Shahid Chamran University of Ahvaz
OPEN ACCESS Adv. Appl. Geol. Summer 2026, Vol. 16(2): 121 - 146

Research Article

Phenology-Based Mapping of Rice Paddies Using Satellite Imagery and Machine Learning Methods: A Case Study of Bavi County

Arman Joveili[1], Ahad Nazarpour[2]*

1- Department of Remote Sensing and GIS, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran
2- Department of Geology, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran

Abstract
Accurate monitoring of the growth patterns and spatial distribution of paddy rice cultivation in areas dependent on surface water resources is essential for sustainable water-resource management and irrigation planning. The aim of this study was to develop a multi-source framework for phenological analysis and mapping of paddy rice cultivation by integrating Sentinel-2 optical and Sentinel-1 radar data within the Google Earth Engine (GEE) platform in northern Bavi County and the agricultural lands surrounding the Karun River. To this end, time series of NDVI, EVI, and LAI were analyzed over the period from 2022 to 2025 to characterize the temporal growth dynamics and phenological stages of paddy rice. Based on the resulting temporal patterns, the growth stages and peak greenness of paddy rice were identified, and an appropriate time window was selected for generating the final 2025 cultivation map. For classification, optical features were integrated with Sentinel-1 radar backscatter features, including VV and VH polarizations, and three machine-learning algorithms, namely Support Vector Machine (SVM), k-Nearest Neighbors (KNN), and Random Forest (RF), were evaluated. Model performance was assessed using an independent validation dataset. The results showed that Random Forest achieved the best classification performance, with an overall accuracy of 91.51% and a Kappa coefficient of 0.9310. Based on the final classification map, the paddy rice cultivation area within the study area was estimated at 7,457 ha in 2025. The proposed framework, through the integration of optical, radar, and temporal information, can support monitoring of cultivated areas, assessment of crop condition and water stress, and provision of spatial information for water-resource allocation, irrigation planning, and cropping-pattern management. When integrated with complementary information such as evapotranspiration, climate, soil, and irrigation data, the resulting rice distribution maps can also serve as a basis for assessing crop water requirements and supporting more informed water-resource management.

Keywords: *Remote sensing, Machine learning, Paddy rice, Karun River.*

1-Introduction

Rice paddy cultivation is among the world's most strategic agricultural systems due to its critical role in food security. As a carbohydrate-rich staple, rice provides a major share of daily energy intake for a large portion of the global population, while also contributing protein, vitamins, and essential minerals, thereby supporting public health and helping alleviate malnutrition (Mohapatra et al., 2021; Zhao et al., 2020). In Iran, although rice production is mainly concentrated in the northern provinces, Khuzestan Province has become an important production pole in the south because of its access to surface-water resources and suitable agricultural lands (Eyni-Nargeseh et al., 2023; Karimi et al., 2025). In the northern part of Bavi County, a considerable share of downstream farmlands depends directly on the hydrological regime of the Karun River, the principal water-supply artery in southwest Iran (Yazdanpanah Dero et al., 2025). However, the dominance of traditional flood irrigation for summer rice cultivation and reliance on electric

* Corresponding author: Ahad.Nazarpour@iau.ac.ir
DOI: 10.22055/aag.2026.52453.2577
Received: 2026-07-18
Accepted: 2026-09-09

ISSN: 2717-0764

pumps and diesel engines for water conveyance have increased production costs and energy use while reducing water-use efficiency. These challenges have been further intensified by recent hydrological fluctuations, declining Karun River discharge, and groundwater-level depletion, which together have increased the vulnerability of the local agricultural production system to water stress and climate variability (Granata et al., 2025). Under these conditions, continuous monitoring and improved water-management strategies are essential. Remote sensing (RS), supported by satellite imagery and data-processing techniques, provides timely and spatially extensive information on field conditions and offers a cost-effective alternative to labor-intensive ground surveys, particularly for large and water-demanding crops such as rice (Sishodia et al., 2020). Satellite observations enable the assessment of crop growth status, water-stress signals, and spatiotemporal dynamics of cultivated areas, facilitating evidence-based decision-making for sustainable agricultural management (Rabie et al., 2025; Wu et al., 2023). Accordingly, this study aims to monitor and analyze the spatiotemporal patterns of rice paddy cultivation in northern Bavi County using remote sensing approaches, with the ultimate goal of supporting improved water-use efficiency and more sustainable agricultural resource management in the Karun River basin.

2- Material and methods

This study aimed to identify and map rice paddy cultivation during the summer of 2025. The input data comprised optical Sentinel-2 imagery and Sentinel-1 SAR data. A Sentinel-2 image collection from January to September 2025 was selected to compute vegetation indices, namely the Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI), and Leaf Area Index (LAI), and to analyze crop growth trajectories throughout the growing season. Sentinel-1 data were used as complementary radar information and were integrated with the optical dataset to improve the discrimination of rice fields.

In the preprocessing stage, the images were filtered, and cloud- and shadow-affected pixels in Sentinel-2 scenes were masked. Vegetation indices were then calculated for all images, and monthly mean NDVI was derived to extract a time-series signal. To detect similar vegetation-behavior patterns and to infer the crop calendar during the summer season, a heatmap matrix was generated in MATLAB. In addition, the mean value of each index for each sampling area was calculated in Google Earth Engine (GEE) to delineate greenness dynamics more robustly. Land-cover classification was performed using the Random Forest algorithm to separate major classes including rice, legumes, sugarcane, bare land, and non-cultivated areas. Field samples and ground control points were used as training data, and radar-derived features were added to the model to enhance the separability of rice paddies. Model validation was conducted using an independent subset of field samples, and classification performance was quantified using a confusion matrix. The study outputs include monthly and aggregated vegetation-index maps, a preliminary classification map, and a final rice paddy distribution map for summer 2025 (Figure 2).

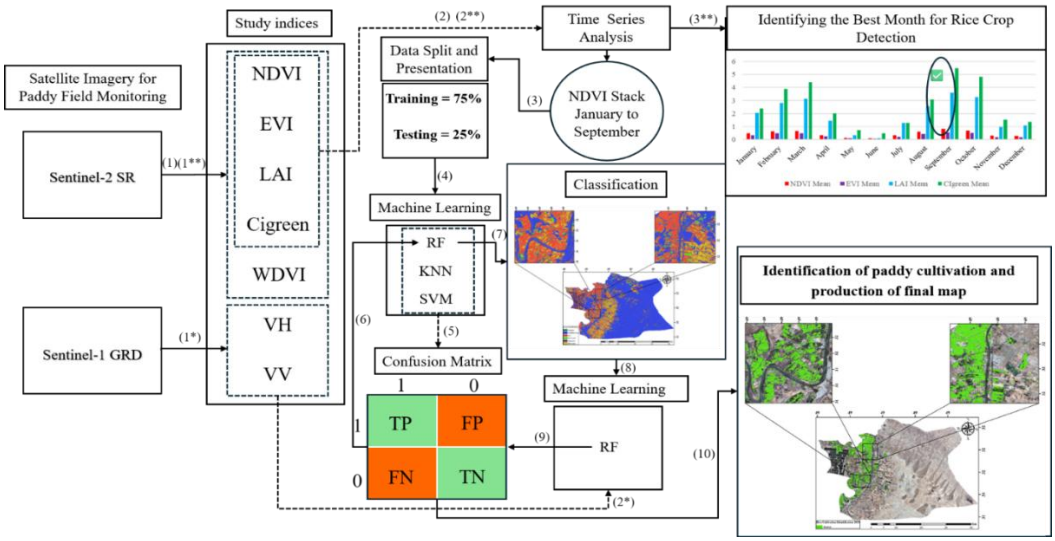


Fig. 2. Flowchart of the methodology for paddy field identification.

