه‌های طبقه‌بندی LULC توسط داده‌های لندست ۸ از ۲۰۱۹ تا ۲۰۲۳



از مقایسه تصاویر طبقه‌بندی شده با وضعیت کاربری واقعی منطقه در سال‌های هدف این نتیجه حاصل می‌شود که طبقه‌بندی تصاویر توسط طبقه‌بندی کننده SVM با استفاده از تصاویر هر دو ماهواره سنتینل ۲ و لندست ۸ بیشتر منطبق بر واقعیت است. به عبارت دیگر طبقه‌بندی کننده‌های RF، CART و MD خطای بیشتری در طبقه‌بندی کاربری و پوشش زمین داشتند و بعضی از پیکسل‌های آن‌ها کاربری زمین را به اشتباه تشخیص دادند. مطالعات اخیر نیز نشان می‌دهند بیشتر الگوریتم‌های یادگیری ماشینی که برای طبقه‌بندی مورد استفاده قرار می‌گیرند، خطاهایی در طبقه‌بندی دارند. بر این اساس پیشنهاد شده است تا از الگوریتم‌هایی مانند شبکه‌های عصبی مصنوعی و یادگیری عمیق که می‌توانند سبب بهبود قابل توجهی در دقت طبقه‌بندی شوند استفاده شود (Ahady et al., 2022; basheer et al., 2022).

علت اینکه برخی از پیکسل‌ها در نقشه‌های LULC، کلاس‌های متفاوتی را پس از طبقه‌بندی نشان می‌دهند، می‌تواند به مطابقت برخی از پیکسل‌ها با پاسخ‌های طیفی متفاوت، تفاوت در بهینه‌سازی پارامتر مدل‌ها و تفاوت‌های دقت در الگوریتم‌های مورد استفاده نسبت داده شود. در این راستا، مطالعات قبلی نیز نشان داده‌اند که طبقه‌بندی LULC با استفاده از تصاویر ماهواره‌ای وابسته به نوع ماهواره، شرایط هواشناسی، نوع الگوریتم طبقه‌بندی و شرایط منطقه مورد مطالعه است. بنابراین ممکن است بر اثر تغییر منطقه مورد مطالعه، تغییر در تعداد داده‌ها و تغییرات جوی، روشنایی و هندسی، افزایش دقت و صحت طبقه‌بندی مشاهده شود (McCarty et al., 2020; Nasiri et al., 2022; Yuh et al., 2023).

ارزیابی دقت

ارزیابی دقت برای بررسی صحت هر یک از طبقه‌بندی کننده‌ها استفاده می‌شود. پس از طبقه‌بندی LULC با استفاده از طبقه‌بندی کننده‌ها، دقت کلی و ضریب کاپا برای بررسی صحت نقشه‌های طبقه‌بندی شده LULC در گوگل ارث انجین محاسبه شد. عملکرد طبقه‌بندی کننده‌های SVM، RF، CART و MD در جدول ۳ از نظر دقت کلی و ضریب کاپا مقایسه شده است.

جدول ۳. ضریب کاپا و دقت کلی برای طبقه‌بندی کننده‌های مختلف بر اساس داده‌های سنتینل ۲ و لندست ۸

| سال مطالعه | طبقه‌بندی کننده | سنتینل ۲ | | لندست ۸ | |
|------------|-----------------|----------|-----------|---------|-----------|
| | | دقت کلی | ضریب کاپا | دقت کلی | ضریب کاپا |
| ۲۰۱۹ | SVM | ۹۱/۶۰ | ۰/۸۹ | ۹۱/۲۰ | ۰/۸۸ |
| | RF | ۸۸/۳۰ | ۰/۸۶ | ۸۸/۰۰ | ۰/۸۵ |
| | CART | ۸۶/۰۰ | ۰/۸۴ | ۸۹/۸۰ | ۰/۸۷ |
| | MD | ۷۹/۴۰ | ۰/۷۵ | ۷۸/۳۰ | ۰/۷۴ |
| ۲۰۲۳ | SVM | ۹۴/۲۰ | ۰/۹۱ | ۹۳/۲۰ | ۰/۸۹ |
| | RF | ۹۲/۲۰ | ۰/۹۰ | ۸۷/۰۰ | ۰/۸۴ |
| | CART | ۹۱/۱۰ | ۰/۸۹ | ۹۰/۷۰ | ۰/۸۷ |
| | MD | ۸۸/۸۰ | ۰/۸۶ | ۷۷/۵۰ | ۰/۷۳ |

نتایج اعتبارسنجی ما نشان داد که SVM، برای ماهواره سنتینل ۲، با دقت کلی 91.6 و 94.2 درصد و ضریب کاپای 0.89 و 0.91 در سال‌های ۲۰۱۹ و ۲۰۲۳ و برای ماهواره لندست ۸، با مقادیر دقت کلی ۹۱،۲ و ۹۳،۲ و ضریب کاپای ۰،۸۸ و ۰،۸۹ در سال‌های ۲۰۱۹ و ۲۰۲۳ بهترین نتیجه را داشت. به‌طور کلی می‌توان گفت این طبقه‌بندی کننده دقت بهتری در تولید نقشه‌های LULC برای هر دو مجموعه داده‌های ماهواره‌ای ارائه می‌دهد. بوسلیم و همکاران (۲۰۲۳) در پژوهش خود توانایی دو الگوریتم یادگیری ماشینی RF و SVM را برای تولید نقشه LULC با استفاده از لندست ۹ و سنتینل ۲ مورد ارزیابی قرار دادند. نتایج این پژوهش نشان داد بهترین طبقه‌بندی توسط ماهواره سنتینل ۲ و طبقه‌بندی کننده SVM صورت گرفت.

برای داده‌های سنتینل ۲ پس از SVM، به ترتیب طبقه‌بندی کننده‌های RF، CART و MD با مقادیر دقت کلی ۸۸،۳، ۸۶ و ۷۹،۴ درصد و ضریب کاپای ۰،۸۶، ۰،۸۴ و ۰،۷۵ برای سال ۲۰۱۹ در رتبه‌های بعدی از نظر دقت طبقه‌بندی قرار گرفتند. در سال ۲۰۲۳ نیز بعد از SVM طبقه‌بندی کننده‌های RF، CART و MD با مقادیر دقت کلی ۹۲،۲، ۹۱،۱ و ۸۸،۸ درصد و ضریب کاپای ۰،۸۹، ۰،۸۶ و ۰،۸۶ قرار دارند.

برای داده‌های لندست ۸ نیز پس از SVM طبقه‌بندی کننده CART با مقادیر دقت کلی ۸۹،۸ و ۹۰،۷ درصد و ضرایب کاپای ۰،۸۷


و ۰,۸۷ به ترتیب برای سال‌های ۲۰۱۹ و ۲۰۲۳ و بعد از آن طبقه‌بندی کننده RF با مقادیر دقت کلی ۸۸ و ۸۷ درصد و ضرایب کاپای ۰,۸۵ و ۰,۸۴ به ترتیب برای سال‌های ۲۰۱۹ و ۲۰۲۳ به دست آمد. همچنین کمترین دقت ارزیابی برای طبقه‌بندی کننده MD با مقادیر دقت کلی ۷۸,۳ و ۷۷,۵ درصد و ضرایب کاپای ۰,۷۴ و ۰,۷۳ برای سال‌های ۲۰۱۹ و ۲۰۲۳ به دست آمد. عبدی (۲۰۲۰) در پژوهشی به بررسی دقت الگوریتم‌های ناپارامتریک طبقه‌بندی در منطقه جنوب مرکزی سوئد پرداخت. نتایج مقایسه بین چهار الگوریتم RF, SVM, Xgboost و DL نشان داد بالاترین دقت کلی توسط ماشین بردار پشتیبان به دست آمد.

نتایج ارزیابی دقت در این مطالعه نشان داد بین دقت کلی و ضریب کاپا حاصل از طبقه‌بندی کننده‌های مختلف، تفاوت چندانی وجود ندارد. از آنجا که دقت کلی بیشتر از ۷۰٪ قابل قبول در نظر گرفته می‌شود و مقدار کاپا در محدوده ۰,۴۰ تا ۰,۸۵ نشان دهنده مطابقت خوب و ۰,۸۶ تا ۱ نشان دهنده مطابقت عالی است (Congalton, 1991)، بنابراین می‌توان مدل‌های RF, CART و MD را برای تهیه نقشه LULC برای هردو مجموعه داده‌های حاصل از ماهواره‌های سنتینل ۲ و لندست ۸ مفید و کاربردی دانست، اما الگوریتم SVM می‌تواند به عنوان بهترین طبقه‌بندی کننده LULC توصیه کرد. به عبارت دیگر در این مطالعه تخمین LULC توسط طبقه‌بندی کننده SVM بیشتر نزدیک به واقعیت است و در مقایسه با طبقه‌بندی کننده‌های RF, CART و MD می‌توان آن را به عنوان کارآمدترین طبقه‌بندی کننده معرفی کرد. این نتیجه با نتایج تحقیقات بوسلیم و همکاران (۲۰۲۳)، لوکیکا و همکاران (۲۰۲۲) و رحمان و همکاران (۲۰۲۰)، مطابقت دارد. ماشین بردار پشتیبان یک الگوریتم طبقه‌بندی بسیار قدرتمند است و وقتی از آن همراه با الگوریتم‌های جنگل تصادفی و دیگر ابزارهای یادگیری ماشین استفاده شود، این الگوریتم می‌تواند مدلی بسیار قابل توجه برای طبقه‌بندی داده‌ها ارائه کند. مطالعات نشان داده SVM در صورتی که داده‌های آموزشی ورودی پراکنده باشد، عملکرد خوبی دارد، و در صورت در دسترس بودن داده، آن را به انتخاب بهتری تبدیل می‌کند (Shetty, 2019).

تان نوی و کاپاس (۲۰۱۷) در پژوهشی به مقایسه الگوریتم‌های RF, KNN و SVM جهت طبقه‌بندی LULC با استفاده از تصاویر سنتینل ۲ در شمال دلتای رود سرخ ویتنام پرداختند. نتایج نشان داد که SVM بالاترین دقت کلی را دارد و پس از آن الگوریتم‌های RF و KNN قرار دارند. در مطالعه‌ای مشابه در تایلند، زوستر و همکاران (۲۰۱۱) به مقایسه سه روش ماشین بردار پشتیبان، حداکثر احتمال و شبکه عصبی در تهیه نقشه کاربری اراضی پرداختند. نتایج تحقیق آن‌ها نشان داد روش ماشین بردار پشتیبان با ضریب کاپا ۰,۹۴,۱۵ دقیق‌ترین روش بوده و روش حداکثر احتمال در رده بعدی قرار داشته است.

علت اینکه الگوریتم طبقه‌بندی کننده حداقل فاصله، کمترین دقت طبقه‌بندی را دارد این است که با استفاده از آن، تمام پیکسل‌ها در تصویر طبقه‌بندی می‌شوند، حتی اگر فاصله آن‌ها از میانگین دور باشد. این باعث می‌شود که در برخی موارد، پیکسل‌هایی که در واقع به کلاس دیگری تعلق دارند، به عنوان عضو همان کلاسی که پیکسل‌های نزدیکی به آن دارند، طبقه‌بندی شوند. (Abinaya & Poonkuntran, 2019). دقیق‌ترین و مناسب‌ترین طبقه‌بندی کننده می‌تواند بر اساس منطقه مورد مطالعه، تعداد و کیفیت نمونه‌های آموزشی^۱ نیز متفاوت باشد. در واقع، دقت طبقه‌بندی LULC نه تنها توسط الگوریتم‌های طبقه‌بندی، بلکه تغییرات مکانی، زمانی و شرایط محیطی نیز تحت تأثیر قرار می‌گیرد (McCarty et al., 2020; Nasiri et al., 2022; Yuh et al., 2023). علاوه بر این، ویژگی‌های حسگر و عوامل مرتبط با داده‌های تصویر، مانند وضوح مکانی و زمانی، نرم‌افزار پردازش و سخت‌افزار نیز می‌توانند بر دقت طبقه‌بندی LULC تأثیر بگذارند. برای مثال، وجود نویز در تصویر، نوع حسگر استفاده شده برای جمع‌آوری تصویر و درستی پایگاه داده می‌توانند دقت طبقه‌بندی را تحت تأثیر قرار دهند (Talukdar et al., 2020; Daulay et al., 2023). شکل ۵ یک نمایش بصری از ضرایب کاپا مربوط به تمام طبقه‌بندی کننده‌های ارزیابی شده را با استفاده از تصاویر سنتینل ۲ و لندست ۸ ارائه می‌کند.

نتایج حاصل از مقایسه دو مجموعه داده سنتینل ۲ و لندست ۸ برای سال‌های ۲۰۱۹ و ۲۰۲۳ با استفاده از طبقه‌بندی کننده SVM، نشان می‌دهد که مقدار بالاتری از ضریب کاپا برای مجموعه داده سنتینل ۲ در مقایسه با مجموعه داده لندست ۸ در سال‌های مذکور به دست آمده است (شکل ۵). این نتایج نشان می‌دهد که طبقه‌بندی کننده SVM در مقایسه با سایر طبقه‌بندی کننده‌ها عملکرد بهتری دارد. نتایج مشابهی در مطالعات بشیر و همکاران (۲۰۱۹) و شتی (۲۰۱۹) گزارش شده است. همچنین، کمترین مقدار ضریب کاپا برای داده‌های لندست ۸ با استفاده از طبقه‌بندی کننده MD مشاهده شد. رحمان و همکاران (۲۰۲۰) در مطالعه خود عملکرد طبقه‌بندی کننده‌های RF و SVM را از طریق سطوح دقت آن‌ها در طبقه‌بندی مناطق شهری و روستایی در بنگلادش بررسی کردند. آن‌ها برای طبقه‌بندی کننده SVM به حداکثر دقت ۹۶.۹% و ۹۸.۳% دست یافتند.