ISSN: 2717-0764

3- Results and discussions

The integration of optical Sentinel-2 and Sentinel-1 SAR data provided an effective framework for identifying and mapping rice paddy fields in northern Bavi County and the agricultural lands adjacent to the Karun River. Time-series analysis of NDVI, EVI, and LAI revealed a clear phenological pattern for rice cultivation throughout the 2025 growing season. At the beginning of the season, corresponding to field flooding and transplanting, NDVI values remained relatively low because standing water and saturated soils reduced spectral contrast. Under these conditions, EVI proved more reliable, as it better minimized background and moisture effects and captured early canopy development more clearly. LAI also showed a gradual increase during this stage, reflecting the onset of leaf-area expansion. During the peak growth period, approximately from July to August, all three indicators increased markedly, with NDVI and EVI generally ranging from 0.7 to 0.9 and LAI reaching about 5–6, indicating maximum canopy density. However, NDVI approached saturation at high biomass levels, whereas EVI retained greater sensitivity to subtle canopy variations. Toward the end of the season, all three indices declined consistently due to chlorophyll reduction, canopy senescence, and harvest-related vegetation loss. These results indicate that although NDVI is suitable for general vegetation monitoring, EVI and LAI provide a more robust basis for phenological discrimination of rice under flooded-field conditions. The three-year NDVI time-series analysis (2022–2025) further confirmed the seasonal behavior of rice in the study area, showing low values during early establishment, a progressive increase through summer, and a decline in autumn. The maximum greenness consistently occurred in September, identifying this month as the representative period of full canopy development in 2025. Based on this phenological pattern, monthly NDVI layers from January to September 2025 were stacked to construct a continuous temporal dataset, which improved the selection of training samples by relying on actual crop-growth behavior rather than a single-date spectral response. This approach enhanced the reliability of rice field detection and strengthened the distinction between rice and other agricultural classes. For final classification, field observations were integrated with training samples representing rice, summer crops, evergreen vegetation, winter crops, and non-cultivated lands. Spectral indices derived from Sentinel-2, including NDVI, EVI, WDVI, LAI, and CIgreen, were combined with Sentinel-1 VV and VH radar backscatter to improve class separability. The Random Forest classifier trained with 100 decision trees showed satisfactory performance in distinguishing rice paddies from other land-cover classes. To improve spatial consistency, patches smaller than 1 ha were removed from the final map. After this post-processing step, the total extent of single-season rice cultivation in 2025 was estimated at 7,457 ha. The overall workflow and the final rice paddy distribution map are presented in Figure 2. These findings demonstrate that integrating phenological analysis with optical-radar data fusion can provide a reliable basis for rice mapping and can serve as a practical support tool for irrigation planning, hydrological modeling, and sustainable agricultural water management in water-stressed environments.

ISSN: 2717-0764
CC BY

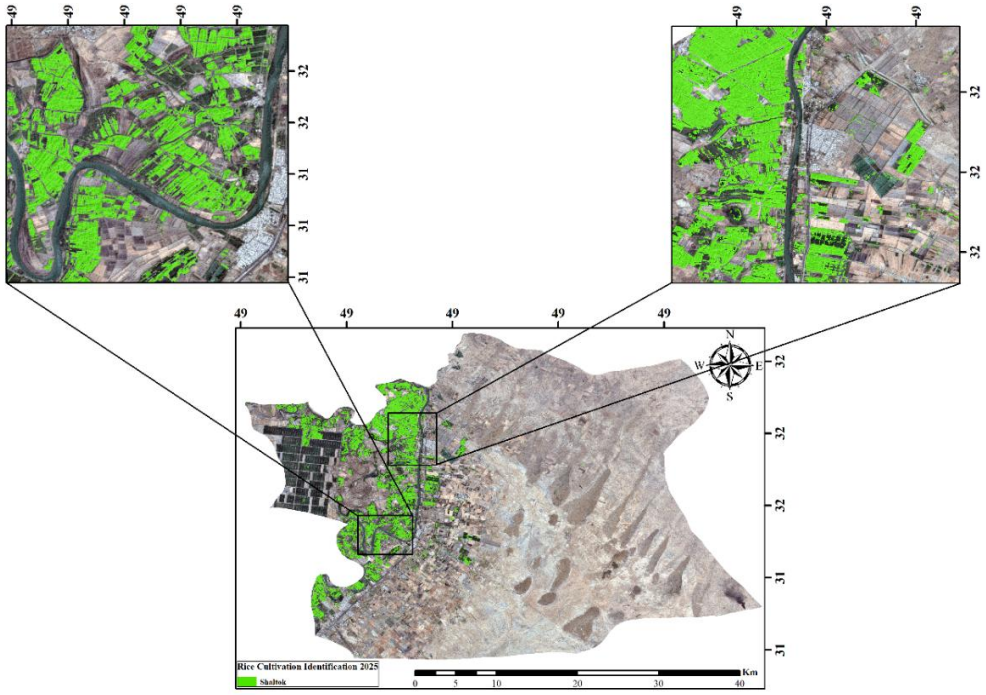


Fig. 7. Final map of paddy rice distribution in Bavi County and the surrounding areas of the Karun River,

4- Conclusion

This study adopted a multi-source remote-sensing approach to accurately identify rice paddies and monitor rice growth stages in northern Bavi County and the agricultural lands adjacent to the Karun River during the 2025 season. Phenology-based analyses derived from NDVI, EVI, and LAI time series indicated a distinctive spectral–biophysical trajectory for rice in the region, with peak greenness and maximum leaf area consistently occurring in September. In the modelling and classification phase, the methodology was designed around a comparative assessment of three widely used machine-learning algorithms (KNN, SVM, and Random Forest). Although all three models were able to separate major land-use/land-cover classes, Random Forest exhibited superior robustness, particularly in reducing spectral noise and capturing complex patterns associated with rice cultivation in high-dimensional feature spaces. Accordingly, the final mapping step relied on a retrained Random Forest model using the optimal feature set extracted from Sentinel-2 optical vegetation indices and Sentinel-1 SAR backscatter (VV and VH polarizations), producing the final rice distribution map. Accuracy assessment using confusion matrices, overall accuracy, and the Kappa coefficient confirmed the reliability of the outputs. The high performance is attributed to the complementary integration of SAR information—sensitive to canopy structure and surface moisture with optical vegetation indicators, which together reduced cloud-related limitations and improved model stability. Based on the final map, the rice cultivated area within the study region in 2025 was estimated at 7,457 ha. Overall, the results demonstrate that combining remote sensing and machine learning can provide a strategic tool for water-resources management in the Karun Basin. Under increasing pressure on surface water and climate-related stress in the Bavi region, the study outputs can support precision agriculture, realistic irrigation-demand estimation, and optimized water allocation during critical periods (e.g., peak summer water demand), ultimately facilitating the deployment of smart irrigation systems and improving water-use efficiency.

5- References

Eyni-Nargeseh, H., Asgharipour, M.R., Rahimi-Moghaddam, S., Gilani, A., Damghani, A.M., Azizi, K., 2023. Which rice farming system is more environmentally friendly in Khuzestan province, Iran? A study based on emergy analysis. Ecological Modelling 481, 110373. https://doi.org/10.1016/j.ecolmodel.2023.110373

ISSN: 2717-0764
CC BY

Granata, F., Zhu, S., Di Nunno, F., 2025. Hydrological extremes in the Mediterranean basin: interactions, impacts, and adaptation in the face of climate change. Regional Environmental Change 25, 100. https://doi.org/10.1007/s10113-025-02432-7

Karimi, M., Ahmadi Nadoushan, M., Chavoshi, E., 2025. A decade-long spatial analysis of opportunistic rice cultivation in a water-stressed agricultural landscape. Environmental Monitoring and Assessment 197, 216. https://doi.org/10.1007/s10661-025-13656-9

Mohapatra, P.K., Sahu, B.B., 2022. Importance of Rice as Human Food. In: Panicle Architecture of Rice and its Relationship with Grain Filling. Springer, Cham. https://doi.org/10.1007/978-3-030-67897-5_1

Omurzakov, K., Koshmatov, B., Musabaeva, K., Askaraliev, B., Dzhakshylykova, Z., 2024. Development of modern irrigation systems for improving efficiency, reducing water consumption, and increasing yields. Machinery and Energetics 15 (3). https://doi.org/10.31548/machinery/3.2024.47

Rabie, A.B., Elhag, M., Subyani, A. 2025. Remote sensing, GIS, and machine learning in water resources management for arid agricultural regions: A review. Water, 17(21), 3125. DOI: https://doi.org/10.3390/w17213125

Sishodia, R.P., Ray, R.L., Singh, S.K., 2020. Applications of remote sensing in precision agriculture: A review. Remote Sensing 12 (19), 3136. https://doi.org/10.3390/rs12193136

Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A. B., Qin, X., Loupian, E., 2023. Challenges and opportunities in remote sensing-based crop monitoring: A review. National Science Review 10 (4), nwac290. https://doi.org/10.1093/nsr/nwac290

Yazdanpanah Dero, Q., Sharif, M., Nikzad Samarin, A., Naseri, A.A., Mohammadi, H.R., 2025. Monitoring of water resources based on remote sensing and ground data: a comprehensive analysis of human and climate impact. Modeling Earth Systems and Environment 11 (1), 24. https://doi.org/10.1007/s40808-024-02193-y

Zhao, M., Lin, Y., Chen, H., 2020. Improving nutritional quality of rice for human health. Theoretical and Applied Genetics 133 (5), 1397-1413. https://doi.org/10.1007/s00122-019-03530-x

HOW TO CITE THIS ARTICLE:
Joveili, A., Nazarpour, A,. 2026. Phenology Based Mapping of Rice Paddies Using Satellite Imagery and Machine Learning Methods: A Case Study of Bavi County. Adv. Appl. Geol. 16 (2), 121-146.
DOI: 10.22055/aag.2026.52453.2577
https://aag.scu.ac.ir/article_20919.html

©2026 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers

ISSN: 2717-0764

مقاله پژوهشی

پایش فنولوژیک و نقشه‌برداری کشت شلتوک با تلفیق تصاویر سنتینل-۱ و سنتینل-۲ و یادگیری ماشین در محیط گوگل ارث انجین: اراضی پایین‌دست رودخانه کارون

آرمان جویلی

گروه سنجش از دور و سیستم اطلاعات جغرافیایی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

احد نظرپور

گروه زمین‌شناسی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

Ahad.nazarpour@iau.ac.ir.com

تاریخ دریافت: ۱۴۰۵/۰۴/۲۷ تاریخ پذیرش: ۱۴۰۵/۰۶/۱۸

چکیده

پایش دقیق الگوی رشد و پراکنش فضایی کشت شلتوک در مناطق وابسته به منابع آب سطحی، برای مدیریت پایدار منابع آب و برنامه‌ریزی آبیاری ضروری است. هدف این پژوهش، ارائه چارچوبی چندمنبعی برای تحلیل الگوی فنولوژیک و نقشه‌برداری کشت شلتوک با تلفیق داده‌های اپتیکی سنتینل-۲ و راداری سنتینل-۱ در محیط گوگل ارث انجین در شمال شهرستان باوی و اراضی پیرامون رودخانه کارون است. بدین منظور، سری زمانی شاخص‌های NDVI، EVI و LAI طی دوره ۲۰۲۲ تا ۲۰۲۵ بررسی شد و بر اساس الگوی زمانی حاصل، مراحل رشد و زمان اوج سبزینگی شلتوک تعیین و بازه مناسب برای تهیه نقشه نهایی کشت در سال ۲۰۲۵ انتخاب گردید. در مرحله طبقه‌بندی، ویژگی‌های اپتیکی و داده‌های راداری VV و VH با استفاده از الگوریتم‌های ماشین بردار پشتیبان، نزدیک‌ترین همسایه و جنگل تصادفی به‌کار گرفته شدند و عملکرد مدل‌ها با داده‌های اعتبارسنجی مستقل ارزیابی شد. نتایج نشان داد که جنگل تصادفی با دقت کلی ۹۱/۵۱ درصد و ضریب کاپای ۰/۹۳۱۰ بهترین عملکرد را داشت. بر اساس نقشه نهایی، سطح زیرکشت شلتوک در محدوده مورد مطالعه ۷۴۵۷ هکتار برآورد شد. چارچوب پیشنهادی می‌تواند برای پایش سطح زیرکشت، ارزیابی وضعیت و تنش آبی، پشتیبانی از تخصیص منابع آب و برنامه‌ریزی آبیاری و الگوی کشت مورد استفاده قرار گیرد.

واژه‌های کلیدی: *سنجش از دور، رودخانه کارون، شلتوک، یادگیری ماشین.*

۱-مقدمه

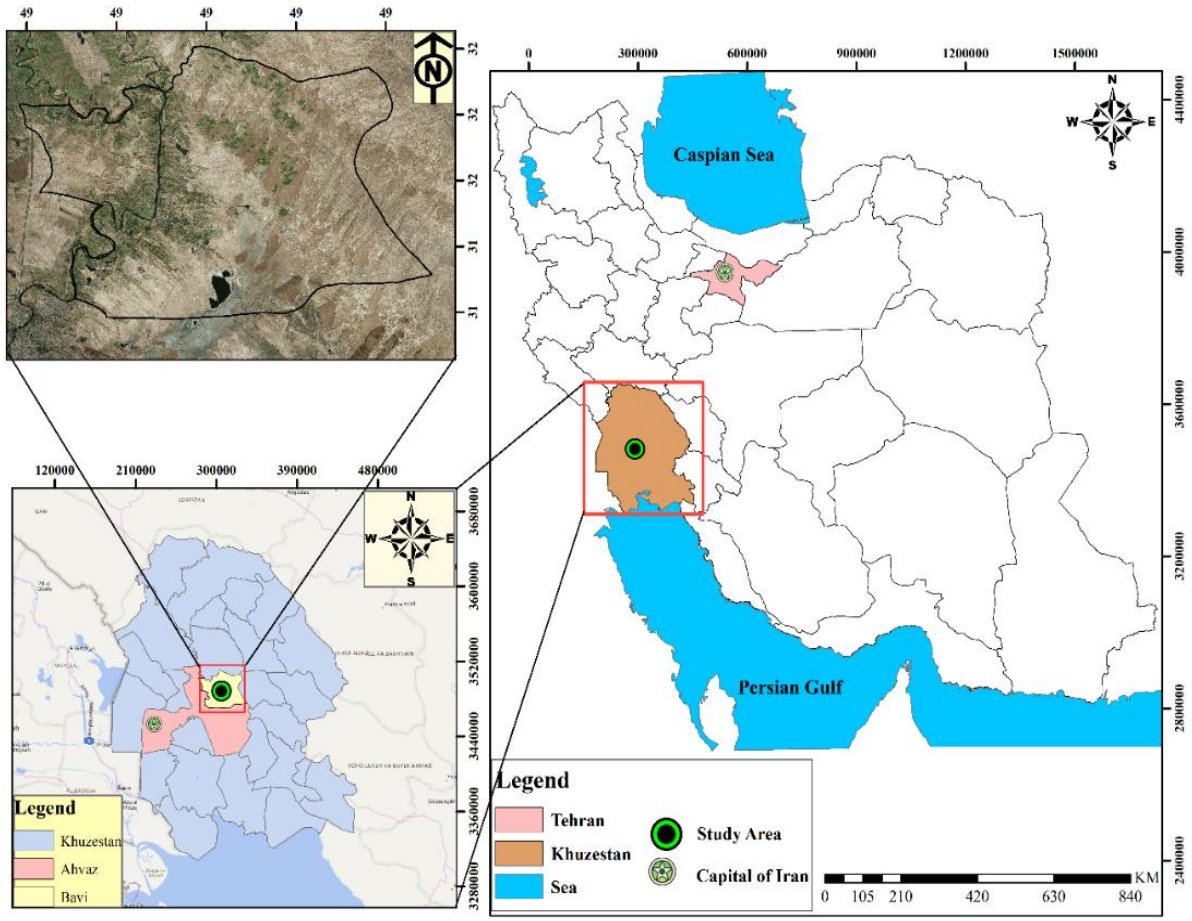
برنج غذای اصلی بیش از نیمی از جمعیت جهان است و تولید جهانی آن بیش از ۵۱۸ میلیون تن در سال گزارش شده است. عمده کشورهای تولیدکننده برنج در آسیا، شامل چین، ژاپن، اندونزی و تایلند، قرار دارند (Rastmanesh et al., 2019). افزون بر این، برنج حاوی مقادیر قابل‌توجهی پروتئین، ویتامین‌ها و عناصر معدنی است؛ ازاین‌رو می‌تواند در ارتقای سلامت عمومی و کاهش پیامدهای سوءتغذیه نقش مؤثری داشته باشد. اهمیت تغذیه‌ای این محصول به‌حدی است که در بسیاری از کشورهای آسیایی و بخش‌هایی از قاره آفریقا، بخش اصلی الگوی مصرف غذایی را تشکیل می‌دهد (Zhao et al., 2020). در ایران نیز کشت شلتوک جایگاهی مهم در نظام تولیدات کشاورزی دارد و سهم قابل‌توجهی در اقتصاد کشاورزی کشور ایفا می‌کند (Eyni- Nargeseh et al., 2023). اگرچه بخش عمده تولید برنج در استان‌های شمالی، به‌ویژه مازندران و گیلان، متمرکز است، استان خوزستان نیز به‌دلیل برخورداری از منابع آب سطحی و اراضی مستعد، به یکی از قطب‌های مهم تولید برنج در جنوب کشور تبدیل شده است (Karimi et al., 2025). این ظرفیت تولیدی، ضرورت مدیریت کارآمد منابع و بهره‌گیری از رویکردهای علمی را برجسته‌تر می‌کند. در شرایط کنونی، بهره‌گیری از فناوری‌های نوین برای ارتقای کارایی سامانه‌های کشاورزی ضروری است. سنجش از دور، به‌عنوان یکی از ابزارهای پیشرفته در این حوزه، با اتکا به تصاویر ماهواره‌ای و روش‌های پردازش داده، امکان استخراج اطلاعات دقیق و به‌هنگام از وضعیت مزارع را فراهم می‌کند (Sishodia et