شکل ۵. مقایسه ضریب کاپا با استفاده از طبقه‌بندی کننده‌های مختلف توسط سن‌تینل ۲ و لندست ۸

بر اساس داده‌های جدول ۴ می‌توان مشاهده کرد میانگین دقت کلی طبقه‌بندی کننده‌های SVM، RF، CART و MD برای سن‌تینل ۲ به ترتیب ۹۲٫۹، ۹۰٫۲، ۸۸٫۵ و ۸۴٫۱ درصد و میانگین ضرایب کاپا برای آن‌ها به ترتیب ۰٫۹۰، ۰٫۸۸، ۰٫۸۶ و ۰٫۸۰ است. همچنین میانگین دقت کلی طبقه‌بندی کننده‌های SVM، RF، CART و MD برای لندست ۸ به ترتیب ۹۲٫۲، ۸۷٫۵، ۹۰٫۲ و ۷۷٫۵ درصد و میانگین ضرایب کاپا برای آن‌ها به ترتیب برابر به ترتیب ۰٫۸۸، ۰٫۸۴، ۰٫۸۷ و ۰٫۷۳ است. بنابراین می‌توان گفت طبقه‌بندی تصاویر سن‌تینل ۲ با مقادیر دقت کلی و ضریب کاپای بالاتر، دقیق‌تر از طبقه‌بندی تصاویر لندست ۸ است. طبقه‌بندی کاربری و پوشش زمین با استفاده از ماهواره سن‌تینل ۲ به دلیل قدرت تفکیک مکانی بالاتر تصاویر سن‌تینل ۲ (۱۰متر) نسبت به لندست ۸ (۳۰متر) دقیق‌تر است و سطح زمین را با جزئیات بیشتری نشان می‌دهد. علاوه بر این ماهواره سن‌تینل ۲ از ۱۳ باند مختلف رنگی استفاده می‌کند که شامل باندهای قرمز نزدیک و لبه قرمز است. این باندها اجازه می‌دهند تصاویر با وضوح بالا از پوشش گیاهی و مناطق خشک و خالی از گیاه تهیه شود در حالی که لندست ۸ فقط از ۱۱ باند طیفی استفاده می‌کند. به عبارت دیگر تصاویر سن‌تینل ۲ به دلیل داشتن نوارهای لبه قرمز امکان طبقه‌بندی پوشش گیاهی را بهتر از لندست ۸ فراهم می‌کند. بنابراین برای برخی کاربردها مثل طبقه‌بندی کاربری و پوشش زمین ماهواره سن‌تینل ۲ بهتر از لندست ۸ عمل می‌کند (Zhao et al., 2021; Gabriele et al., 2022). آدیانسیا و ساپوترا (۲۰۲۳) نیز در مطالعه خود بر روی مقایسه طبقه‌بندی توسط تصاویر ماهواره‌ای مختلف به این نتیجه دست یافتند که برای طبقه‌بندی دقیق‌تر بهتر است از داده‌های سن‌تینل ۲ در مقایسه با لندست ۸ استفاده شود. آن‌ها اعلام کردند عواملی مانند وجود باندهای اضافی، به ویژه باند Red-Edge و وضوح فضایی دقیق‌تر سبب عملکرد بهتر سن‌تینل ۲ می‌شود.

جدول ۴. میانگین دقت کلی و ضریب کاپا برای طبقه‌بندی کننده‌های مختلف بر اساس داده‌های سن‌تینل ۲ و لندست ۸

| طبقه‌بندی کننده | سن‌تینل ۲ | | لندست ۸ | |
|-----------------|-----------|-----------|---------|-----------|
| | دقت کلی | ضریب کاپا | دقت کلی | ضریب کاپا |
| SVM | ۹۲/۹۰ | ۰/۹۰ | ۹۲/۲۰ | ۰/۸۸ |
| RF | ۹۰/۲۰ | ۰/۸۸ | ۸۷/۵۰ | ۰/۸۴ |
| CART | ۸۸/۵۰ | ۰/۸۶ | ۹۰/۲۰ | ۰/۸۷ |
| MD | ۸۴/۱۰ | ۰/۸۰ | ۷۷/۵۰ | ۰/۷۳ |

تغییرات کاربری و پوشش اراضی

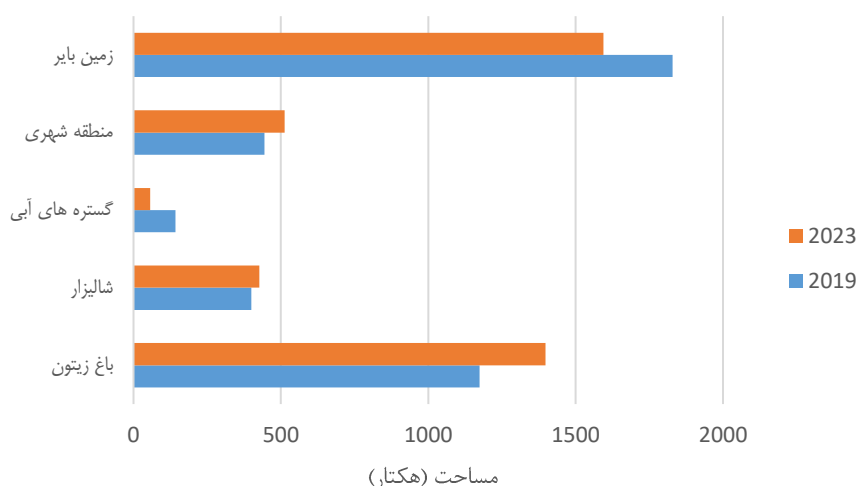
روش‌های مختلفی برای تشخیص تغییرات LULC با استفاده از داده‌های تصاویر ماهواره‌ای مختلف وجود دارد (Zhu, 2017). یکی از روش‌های ساده و در عین حال کارآمد برای تشخیص تغییرات، مقایسه داده‌های سن‌جس از دور بدست آمده در چندین تاریخ است (Tewkesbury et al., 2015; Homer et al., 2020). جدول ۵ تغییرات طبقه‌بندی LULC را که از تصاویر سن‌تینل ۲ و لندست ۸ با

استفاده از الگوریتم طبقه‌بندی SVM برای سال‌های ۲۰۱۹ و ۲۰۲۳ تعیین شده است، نشان می‌دهد. همان‌طور که مشاهده می‌شود، مساحت کاربری‌های باغ زیتون، شالیزار و مناطق شهری به ترتیب 5.63، 0.67 و 1.70 درصد افزایش یافته و در مقابل از مساحت گستره‌های آبی و زمین بایر به ترتیب به مقدار 2.15 و 5.84 درصد کاسته شده است. بررسی تصاویر ماهواره‌ای مربوط به این دوره نیز صحت نتایج فوق را تایید می‌کند. به‌طوریکه مشاهده شد، در طی این دوره ۴ ساله مقادیری از زمین‌های بایر منطقه تبدیل به باغ‌های زیتون و مناطق صنعتی و مسکونی شده است. همچنین کاهش بارش سالیانه و افزایش دما و وقوع خشکسالی سبب کاهش مقادیر آب رودخانه شده است و زمین‌های حاشیه رودخانه توسط اهالی منطقه تبدیل به شالیزار شده‌اند، در نتیجه شاهد کاهش مساحت گستره‌های آبی و افزایش مساحت شالیزار هستیم.