al., 2020). این فناوری به‌ویژه در کشت‌های وسیع و آب‌بر مانند برنج که پایش میدانی آن‌ها مستلزم زمان و هزینه قابل‌توجه است، کارآمدی بالایی دارد. در مقایسه با روش‌های سنتی برداشت داده‌های میدانی، سنجش از دور پوشش گسترده‌تر، تکرارپذیری زمانی مناسب و دسترسی به داده‌های به‌روز را فراهم می‌کند و بدین‌ترتیب زمینه تصمیم‌گیری مبتنی بر داده را مهیا می‌سازد. رودخانه کارون، به‌عنوان اصلی‌ترین شریان تأمین آب در جنوب‌غرب ایران، نقشی محوری در پشتیبانی از فعالیت‌های کشاورزی دارد(Yazdanpanah Dero et al., 2025). این رودخانه از ارتفاعات زاگرس سرچشمه می‌گیرد و پس از عبور از استان خوزستان، در نهایت به سامانه آبی شط‌العرب می‌پیوندد (Yazdanpanah Dero et al., 2025). در منطقه مورد مطالعه واقع در بخش شمالی شهرستان باوی، بخش قابل‌توجهی از اراضی کشاورزی پایین‌دست به جریان این رودخانه وابسته است و الگوی کشت نیز به میزان دسترسی به منابع آب سطحی کارون وابستگی مستقیم دارد. با وجود این ظرفیت آبی، شیوه‌های آبیاری غالب در منطقه همچنان مبتنی بر روش‌های سنتی است. استفاده از پمپ‌های برقی و موتورهای دیزلی برای انتقال آب به مزارع، ضمن افزایش مصرف انرژی و هزینه‌های تولید، بهره‌وری مصرف آب را کاهش می‌دهد و به اتلاف بخشی از منابع آبی منجر می‌شود. این وابستگی شدید به جریان‌های سطحی، به‌ویژه در دوره‌های کاهش بارندگی و افت دبی رودخانه، آسیب‌پذیری نظام تولید کشاورزی را تشدید کرده است (Granata et al., 2025). در سال‌های اخیر، نوسانات هیدرولوژیک، کاهش آورد رودخانه کارون و افت سطح آب‌های زیرزمینی، محدودیت‌هایی در تأمین آب مورد نیاز کشت تابستانه برنج ایجاد کرده است. تداوم این روند می‌تواند فشار مضاعفی بر منابع آب وارد کند و پایداری تولید و امنیت غذایی منطقه را با چالش مواجه سازد. در منطقه مورد مطالعه، الگوی کشت به‌گونه‌ای است که برنج عمدتاً در فصل گرم سال و به‌صورت غرقابی کشت می‌شود، در حالی‌که گندم در فصل سرد و با نیاز آبی کمتر تولید می‌گردد. این وابستگی فصلی به منابع آب سطحی، در شرایط تغییرات اقلیمی و کاهش بارش، مسائل مدیریتی متعددی ایجاد کرده است. در چنین شرایطی، بهره‌گیری از فناوری‌های نوین، از جمله سنجش از دور و سامانه‌های بهینه مدیریت آبیاری، می‌تواند راهکاری مؤثر برای ارتقای بهره‌وری مصرف آب در منطقه مورد مطالعه باشد (Rabie et al., 2024). داده‌های ماهواره‌ای امکان پایش دقیق وضعیت رشد گیاه، تنش آبی، تغییرات سطح زیرکشت و روندهای زمانی را فراهم می‌کند (Wu et al., 2023). استفاده هدفمند از این اطلاعات، ضمن کاهش اتلاف منابع، زمینه تصمیم‌گیری مبتنی بر شواهد را برای مدیریت پایدار کشاورزی فراهم می‌کند و می‌تواند نقش مهمی در کاهش آسیب‌پذیری بخش کشاورزی و حرکت به سوی توسعه پایدار در منطقه ایفا کند(Wu et al., 2023). ازاین‌رو، پژوهش حاضر با هدف ارائه یک چارچوب چندمنبعی برای تحلیل الگوی فنولوژیک و نقشه‌برداری کشت شلتوک در شمال شهرستان باوی و اراضی پیرامون رودخانه کارون انجام شد. در این پژوهش، سری زمانی شاخص‌های پوشش گیاهی در دوره ۲۰۲۲ تا ۲۰۲۵ برای بررسی الگوی رشد شلتوک تحلیل شد و سپس با تلفیق داده‌های اپتیکی سنتینل-۲ و داده‌های راداری سنتینل-۱، سه الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان، نزدیک‌ترین همسایه و جنگل تصادفی برای تفکیک مزارع به‌کار گرفته شدند. در نهایت، عملکرد مدل‌ها ارزیابی و نقشه پراکنش کشت شلتوک برای سال ۲۰۲۵ تهیه شد. این چارچوب می‌تواند اطلاعات مکانی لازم برای پایش سطح زیرکشت و پشتیبانی از برنامه‌ریزی آبیاری، تخصیص منابع آب و مدیریت الگوی کشت را فراهم کند.

۲-محدوده مورد مطالعه

رودخانه کارون، به‌عنوان مهم‌ترین و پرآب‌ترین رودخانه استان خوزستان، یکی از اصلی‌ترین منابع تأمین آب در جنوب‌غرب کشور به‌شمار می‌رود (Bahiraie et al., 2025). این رودخانه از ارتفاعات زاگرس سرچشمه می‌گیرد و پس از طی مسیری طولانی و عبور از دشت‌های آبرفتی حاصلخیز، در نهایت به سامانه آبی شط‌العرب متصل می‌شود (Salman and Jazaa, 2023). کارون به دلیل گستره حوضه آبریز و حجم جریان سالانه، نقشی بنیادین در تأمین نیازهای آبی کشاورزی، شرب و صنعت دارد و از ارکان اصلی پایداری اقتصادی در این بخش از کشور محسوب می‌شود (Gharibreza et al., 2023). در منطقه مورد مطالعه واقع

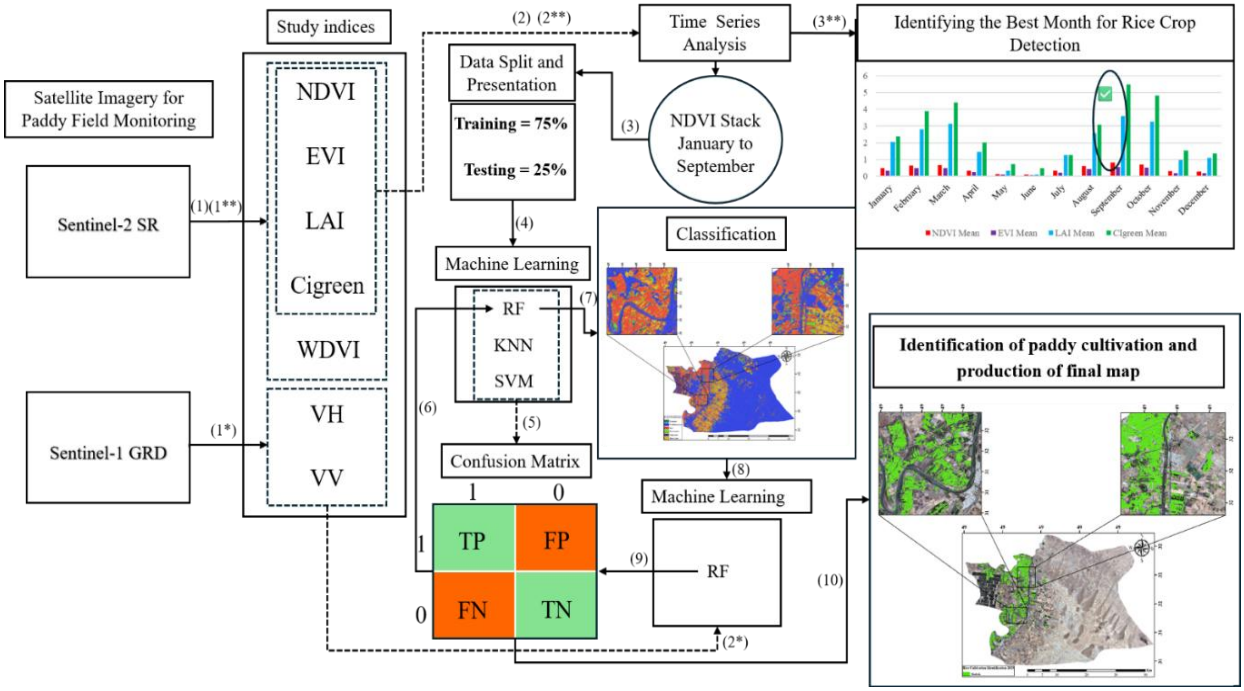
در شهرستان باوی، وابستگی اراضی کشاورزی به منابع آب سطحی کارون بسیار قابل‌توجه است (Dakhili et al., 2025). این محدوده به‌دلیل قرارگیری در دشت‌های هموار و مستعد، ظرفیت بالایی برای تولید محصولات زراعی دارد و بخش عمده فعالیت‌های کشاورزی آن بر پایه آب این رودخانه استوار است (Dakhili et al., 2025). محصولات راهبردی نظیر برنج، گندم و ذرت در اراضی پایین‌دست کشت می‌شوند و استمرار تولید آن‌ها به وضعیت هیدرولوژیک کارون وابستگی مستقیم دارد. آب رودخانه کارون، به‌واسطه تغذیه از زیرحوضه‌های کوهستانی و جریان نسبتاً پایدار در شرایط نرمال اقلیمی، از کیفیت مناسبی برای مصارف کشاورزی برخوردار است (Abdi-Dehkordi et al., 2021). این ویژگی در منطقه مورد مطالعه، امکان توسعه کشت‌های متنوع به‌ویژه محصولات با نیاز آبی بالا را فراهم کرده و در ارتقای بهره‌وری اراضی نقش مؤثری داشته است. ازاین‌رو، بخش کشاورزی این محدوده به‌طور ساختاری به تداوم جریان و مدیریت بهینه منابع آب کارون وابسته است. افزون بر کارکرد کشاورزی، رودخانه کارون سهم مهمی در تأمین آب شرب و نیازهای صنعتی سکونتگاه‌های شهری و روستایی پیرامون منطقه مورد مطالعه دارد. این کارکرد چندمنظوره، اهمیت راهبردی رودخانه را در ساختار اقتصادی و اجتماعی بخش شمالی شهرستان باوی دوچندان کرده است (Gharibreza et al., 2023). در مجموع، پایداری منابع آب کارون و مدیریت علمی آن، از الزامات اساسی تداوم توسعه کشاورزی و تقویت بنیان‌های اقتصادی و اجتماعی در منطقه مورد مطالعه به‌شمار می‌رود. موقعیت جغرافیایی منطقه مورد مطالعه در شمال شهرستان باوی، استان خوزستان، به‌همراه جایگاه آن در مقیاس ملی و محلی، در (شکل ۱) ارائه شده است.



شکل ۱- نقشه ساده شده ایران، خوزستان و منطقه مورد مطالعه.
Fig. 1. Simplified map of Iran, Khuzestan, and the study area.

۳-مواد و روش‌ها

این پژوهش با هدف شناسایی و نقشه‌برداری اراضی شالیزاری در تابستان ۲۰۲۵ انجام شد. داده‌های مورد استفاده شامل تصاویر اپتیکی سنتینل-۲ و داده‌های راداری سنتینل-۱ بود. برای تهیه نقشه نهایی اراضی شالیزاری، تصاویر سنتینل-۲ در دوره ژانویه تا سپتامبر ۲۰۲۵ مورد استفاده قرار گرفتند. همچنین، به‌منظور بررسی الگوی زمانی رشد و ویژگی‌های فنولوژیک شلتوک، سری زمانی شاخص NDVI در دوره ژانویه ۲۰۲۲ تا سپتامبر ۲۰۲۵ استخراج و تحلیل شد. داده‌های سنتینل-۱ نیز به‌عنوان اطلاعات مکمل راداری برای افزایش قابلیت تفکیک اراضی شالیزاری در کنار داده‌های اپتیکی به کار گرفته شدند. در مرحله پیش‌پردازش، تصاویر فیلتر و پیکسل‌های تحت تأثیر ابر و سایه در تصاویر سنتینل-۲ ماسک شدند. سپس شاخص‌های گیاهی مذکور برای تمامی تصاویر محاسبه شد و میانگین ماهانه NDVI برای تحلیل سری زمانی استخراج گردید. برای شناسایی الگوهای مشابه رفتار گیاهی و تعیین تقویم زراعی در طول فصل تابستان، از ماتریس نقشه حرارتی در نرم‌افزار متلب استفاده شد. افزون بر این، میانگین این شاخص برای هر منطقه نمونه در پلتفرم گوگل ارث انجین محاسبه شد تا روند سبزینگی با دقت بیشتری مشخص شود. برای مقایسه عملکرد الگوریتم‌های یادگیری ماشین، سه الگوریتم جنگل تصادفی، ماشین بردار پشتیبان و K نزدیک‌ترین همسایه برای طبقه‌بندی کلاس‌های کاربری/پوشش زمین به کار گرفته شدند.برای تفکیک کلاس‌های مختلف شامل برنج، حبوبات، نیشکر، زمین‌های بایر و مناطق غیرکاشت انجام شد. در این فرآیند، نمونه‌های میدانی و نقاط کنترل زمینی به‌عنوان داده‌های آموزشی به‌کار گرفته شدند و ویژگی‌های راداری برای افزایش تمایز مزارع برنج به مدل افزوده شد. در نهایت، اعتبارسنجی مدل با استفاده از بخش مستقلی از نمونه‌های میدانی و محاسبه ماتریس خطا صورت گرفت. خروجی‌های این پژوهش شامل سری زمانی و نقشه‌های ماهانه شاخص‌های پوشش گیاهی، نقشه طبقه‌بندی مقدماتی و نقشه نهایی تفکیک اراضی شالیزاری در سال ۲۰۲۵ است (شکل ۲).



شکل ۲- فلوچارت متدولوژی شناسایی مزارع برنج.

Fig. 2. Flowchart of the methodology for paddy field identification.