جدول ۵. تشخیص تغییر در کلاس‌های مختلف LULC از ۲۰۱۹ تا ۲۰۲۳

| درصد تغییر مساحت | مساحت (هکتار) | | کلاس کاربری |
|------------------|---------------|---------|---------------|
| | ۲۰۲۳ | ۲۰۱۹ | |
| ۵۶۳ | ۱۳۹۸,۳۱ | ۱۱۷۴,۵۱ | باغ زیتون |
| ۰,۶۷ | ۴۲۶,۵۰ | ۴۰۰,۰۳ | شالیزار |
| -۲,۱۵ | ۵۶,۸۷ | ۱۴۲,۶۸ | گستره‌های آبی |
| ۱,۷۰ | ۵۱۲,۲۷ | ۴۴۴,۷۱ | منطقه شهری |
| -۵,۸۴ | ۱۵۹۴,۶۵ | ۱۸۲۸,۶۵ | زمین بایر |

شکل ۶ نشان می‌دهد بیشترین تغییر در کاربری اراضی مربوط به تبدیل زمین‌های بایر به باغ‌های زیتون است که مزایای بسیاری از جمله: محافظت از خاک، حفظ و نگهداری مواد مغذی در خاک، افزایش جذب دی‌اکسید کربن، حفظ تنوع زیستی، ایجاد فرصت‌های شغلی و افزایش درآمد کشاورزان منطقه را در پی دارد (Edwards et al., 2010). به‌طور کلی، استفاده از تصاویر ماهواره‌ای و الگوریتم‌های طبقه‌بندی مناسب، به ما این امکان را می‌دهد تا تغییرات کاربری و پوشش زمین را با دقت بالا تشخیص داده و تحلیل کنیم. این اطلاعات می‌تواند در برنامه‌ریزی و مدیریت منابع طبیعی و همچنین ارزیابی تاثیرات آن‌ها بر محیط زیست، اقتصاد و جامعه مفید واقع شود. بنابراین، استفاده از این روش‌ها در برنامه‌ریزی و تصمیم‌گیری‌های مرتبط با مدیریت منابع طبیعی بسیار مهم و حائز اهمیت است.

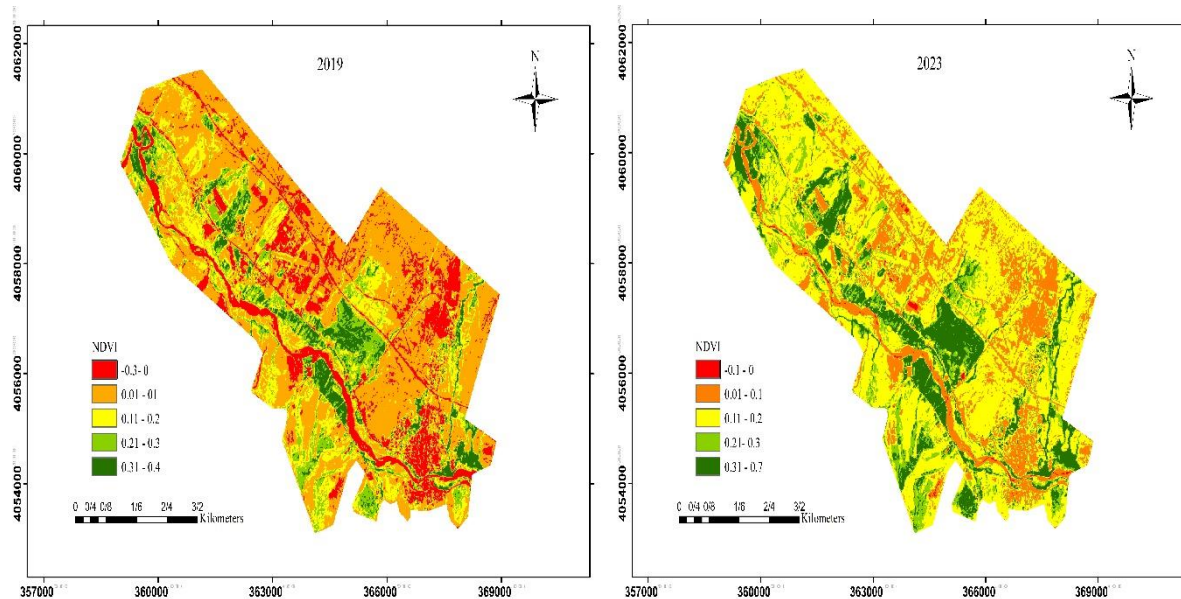


شکل ۶. نمودار تغییرات LULC با استفاده از طبقه‌بندی کننده SVM توسط داده سنتینل ۲ از ۲۰۱۹ تا ۲۰۲۳

تجزیه و تحلیل رابطه بین تغییرات LULC و LST

تغییر کاربری و پوشش زمین ارتباط نزدیکی با تغییرات دمای سطح زمین دارد (Guha et al., 2022; Damayanti et al., 2023). تغییر در شاخص NDVI از مهم‌ترین عوامل موثر بر تغییر دمای سطح زمین است به طوری که افزایش سطوح غیرتبخیری و کاهش سطح پوشش گیاهی باعث افزایش دمای سطح زمین می‌شود (Kumari et al., 2020). در این پژوهش به منظور بررسی اثر تغییر کاربری و

پوشش زمین بر LST، نقشه توزیع LST و NDVI با استفاده از تصاویر ماهواره سنتینل ۲ در سامانه GEE تهیه شده و ارتباط بین آن‌ها مورد بررسی قرار گرفت (شکل ۷).



شکل ۷. نقشه NDVI در سال‌های ۲۰۱۹ و ۲۰۲۳

بررسی تغییرات نشان می‌دهد مساحت کل پوشش گیاهی در منطقه مورد مطالعه از ۱۵۷۴٫۵ هکتار در سال ۲۰۱۹ به ۱۸۲۴٫۸ هکتار در سال ۲۰۲۳ رسیده است (جدول ۵). این تغییرات پوشش گیاهی در نقشه توزیع NDVI نیز مشاهده می‌شود (شکل ۷). افزایش مساحت در پوشش گیاهی سبب افزایش NDVI در طول دوره مطالعه شده است، به طوری که حداکثر مقدار آن از ۰٫۳۹ در سال ۲۰۱۹ به ۰٫۶۸ در سال ۲۰۲۳ تغییر یافته است (جدول ۶).

مطالعات نشان داده‌اند تبدیل اراضی بایر به کاربری‌های کشاورزی و باغات می‌تواند منجر به افزایش NDVI شود (Sun et al., 2020). باغ‌های زیتون، که معمولاً در مناطق نیمه‌خشک و بایر ایجاد می‌شوند، تأثیر مثبتی بر NDVI دارند. پژوهشی در مدیریت باغ‌های زیتون، که NDVI در باغ‌های زیتون به طور متوسط ۰٫۱ تا ۰٫۲ واحد بیشتر از زمین‌های بایر اطراف بود، که به دلیل پوشش گیاهی متراکم و مدیریت بهینه باغ‌ها بود (Alganci et al., 2018).

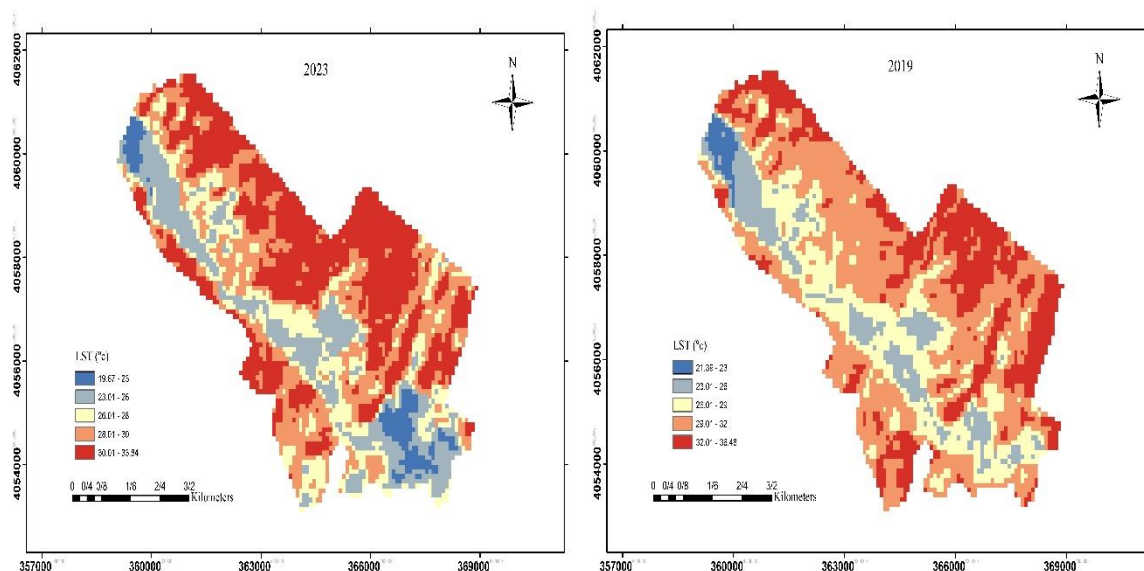
با توجه به نتایج این تحقیق به طور کلی می‌توان اعلام کرد تغییرات کاربری زمین از بایر به کشاورزی، باغ‌های زیتون و شالیزارها تأثیرات قابل توجهی بر پوشش زمین و شاخص NDVI دارند. این تغییرات معمولاً منجر به افزایش NDVI و بهبود پوشش گیاهی می‌شوند که می‌تواند به بهبود کیفیت محیطی و افزایش تولیدات کشاورزی کمک کند. استفاده از داده‌های سنجنده از دور برای پایش این تغییرات و تحلیل آن‌ها با استفاده از شاخص‌های پوشش گیاهی مانند NDVI، اطلاعات ارزشمندی برای مدیریت منابع طبیعی و برنامه‌ریزی‌های محیطی فراهم می‌آورد.

جدول ۶. مقادیر تغییرات NDVI در طول سال‌های مطالعه

| سال مطالعه | NDVI _{min} | NDVI _{max} |
|------------|---------------------|---------------------|
| ۲۰۱۹ | -۰/۳۰ | ۰/۳۹ |
| ۲۰۲۳ | -۰/۱۲ | ۰/۶۸ |

شکل ۸ نقشه توزیع دمای سطح زمین در منطقه مورد مطالعه را نشان می‌دهد. همانطور که مشاهده می‌شود، در زمین‌های بایر و مناطق شهری دمای سطح زمین بالاترین مقدار را دارد و بالعکس در گستره‌های آبی و مناطق دارای پوشش گیاهی از مقدار آن کاسته می‌شود. بررسی الگوی توزیع فضایی LST در سال‌های مطالعه نشان می‌دهد تغییر LULC منجر به تغییر دمای سطح زمین شده است و در مناطقی که زمین‌های بایر تبدیل به باغ زیتون شده (افزایش NDVI)، مقدار LST کاهش یافته است. نقشه‌ها نشان می‌دهند بخش‌های

شمالی منطقه مورد مطالعه که بیشتر از زمین‌های بایر و مناطق شهری تشکیل شده است مقدار LST حداکثر است و در مقابل آن بخش مرکزی و نواحی اطراف رودخانه به دلیل وجود زمین‌های کشاورزی و همچنین گسترش باغ‌های زیتون، LST مقدار کمتری دارد. مطالعات متعددی نشان داده‌اند که تغییرات در کاربری زمین می‌تواند منجر به تغییرات قابل توجهی در دمای سطح زمین شود. به عنوان مثال، تبدیل زمین‌های بایر به اراضی کشاورزی معمولاً باعث کاهش LST می‌شود، زیرا پوشش گیاهی جدید می‌تواند مقدار زیادی از تابش خورشیدی را جذب و فرآیند تعرق را تقویت کند، که به نوبه خود به کاهش دما کمک می‌کند (Li et al., 2018). این اثر به‌ویژه در مناطقی که از سیستم‌های آبیاری استفاده می‌کنند، قابل توجه است. مطالعه‌ای در چین نشان داد که تغییرات کاربری زمین از بایر به کشاورزی، منجر به کاهش میانگین LST تا ۲ درجه سانتی‌گراد در منطقه مورد مطالعه شد (Zhang et al., 2017). باغ‌های زیتون به دلیل نیاز کمتر به آب و سازگاری با شرایط خشک، معمولاً در مناطق نیمه‌خشک و بایر ایجاد می‌شوند. این باغ‌ها می‌توانند LST را به‌ویژه در ماه‌های گرم سال کاهش دهند. مطالعه‌ای در منطقه مدیترانه نشان داد که باغ‌های زیتون، LST را به طور متوسط ۳ درجه سانتی‌گراد کمتر از زمین‌های بایر مجاور کاهش داده‌اند (Pérez-Luque et al., 2019). شالیزارها نیز به دلیل نیاز بالا به آب و پوشش گیاهی متراکم، نقش مهمی در کاهش LST دارند. آب موجود در شالیزارها به عنوان یک ذخیره حرارتی عمل می‌کند و تبخیر آب از سطح شالیزار باعث کاهش دمای محلی می‌شود. در یک مطالعه در مناطق جنوب آسیا، مشخص شد که تبدیل زمین‌های بایر به شالیزارها می‌تواند LST را تا ۵ درجه سانتی‌گراد کاهش دهد (Rahman et al., 2017).