۳-۱- یادگیری ماشین

یادگیری ماشین یکی از شاخه‌های علم داده است که به سامانه‌ها امکان می‌دهد با تکیه بر داده‌ها، الگوها را استخراج کرده و بدون کدنویسی مستقیمِ قواعد، عملکرد خود را به‌تدریج بهبود دهند (Raschka et al., 2020). این فرایند معمولاً در دو گامِ آموزش و ارزیابی انجام می‌شود؛ به این معنا که مدل در مرحله آموزش از داده‌های ورودی می‌آموزد و در مرحله ارزیابی، کارایی آن با استفاده از داده‌های اعتبارسنجی سنجیده می‌شود (Varoquaux and Colliot, 2023). به‌طور کلی، روش‌های یادگیری ماشین به دو دسته نظارت‌شده و بدون نظارت تقسیم می‌شوند. در روش نظارت‌شده، مدل با داده‌های برچسب‌دار آموزش می‌بینند؛ در حالی‌که در روش بدون نظارت، هدف شناسایی الگوها و ساختارهای نهفته در داده‌ها است (Naeem et al., 2023). این روش‌ها در مسائل گوناگونی مانند پیش‌بینی، طبقه‌بندی، شناسایی الگو و پشتیبانی از تصمیم‌گیری به کار می‌روند و در حوزه‌هایی همچون بهداشت، کشاورزی، امور مالی و سامانه‌های خودران کاربرد گسترده دارند (Sarker, 2021).

۳-۲- جنگل تصادفی

جنگل تصادفی (RF) یک الگوریتم یادگیری نظارت‌شده مبتنی بر یادگیری گروهی است که با استفاده از نمونه‌گیری Bootstrap و انتخاب تصادفی زیرمجموعه‌ای از ویژگی‌ها، مجموعه‌ای از درخت‌های تصمیم را ایجاد می‌کند (Salman et al., 2024). در این پژوهش، مدل جنگل تصادفی با ۱۰۰ درخت تصمیم اجرا شد.

$$W(A) = \alpha v_k \max_B \sum_{i=1}^{K} I(\omega i(A) = B$$

(رابطه ۱)

که در آن W(A)ترکیب مدل را نشان می‌دهد$i\omega$. نشان‌دهنده یک درخت تصمیم منفرد است. B متغیر خروجی است و I(.) تابع شاخص می‌باشد.

$$mg(A,B) = \alpha v_k I(Wk(A) = B) - \max_{j \neq B} \alpha v_k I(\omega k(B) = j)$$

(رابطه ۲)

معادله (۲) اعتبار مدل را محاسبه می‌کند. هرچه مقدار تابع بیشتر باشد، طبقه‌بندی مدل قابل اعتمادتر خواهد بود. بیان تعمیم‌پذیری طبقه‌بندی به صورت زیر است:

$$PQ* = P_{ab}(mg(A,B) < 0)$$ (رابطه ۳)

که در آن (A,B) نشان‌دهنده قابلیت اجرا است. با افزایش تعداد درختان تصمیم، دنباله PQ به PQ^* می‌رسد.

$$P_{ab}(P_\theta(\omega(A,\theta) = B) \max P_\theta(\omega(A,\theta) = J) < 0$$

(رابطه ۴)

این معادله نشان می‌دهد که خطای تعمیم با افزایش تعداد درختان کاهش می‌یابد. علاوه بر این، با استفاده از RFکه پایدار بوده و عملکرد خوبی دارد، این نقص برطرف می‌شود.

۳-۳- ماشین بردار پشتیبان (Support Vector Machine (SVM)

ماشین بردار پشتیبان یک الگوریتم قدرتمند یادگیری نظارت‌شده است که برای یافتن مرز بهینه بین کلاس‌ها طراحی شده است (Shetty et al., 2022). این الگوریتم با حداکثر کردن حاشیه بین دو کلاس و تعیین ابرصفحه‌ای که بهترین تفکیک را انجام می‌دهد، خطای تعمیم را به حداقل می‌رساند SVM .برای مجموعه داده‌های با ابعاد بالا و مسائل طبقه‌بندی غیرخطی به‌ویژه در کاربردهای سنجش از دور برای طبقه‌بندی پوشش زمین و محصولات کشاورزی بسیار مؤثر است.

$$(A) = \mathrm{Sign}\left(\sum_{i=1}^{n} \propto_i y_i K(A_i, A) + b\right)$$

(رابطه ۵)

که در آنA_i نمونه‌های آموزشی،$\mathcal{Y}_i$ برچسب‌های کلاس،$\propto_i$ ضرایب لاگرانژ،$K(A_i, A)$ تابع هسته و b عبارت انحراف مدل است. تابع هسته داده‌ها را به فضایی با ابعاد بالاتر نقشه‌برداری کرده و جداسازی غیرخطی بین کلاس‌ها را ممکن می‌سازد.

تابع هدف در SVM برای مسئله دوکلاسه به‌صورت زیر تعریف می‌شود:

$$\min_{w,b,\xi} \frac{1}{2} \| w \|^2 + C \sum_{i=1}^{n} \xi_i$$

(رابطه ۶)

با محدودیت‌ها:

$$Y_i(\mathbf{w}^T\phi(A_i)+b)\geq 1-\xi_l,\xi_i\geq 0$$

(رابطه ۷)

که در آن $\phi(A_i)$ تابع نقشه‌برداری داده، ξ_i خطاها و C تعادل بین حداکثر کردن حاشیه‌ها و کاهش خطای طبقه‌بندی است.

تعمیم‌پذیری یک مدل می‌تواند از طریق حاشیه بیان شود. هرچه حاشیه بزرگ‌تر باشد، احتمال خطای تعمیم کمتر و پایداری مدل بیشتر خواهد بود.

احتمال خطای تعمیم یک مدل به‌صورت زیر محاسبه می‌شود:

$$E_g = P\big(y\neq f(A)\big) = P(y(\mathbf{w}^T\phi(A)+b)<0)$$

(رابطه۸)

معادله (۸) نشان می‌دهد که با افزایش فاصله نقاط داده از مرز تصمیم‌گیری، خطای تعمیم E_g کاهش می‌یابد، که این منجر به دقت و قابلیت اطمینان بالاتر مدل می‌شود. بنابراین، ماشین بردار پشتیبانی (SVM) با استفاده از مفهوم حاشیه، امکان طبقه‌بندی دقیق داده‌ها را فراهم می‌کند و عملکرد پایداری را در حضور نویز و مجموعه‌های داده نامتعادل نشان می‌دهد.

۳-۴- الگوریتم K نزدیک‌ترین همسایه(K-Nearest Neighbors KNN)

الگوریتم KNN یکی از ساده‌ترین و مؤثرترین روش‌های یادگیری نظارت‌شده است که بر اساس شباهت نمونه‌ها عمل می‌کند (Suyal and Goyal, 2022). این روش نیاز به آموزش صریح ندارد و به‌جای آن، داده‌های جدید را بر اساس نزدیکی آن‌ها به نمونه‌های آموزشی موجود طبقه‌بندی می‌کند (Richards, 2022).

فاصله بین نمونه‌ها با استفاده از یکی از معیارهای فاصله، معمولاً فاصله اقلیدسی، محاسبه می‌شود که به‌صورت زیر تعریف می‌شود:

$$D(A,A_i)=\sqrt{\sum_{j=1}^{n}(A_j-A_{ij})^2}$$ (رابطه ۹)

در صورت استفاده از وزن‌دهی بر اساس فاصله، سهم هر همسایه به‌طور معکوس با فاصله آن از نمونه تنظیم می‌شود. در این حالت، تابع تصمیم‌گیری به‌صورت زیر اصلاح می‌شود:

$$f(A)=\arg\max_B \sum_{i=1}^{K} w_i\, I(y=B)$$

(رابطه ۱۰)

که در آن $w_i=\frac{1}{D(A,A_i)}$ وزن اختصاص داده‌شده به همسایه i-th است.

همسایه‌ها تأثیر بیشتری در تعیین کلاس نهایی دارند. دقت و تعمیم‌پذیری الگوریتم KNN به انتخاب مناسب مقدار K بستگی دارد؛ انتخاب مقادیر خیلی کوچک K ممکن است به هم‌پوشانی بیش از حد (overfitting) و حساسیت زیاد به نویز محلی منجر شود، در حالی که مقادیر بزرگ‌تر K باعث هموار شدن مرزهای تصمیم می‌شوند، که حساسیت به نویز را کاهش می‌دهد، اما ممکن است دقت طبقه‌بندی را کاهش دهد(Richards, 2022).بنابراین، تعیین مقدار بهینه K برای دستیابی به تعادلی بین پایداری مدل و دقت آن ضروری است.