شکل ۸. نقشه LST در سال‌های ۲۰۱۹ و ۲۰۲۳

بررسی تغییرات LST بین سال‌های ۲۰۱۹ و ۲۰۲۳ (جدول ۷) نشان داد تغییر کاربری و پوشش زمین بر مقدار حداکثر و حداقل دما نیز موثر بوده و دمای سطح زمین از حداکثر و حداقل ۳۶٫۴۸ و ۲۱٫۸ در سال ۲۰۱۹ به ۳۳٫۸۴ و ۱۹٫۶۷ در سال ۲۰۲۳ رسیده است. این نتایج نشان می‌دهد عوامل مختلفی مانند نوع پوشش گیاهی، تراکم گیاهی و فعالیت‌های انسانی می‌توانند بر LST تأثیر بگذارند. به طوری که تغییرات در پوشش زمین و سایر مشخصات سطح زمین (مانند تغییر کاربری اراضی، رویش گیاهان، ساخت و ساز و ...) می‌تواند باعث تغییرات قابل ملاحظه در دمای سطحی زمین شود. از این رو، در تحلیل تغییرات پوشش زمین و بررسی تأثیرات آن بر بودجه انرژی سطحی، باید به این عوامل توجه ویژه‌ای داشته باشیم.

نتایج این پژوهش تایید کننده نتایج پژوهش‌های اخیر است که در این زمینه توسط محققان دیگر صورت گرفته است. مثلاً امیری و همکاران (۲۰۲۳) در مطالعه‌ای با هدف بررسی اثر تغییرات کاربری و پوشش زمین بر LST به این نتیجه دست یافتند که مقدار LST در نتیجه تغییر کاربری و پوشش زمین تغییر می‌یابد. به طوری که افزایش پوشش گیاهی سبب کاهش LST و خشک شدن دریاچه‌ها سبب افزایش آن می‌شود. داماینتی و همکاران (۲۰۲۳) نیز به این نتیجه دست یافتند که تغییر دمای سطح خاک ارتباط نزدیکی با تغییر پوشش زمین دارد و در مناطقی که تغییر کاربری صورت گرفته، افزایش دمای خاک مشاهده شده است. به طور کلی می‌توان نتیجه گرفت تغییرات

کاربری زمین از بایر به کشاورزی، باغ‌های زیتون و شالیزارها تأثیرات مثبتی بر توزیع LST دارند. افزایش پوشش گیاهی و فرآیندهای تعرقی در این مناطق به کاهش دمای سطح زمین منجر می‌شود که می‌تواند به بهبود شرایط محیطی و کاهش اثرات تغییرات اقلیمی کمک کند. بررسی دقیق و مستمر این تغییرات با استفاده از داده‌های سنجنش از دور می‌تواند اطلاعات مفیدی برای مدیریت منابع طبیعی و برنامه‌ریزی محیط زیستی فراهم کند.

جدول ۷. مقادیر تغییرات LST در طول سال‌های مطالعه

| سال مطالعه | LST _{min} (°C) | LST _{max} (°C) |
|------------|----------------------------|----------------------------|
| ۲۰۱۹ | ۲۱ | ۳۶ |
| ۲۰۲۳ | ۱۹ | ۳۳ |

نتیجه‌گیری

در مطالعه حاضر، توانایی طبقه‌بندی‌کننده‌های مختلف در پلتفرم GEE برای تولید نقشه‌های دقیق کاربری اراضی و پوشش آن‌ها با هدف شناسایی بهترین طبقه‌بندی‌کننده، مورد بررسی قرار گرفت. نتایج نشان داد طبقه‌بندی‌کننده SVM با تصاویر سنتینل ۲ در این منطقه که شامل انواع مختلف کاربری زمین مانند: باغ زیتون، شالیزار، گستره‌های آبی، کاربری شهری و زمین بایر است، عملکرد بهتری نسبت به سایر طبقه‌بندی‌کننده‌ها دارد. تجزیه و تحلیل تشخیص تغییر در طول دوره مطالعه نشان داد مساحت کل پوشش گیاهی از مقدار ۱۵۷۴,۵ هکتار در سال ۲۰۱۹ به ۱۸۲۴,۸ هکتار در سال ۲۰۲۳ رسیده است. این افزایش در مساحت پوشش گیاهی سبب افزایش NDVI و کاهش دمای سطح زمین شده است. همچنین پلتفرم‌های محاسبات ابری مانند GEE و داده‌های ماهواره‌ای مانند سنتینل ۲ به‌طور قابل توجهی در بهبود نقشه‌برداری و پایش LULC کمک کرده‌اند. در نتیجه، طبقه‌بندی LULC با استفاده از تصاویر با وضوح مکانی بالا و الگوریتم SVM در پلتفرم گوگل ارث انجین، به عنوان یک روش دقیق و کارآمد برای ارزیابی تغییرات کاربری و پوشش زمین در دوره‌های زمانی مختلف می‌باشد. بنابراین این روش می‌تواند به عنوان یک ابزار مفید در برنامه‌ریزی و مدیریت منابع طبیعی و شهری، مانند برنامه‌ریزی کاربری اراضی و مدیریت منابع آب و خاک، مورد استفاده قرار گیرد. البته باید در نظر داشت اگرچه استفاده از داده‌های ماهواره‌ای در تحقیقات محیطی مزایای بسیاری دارد، اما برخی محدودیت‌ها نیز وجود دارد. برای مثال، این روش برای شناسایی کاربری و پوشش زمین در مناطقی که با ابر و مه پوشیده شده‌اند، دچار مشکل می‌شود و ضروری است تا از داده‌های رادار استفاده شود. پیشنهاد می‌شود در پژوهش‌های آینده برای تهیه نقشه کاربری و پوشش زمین از سایر الگوریتم‌های طبقه‌بندی مانند شبکه‌های عصبی مصنوعی و یادگیری عمیق استفاده شود و دقت سایر طبقه‌بندی‌ها بررسی شود. همچنین می‌توان به منظور افزایش دقت و کیفیت تولید نقشه‌های کاربری و پوشش زمین از ترکیب داده‌های ماهواره‌ای با داده‌های دیگر مانند داده‌های سنجنش از دور، داده‌های میدانی و داده‌های حاصل از مدل‌سازی استفاده شود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

- Abdi, A. M. (2020). Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience & Remote Sensing*, 57(1), 1-20.
- Abinaya, V., & Poonkuntran, S. (2019). Classification of satellite image using minimum distance classification algorithm. *SSRG Int J Comput Sci Eng (SSRG-IJCSE)*. Special. (15-18).
- Affonso, A. A., Mandai, S. S., Portella, T. P., Quintanilha, J. A., Conti, L. A., & Grohmann, C. H. (2023). A Comparison between Supervised Classification Methods: Study Case on Land Cover Change Detection Caused by a Hydroelectric Complex Installation in the Brazilian Amazon. *Sustainability*, 15(2), 1309.
- Ahady, A. B., & Kaplan, G. (2022). Classification comparison of Landsat-8 and Sentinel-2 data in Google Earth Engine, study case of the city of Kabul. *International Journal of Engineering and Geosciences*, 7(1), 24-31.
- 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.
- Alganci, U., Sertel, E., & Kaya, S. (2018). Determination of the olive trees with object based classification of

- Pleiades satellite image. *International Journal of Environment and Geoinformatics*, 5(2), 132-139.
- Amiri, A. M., & Dadaser-Celik, F. (2023). Multi-temporal assessment of land surface temperatures as an indicator of land use/cover changes and climate variability in the Develi Basin, Turkey. *Environmental Science and Pollution Research*, 30(30), 75549-75563.
- Basheer, S., Wang, X., Farooque, A. A., Nawaz, R. A., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of land use land cover classifiers using different satellite imagery and machine learning techniques. *Remote Sensing*, 14(19), 4978.
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote sensing of environment*, 204, 509-523.
- Bouslihim, Y., Kharrou, M. H., Miftah, A., Attou, T., Bouchaou, L., & Chehbouni, A. (2022). Comparing Pan-sharpened Landsat-8 and Sentinel-2 for Land-Use Classification Using Machine Learning Classifiers. *Journal of Geovisualization and Spatial Analysis*, 6(2), 35.
- Breiman, L. (2001). Random Forests. *Mach. Learn.* 45, 5–32.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46.
- da Cunha, E. R., Santos, C. A. G., da Silva, R. M., Bacani, V. M., & Pott, A. (2021). Future scenarios based on a CA-Markov land use and land cover simulation model for a tropical humid basin in the Cerrado/Atlantic forest ecotone of Brazil. *Land Use Policy*, 101, 105141.
- Daba, M. H., & You, S. (2022). Quantitatively assessing the future land-use/land-cover changes and their driving factors in the upper stream of the Awash River based on the CA-markov model and their implications for water resources management. *Sustainability*, 14(3), 1538.
- Damayanti, A., Khairunisa, F. I., & Maulidina, K. (2023). Impacts of Land Cover Changes on Land Surface Temperature using Landsat Imagery with the Supervised Classification Method. *Aceh International Journal of Science and Technology*, 12(1), 115-124.
- Das, S., & Sarkar, R. (2019). Predicting the land use and land cover change using Markov model: A catchment level analysis of the Bhagirathi-Hugli River. *Spatial Information Research*, 27(4), 439-452.
- Daulay, U. A., Ahmad, A. G., & Purwoko, A. (2023). Analysis of land cover change due to deforestation at Holiday Resort Nature Park, North Sumatra Province, Indonesia. *Journal of Sylva Indonesiana*, 6(01), 44-58.
- Edwards, S., Egziabher, T. B. G., & Araya, H. (2010). Successes and challenges in ecological agriculture experiences from Tigray, Ethiopia. *Tigray Project*.
- Gabriele, M., Brumana, R., Previtali, M., & Cazzani, A. (2022). A combined GIS and remote sensing approach for monitoring climate change-related land degradation to support landscape preservation and planning tools: the Basilicata case study. *Applied Geomatics*, 1-36.
- Gibril, M.B.A., Idrees, M.O., Yao, K., & Shafri, H.Z.M. (2018). Integrative image segmentation optimization and machine learning approach for high quality land-use and land-cover mapping using multisource remote sensing data. *Journal of Applied Remote Sensing*, 12(1), 016036.
- 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.
- Guha, S., & Govil, H. (2023). Evaluating the stability of the relationship between land surface temperature and land use/land cover indices: a case study in Hyderabad city, India. *Geology, Ecology, and Landscapes*, 1-13.
- Guha, S., Govil, H., Taloor, A. K., Gill, N., & Dey, A. (2022). Land surface temperature and spectral indices: A seasonal study of Raipur City. *Geodesy and Geodynamics*, 13(1), 72-82.
- Hasan, M. A., Mia, M. B., Khan, M. R., Alam, M. J., Chowdury, T., Al Amin, M., & Ahmed, K. M. U. (2023). Temporal Changes in Land Cover, Land Surface Temperature, Soil Moisture, and Evapotranspiration Using Remote Sensing Techniques—a Case Study of Kutupalong Rohingya Refugee Camp in Bangladesh. *Journal of Geovisualization and Spatial Analysis*, 7(1), 11.
- Hassan, Z., Shabbir, R., Ahmad, S. S., Malik, A. H., Aziz, N., Butt, A., & Erum, S. (2016). Dynamics of land use and land cover change (LULCC) using geospatial techniques: a case study of Islamabad Pakistan. *SpringerPlus*, 5(1), 1-11.