۳-۵- معیارهای ارزیابی مدل‌ها

۳-۵-۱-ماتریس درهم‌ریختگی(Confusion Matrix)

ماتریس اشتباهات یکی از ابزارهای استاندارد برای ارزیابی دقت مدل‌های طبقه‌بندی است که امکان مقایسه نتایج پیش‌بینی شده و داده‌های واقعی یا مرجع را فراهم می‌آورد (Foody, 2023). این ماتریس به‌صورت یک جدول مربعی نمایش داده می‌شود که در آن سطرها به کلاس‌های واقعی و ستون‌ها به کلاس‌های پیش‌بینی‌شده اختصاص دارند (Pommé et al., 2022). با تحلیل ماتریس اشتباهات(CM)، می‌توان دقت پیش‌بینی، خطاهای نوع I و نوعII ، و همپوشانی کلاس‌ها را ارزیابی کرد. ماتریس اشتباهات به‌طور گسترده برای محاسبه شاخص‌های مختلف دقت، از جمله دقت کلی(OA)، دقت کاربر(UA)، دقت تولیدکننده (PA) و ضریب کاپا استفاده می‌شود (Pommé et al., 2022). این شاخص‌ها بینش‌های ارزشمندی در مورد قابلیت تفکیک مدل و عملکرد تعمیم آن بر روی داده‌های دیده‌نشده ارائه می‌دهند. ماتریس اشتباهات به‌صورت عددی با فرمول زیر محاسبه می‌شود:

$$\text{Overall Accuracy}=\frac{{}_{ii}CM_{i=1}^{n}\sum}{{}_{ij}CM_{j=1}^{n}\sum_{i=1}^{n}\sum}$$

(رابطه ۱۱)

که در آن CM_{ii} تعداد نمونه‌های درست پیش‌بینی‌شده برای کلاس i است و CM_{ij} تعداد کل نمونه‌ها بین کلاس واقعی i و کلاس پیش‌بینی‌شده j است. با استفاده از ماتریس اشتباهات، نه تنها می‌توان دقت کلی مدل را اندازه‌گیری کرد، بلکه می‌توان نقاط ضعف طبقه‌بندی را در تشخیص بین کلاس‌های نزدیک به هم شناسایی کرده و اقدامات اصلاحی برای بهبود دقت مدل انجام داد.

۳-۵-۲- شاخص کاپا (Kappa Coefficient)

شاخص کاپا (κ) یک معیار آماری است که برای ارزیابی توافق بین پیش‌بینی‌ها و طبقه‌بندی‌های واقعی استفاده می‌شود و توافقاتی که ممکن است به‌طور تصادفی رخ دهند را تصحیح می‌کند. این شاخص یک معیار مهم برای ارزیابی دقت مدل‌های طبقه‌بندی است، به‌ویژه زمانی که با کلاس‌های نامتوازن یا داده‌های نویزی مواجه هستیم. شاخص کاپا مقداری بین ۱- و ۱+ دارد، که در آن ۱+ نشان‌دهنده توافق کامل، ۰ نشان‌دهنده عدم توافق بیشتر از آنچه که تصادفی باشد، و مقادیر کمتر از ۰ نشان‌دهنده توافق بدتر از تصادف هستند (Verma et al., 2020).

از نظر ریاضی، شاخص کاپا با استفاده از فرمول زیر محاسبه می‌شود:

$$Kappa = \frac{P_o - P_e}{1 - P_e}$$

(رابطه ۱۲)

که در آن P_o:توافق مشاهده‌شده است (یعنی نسبت نمونه‌های درست طبقه‌بندی‌شده که از عناصری که در قطر ماتریس اشتباهات قرار دارند محاسبه می‌شود).

P_e توافق مورد انتظار است (یعنی احتمال توافق تصادفی که از روی مجموع‌های حاشیه‌ای ماتریس اشتباهات محاسبه می‌شود).

توافق مشاهده‌شده (P_o) برابر با مجموع عناصر قطر ماتریس اشتباهات (نمونه‌های درست پیش‌بینی‌شده) تقسیم بر مجموع کل نمونه‌ها است. توافق مورد انتظار (P_e) بر اساس توزیع کلاس‌ها در داده‌های پیش‌بینی‌شده و واقعی محاسبه می‌شود.

تفسیر کاپا:

$\kappa = 1$: توافق کامل بین کلاس‌های پیش‌بینی‌شده و واقعی.

$\kappa = 0$: هیچ توافقی بیشتر از آنچه که تصادفی باشد وجود ندارد.

$\kappa < 0$: توافق بدتر از تصادف است.

$0 < \kappa < 1$: توافق بهتر از تصادف است، و هرچه مقدار کاپا بالاتر باشد، قدرت پیش‌بینی مدل بهتر است.

شاخص کاپا به‌طور گسترده‌ای در وظایف طبقه‌بندی، به‌ویژه هنگام ارزیابی مسائل چندکلاسه استفاده می‌شود. این شاخص یک معیار قوی‌تر نسبت به دقت ساده فراهم می‌کند، زیرا امکان توافق تصادفی را در نظر می‌گیرد که در مواقعی که توزیع کلاس‌ها نامتوازن است، ممکن است گمراه‌کننده باشد.

۳-۵-۳- ماتریس همبستگی (Correlation Matrix)

ماتریس همبستگی یک ابزار آماری استاندارد است که برای اندازه‌گیری درجه وابستگی خطی میان متغیرهای مختلف استفاده می‌شود (Podani et al., 2023). این ماتریس به‌صورت یک جدول مربعی نمایش داده می‌شود که در آن هر سطر و ستون مربوط به یک متغیر است و هر سلول مقدار نشان‌دهنده قدرت و جهت رابطه خطی بین دو متغیر است. ضرایب همبستگی معمولاً بین ۱- و ۱+ قرار دارند، که مقادیر نزدیک به ۱+ نشان‌دهنده همبستگی مثبت قوی، مقادیر نزدیک به ۱- نشان‌دهنده همبستگی منفی قوی، و مقادیر نزدیک به صفر نشان‌دهنده عدم وجود رابطه خطی معنی‌دار است (Podani et al., 2023). ماتریس‌های همبستگی اغلب به‌صورت نقشه‌های حرارتی (heat maps) تجسم می‌شوند تا نمای گرافیکی شهودی از قدرت و جهت روابط بین متغیرها ارائه دهند (Singh and Nagahara, 2024).

فرمول محاسبه همبستگی بین دو متغیر به‌صورت زیر است:

$$r_{XY} = \frac{\sum_{i=1}^{n} (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^{n} (X_i - \bar{X})^2 \sum_{i=1}^{n} (Y_i - \bar{Y})^2}}$$

(رابطه ۱۳)

این معادله نحوه محاسبه همبستگی بین دو متغیر را تعریف می‌کند. در این معادله، X_i و Y_i مقادیر نمونه هستند، $\bar{X}$ و $\bar{Y}$ میانگین‌های هر متغیر و n تعداد نمونه‌ها است. این فرمول نشان می‌دهد که چگونه تغییرات در یک

متغیر نسبت به میانگین آن با تغییرات در متغیر دیگر همبستگی دارد (شکل ۲).

۳-۶- ویژگی‌ها و شاخص‌های مورد استفاده

۳-۶-۱- شاخص نرمال‌شده تفاوت پوشش گیاهی (The Normalized Difference Vegetation Index (NDVI))

شاخص نرمال‌شده تفاوت پوشش گیاهی (NDVI) یکی از پرکاربردترین شاخص‌های طیفی در سنجش از دور برای شناسایی و نظارت بر پوشش گیاهی است. این شاخص بر اساس تفاوت در بازتابش طیفی گیاهان در باندهای قرمز (RED)و نزدیک به مادون قرمز (NIR) تعریف شده است (Huang et al., 2021). از آنجا که گیاهان زنده مقدار زیادی انرژی را در باند قرمز جذب کرده و بازتابش بالایی در باند نزدیک به مادون قرمز دارند، نسبت این دو بازتابش اطلاعات ارزشمندی در مورد وضعیت پوشش گیاهی و چگالی گیاهان ارائه می‌دهد (Kior et al., 2021). NDVI تغییرات در محتوای کلروفیل و چگالی تاج گیاهان را به‌طور مؤثر منعکس می‌کند (Caruso et al., 2023). مقادیر این شاخص معمولاً از ۱- تا ۱+ متغیر است، که مقادیر نزدیک به صفر یا منفی نشان‌دهنده سطوح خالی (مانند آب، برف یا خاک لخت) و مقادیر نزدیک به ۱+ نشان‌دهنده پوشش گیاهی متراکم و سالم هستند .به‌دلیل سادگی در محاسبه، قابلیت مقایسه زمانی و فضایی و حساسیت بالا به تغییرات پوشش گیاهی، NDVI در مطالعات دینامیک فصلی، ارزیابی خشکسالی و نظارت بر سلامت گیاهان به‌طور گسترده‌ای استفاده می‌شود.