- Homer, C., Dewitz, J., Jin, S., Xian, G., Costello, C., Danielson, P., Gass, L., Funk, M., Wickham, J., Stehman, S., & Auch, R. (2020). Conterminous United States land cover change patterns 2001–2016 from the 2016 national land cover database. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 184-199.
- Hua, A. K., & Ping, O. W. (2018). The influence of land-use/land-cover changes on land surface temperature: a case study of Kuala Lumpur metropolitan city. *European Journal of Remote Sensing*, 51(1), 1049-1069.
- Khan, Z., Saeed, A., & Bazai, M. H. (2020). Land use/land cover change detection and prediction using the CA-Markov model: A case study of Quetta city, Pakistan. *Journal of Geography and Social Sciences*, 2(2), 164-182.
- Kolli, M.K., Opp, C., Karthe, D., & Groll, M. (2020). Mapping of major land-use changes in the Kolleru Lake freshwater ecosystem by using Landsat satellite images in Google Earth Engine. *Water*, 12(9), 2493.
- Kulithalai Shiyam Sundar, P., & Deka, P.C. (2022). Spatio-temporal classification and prediction of land use and land cover change for the Vembanad Lake system, Kerala: a machine learning approach. *Environmental Science and Pollution Research*, 29(57), 86220-86236.
- Kumari, B., Tayyab, M., Ahmed, I.A., Baig, M.R.I., Khan, M.F., & Rahman, A. (2020). Longitudinal study of land surface temperature (LST) using mono- and split-window algorithms and its relationship with NDVI and NDBI over selected metro cities of India. *Arabian Journal of Geosciences*, 13, 1-19.
- Liping, C., Yujun, S., & Saeed, S. (2018). Monitoring and predicting land use and land cover changes using remote sensing and GIS techniques—A case study of a hilly area, Jiangle, China. *PLoS One*, 13(7), e0200493.
- 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. *Sustainability*, 13(24), 13758.
- Loukika, K.N., Keesara, V.R., Buri, E.S., & Sridhar, V. (2022). Predicting the Effects of Land Use Land Cover and Climate Change on Munneru River Basin Using CA-Markov and Soil and Water Assessment Tool. *Sustainability*, 14(9), 5000.
- Lukas, P., Melesse, A.M., & Kenea, T.T. (2023). Prediction of Future Land Use/Land Cover Changes Using a Coupled CA-ANN Model in the Upper Omo–Gibe River Basin, Ethiopia. *Remote Sensing*, 15(4), 1148.
- McCarty, D.A., Kim, H.W., & Lee, H.K. (2020). Evaluation of light gradient boosted machine learning technique in large scale land use and land cover classification. *Environments*, 7(10), 84.
- Mollick, T., Azam, M.G., & Karim, S. (2023). Geospatial-based machine learning techniques for land use and land cover mapping using a high-resolution unmanned aerial vehicle image. *Remote Sensing Applications: Society and Environment*, 29, 100859.
- Murtaza, K.O., & Romshoo, S.A. (2014). Determining the suitability and accuracy of various statistical algorithms for satellite data classification. *International Journal of Geomatics and Geosciences*, 4(4), 585-599.
- Nasiri, V., Deljouei, A., Moradi, F., Sadeghi, S. M. M., & Borz, S. A. (2022). Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods. *Remote Sensing*, 14(9), 1977.
- Pandey, A., Mondal, A., Guha, S., Upadhyay, P. K., & Singh, D. (2023). A Long-Term Analysis of the Dependency of Land Surface Temperature on Land Surface Indexes. *Papers in Applied Geography*, 1-16.
- Pérez-Luque, A. J., Martínez-Cob, A., & Gil-Pelegrín, E. (2019). "Mapping Olive Orchards Using Landsat Imagery and Object-Based Image Analysis." *Agricultural Systems*, 170, 56-66.
- Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using Google Earth Engine and random forest classifier—The role of image composition. *Remote Sensing*, 12(15), 2411.
- Rahman, A., Abdullah, H. M., Tanzir, M. T., Hossain, M. J., Khan, B. M., Miah, M. G., & Islam, I. (2020). Performance of different machine learning algorithms on satellite image classification in rural and urban setup. *Remote Sensing Applications: Society and Environment*, 20, 100410.
- Rahman, M. M., & Ahmed, K. S. (2017). "Assessing the Impact of Paddy Fields on Vegetation Dynamics Using NDVI." *Journal of Environmental Management*, 193, 385-393.
- Rana, V. K., & Suryanarayana, T. M. V. (2020). Performance evaluation of MLE, RF and SVM classification

- algorithms for watershed scale land use/land cover mapping using sentinel 2 bands. *Remote Sensing Applications: Society and Environment*, 19, 100351.
- Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy assessment of land use/land cover classification using remote sensing and GIS. *International Journal of Geosciences*, 8(04), 611.
- Shetty, S. (2019). Analysis of machine learning classifiers for LULC classification on Google Earth Engine (Master's thesis, University of Twente).
- Simonetti, D., Simonetti, E., Szantoi, Z., Lupi, A., & Eva, H. D. (2015). First results from the phenology-based synthesis classifier using Landsat 8 imagery. *IEEE Geoscience and Remote Sensing Letters*, 12(7), 1496-1500.
- Sridhar, V., Kang, H., & Ali, S. A. (2019). Human-induced alterations to land use and climate and their responses for hydrology and water management in the Mekong River Basin. *Water*, 11(6), 1307.
- Sujatha, E. R., & Sridhar, V. (2018). Spatial Prediction of Erosion Risk of a small mountainous watershed using RUSLE: A case-study of the Palar sub-watershed in Kodaikanal, South India. *Water*, 10(11), 1608.
- Szostak, M., Likus-Cieślak, J., & Pietrzykowski, M. (2021). PlanetScope Imageries and LiDAR Point Clouds Processing for Automation Land Cover Mapping and Vegetation Assessment of a Reclaimed Sulfur Mine. *Remote Sensing*, 13(14), 2717.
- Szuster, B. W., Chen, Q., & Borger, M. (2011). A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography*, 31(2), 525-532.
- Talukdar, S., Singha, P., Mahato, S., 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.
- 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.
- Tassi, A., & Vizzari, M. (2020). Object-oriented lulc classification in Google Earth Engine combining snic, glcm, and machine learning algorithms. *Remote Sensing*, 12(22), 3776.
- Teluguntla, P., Thenkabail, P. S., Oliphant, A., Xiong, J., Gumma, M. K., Congalton, R. G., Yadav, K., & Huete, A. (2018). A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 325-340.
- Tewkesbury, A. P., Comber, A. J., Tate, N. J., Lamb, A., & Fisher, P. F. (2015). A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment*, 160, 1-14.
- Thanh Noi, P., & Kappas, M. (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 18(1), 18.
- Tilahun, A., & Teferie, B. (2015). Accuracy assessment of land use land cover classification using Google Earth. *American Journal of Environmental Protection*, 4(4), 193-198.
- Waleed, M., Sajjad, M., Acheampong, A. O., & Alam, M. T. (2023). Towards Sustainable and Livable Cities: Leveraging Remote Sensing, Machine Learning, and Geo-Information Modeling to Explore and Predict Thermal Field Variance in Response to Urban Growth. *Sustainability*, 15(2), 1416.
- Wang, Y., Ziv, G., Adami, M., Mitchard, E., Batterman, S.A., Buermann, W., Marimon, B.S., Junior, B.H.M., Reis, S.M., Rodrigues, D., & Galbraith, D. (2019). Mapping tropical disturbed forests using multi-decadal 30 m optical satellite imagery. *Remote Sensing of Environment*, 221, 474-488.
- Xiao, Y., Hao, Q., Zhang, Y., Zhu, Y., Yin, S., Qin, L., & Li, X. (2022). Investigating sources, driving forces and potential health risks of nitrate and fluoride in groundwater of a typical alluvial fan plain. *Science of the Total Environment*, 802, 149909.
- Yifru, B.A., Chung, I.M., Kim, M.G., & Chang, S.W. (2021). Assessing the effect of land/use land cover and climate change on water yield and groundwater recharge in East African Rift Valley using integrated model. *Journal of Hydrology: Regional Studies*, 37, 100926.
- Yuh, Y.G., Tracz, W., Matthews, H.D., & Turner, S.E. (2023). Application of machine learning approaches for land cover monitoring in northern Cameroon. *Ecological Informatics*, 74, 101955.



- Zhao, M., Cai, H., Qiao, Z., & Xu, X. (2016). Influence of urban expansion on the urban heat island effect in Shanghai. *International Journal of Geographical Information Science*, 30(12), 2421-2441.
- Zhao, Q., Yu, L., Li, X., Peng, D., Zhang, Y., & Gong, P. (2021). Progress and trends in the application of Google Earth and Google Earth Engine. *Remote Sensing*, 13(18), 3778.
- Zhu, Z. (2017). Change detection using Landsat time series: A review of frequencies, preprocessing, algorithms, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 370-384.