۳-۶-۲- شاخص پوشش گیاهی تفاضلی وزنی (Weighted Difference Vegetation Index (WDVI))

شاخص پوشش گیاهی تفاضلی وزنی (WDVI) یک شاخص طیفی رایج است که برای ارزیابی پوشش گیاهی استفاده می‌شود و برای کاهش تأثیرات بازتابش خاک و تمایز بهتر بین سطوح گیاهی و غیرگیاهی توسعه یافته است (Almalki et al., 2022). این شاخص بر اساس رابطه خطی بین بازتابش باند قرمز و نزدیک به مادون قرمز تعریف شده است و می‌توان آن را یک NDVI اصلاح‌شده دانست که تأثیرات بازتابش خاک پس‌زمینه را با استفاده از شیب خط خاک (a) حذف می‌کند WDVI. به تغییرات پوشش گیاهی بسیار حساس است و به‌ویژه برای مناطقی با خاک‌های سبک یا سطوح پوشش کم مناسب است(Yang et al., 2022). این ویژگی باعث می‌شود که WDVI برای ارزیابی سلامت گیاه، برآورد مساحت سبز و تحلیل روندهای زمانی تغییرات پوشش گیاهی قابل اعتماد باشد(Ahmed et al., 2024). مقادیر WDVI معمولاً از ۰ تا نزدیک به ۱ متغیر است، که مقادیر پایین‌تر نشان‌دهنده خاک لخت یا پوشش گیاهی پراکنده و مقادیر بالاتر نشان‌دهنده پوشش گیاهی متراکم‌تر هستند (Han et al., 2025).

$$WDVI = NIR - 1.35 \times RED \quad \text{(رابطه ۱۴)}$$

که در آن NIR و RED نمایانگر بازتابش باندهای نزدیک به مادون قرمز و قرمز به‌ترتیب هستند و a شیب خط خاک است که از رابطه بین این دو باند در پیکسل‌هایی که بدون پوشش گیاهی هستند، تعیین می‌شود.

۳-۶-۳- شاخص سطحِ برگ (Leaf Area Index (LAI))

شاخص سطحِ برگ (LAI) یک شاخص کلیدی در سنجش از دور است که برای ارزیابی وضعیت پوشش گیاهی استفاده می‌شود و نمایانگر مجموع مساحت یک‌طرفه برگ‌ها در هر واحد مساحت سطح زمین است (Gong et al., 2021). این شاخص چگالی گیاهان، سلامت آن‌ها و ظرفیت فتوسنتزی آن‌ها را منعطف می‌کند و به‌طور مستقیم با بیوماس، تبخیر-تعرق و عملکرد محصول مرتبط است(Zhang et al., 2021). LAI معمولاً از طریق روابط تجربی با شاخص‌های طیفی مانند NDVI یاEVI ، بر اساس بازتابش باندهای قرمز و نزدیک به مادون قرمز، برآورد می‌شود (Qiao et al., 2024). مقادیر LAI معمولاً از ۰ تا بیش از ۶ متغیر است، که مقادیر پایین‌تر نشان‌دهنده پوشش گیاهی پراکنده و مقادیر بالاتر نشان‌دهنده تاج‌های گیاهی متراکم و فعال فتوسنتزی هستند(Liu et al., 2021). در این مطالعه، شاخص LAI برای ارزیابی شرایط رشد گیاهان و تمایز مناطق با چگالی گیاهی بالا محاسبه شد.

$$LAI = 0.118 - NDVI \times 3.618 \quad \text{(رابطه ۱۵)}$$

۳-۶-۴- شاخص کلروفیل مبتنی بر باند سبز (Green-band-based Chlorophyll Index (CI))

شاخص کلروفیل مبتنی بر باند سبز (CIgreen) یک شاخص طیفی پیشرفته است که برای برآورد محتوای کلروفیل و ارزیابی وضعیت سلامت پوشش گیاهی استفاده می‌شود (Kurbanov et al., 2020). این شاخص بر اساس تفاوت در بازتابش بین باندهای نزدیک به مادون قرمز (NIR) و سبز تعریف شده است و حساسیت بالاتری به تغییرات در غلظت کلروفیل برگ‌ها ارائه می‌دهد و آن را به ابزاری مؤثر برای تحلیل رشد گیاه، چگالی بیوماس و دینامیک‌های فصلی پوشش گیاهی تبدیل می‌کند (Falcioni et al., 2022). با استفاده از جذب بالای کلروفیل در ناحیه سبز و بازتابش بالای آن در ناحیهNIR، CIgreen امکان شناسایی دقیق‌تر تفاوت‌های جزئی در شرایط فیزیولوژیکی گیاهان را فراهم می‌کند (Hassan and Chang, 2025). این شاخص به‌ویژه در مواقعی که NDVIبه اشباع می‌رسد (مثلاً در تاج‌های گیاهی بسیار متراکم) مؤثر است و بنابراین به‌عنوان یک شاخص تکمیلی برای شاخص‌های کلاسیک پوشش گیاهی عمل می‌کند (Wang et al,. 2025). مقادیر CIgreen معمولاً از نزدیک صفر تا مقادیر مثبت بالاتر متغیر است، که مقادیر بالاتر نشان‌دهنده محتوای کلروفیل بیشتر و پوشش گیاهی سالم‌تر هستند.

$$\mathrm{CI_{green}} = \frac{\mathrm{NIR}}{\mathrm{GREEN}} - 1 \qquad \text{(رابطه ۱۶)}$$

که در آن NIR نمایانگر بازتابش باند نزدیک به مادون قرمز وGREEN نمایانگر بازتابش باند سبز است.

۳-۶-۵- داده‌های راداری (Synthetic Aperture Radar (SAR))

داده‌های راداری سنتینل ۱ در این مطالعه به‌دلیل توانایی بالای آن‌ها در ثبت بازتاب ریزموج از سطح زمین، بدون وابستگی به شرایط جوی و پوشش ابرها استفاده شد (Bauer-Marschallinger et al., 2021).

سنتینل ۲ یک ماهواره دوقلو است که اگر هر دو ماهواره به طور هم زمان تصویربرداری کنند، میتوانند در طول ۵ روز از کل زمین یک پوشش کامل تهیه نمایند (Kabelizadeh et al., 2018).

تصاویر راداری با قطبش‌های VV و VH امکان تحلیل زبری سطح، محتوای رطوبت خاک و تغییرات ساختاری مزارع کشاورزی را فراهم می‌کنند (Zhang et al., 2024). از آنجا که مزارع برنج در مقایسه با سایر محصولات در مراحل مختلف رشد، به‌ویژه در دوره‌های آب‌گرفتگی و سبز شدن، رفتار بازتابی متمایزی دارند، داده‌های راداری سنتینل ۱ به‌عنوان ویژگی‌های کمکی در کنار شاخص‌های طیفی برای افزایش دقت تفکیک محصولات برنج به‌کار گرفته شدند. در نتیجه، ترکیب داده‌های اپتیکی و راداری شناسایی دقیق‌تری از مزارع برنج و تفکیک آن‌ها از سایر نوع‌های محصولات کشاورزی را ممکن ساخت.

۳-۶-۶- بررسی سری زمانی شاخص تفاوت گیاهی نرمال‌شده (NDVI time series analysis)

سری‌های زمانی شاخص‌های سنجش از دور ابزارهای ضروری برای تحلیل تغییرات زمانی و دینامیک‌های پدیده‌های سطح زمین هستند. این شاخص‌ها نقش مهمی در نظارت بلندمدت بر پوشش گیاهی، تغییرات کاربری زمین و فرآیندهای زیست‌محیطی ایفا می‌کنند (Zheng et al., 2022). در میان این شاخص‌ها، شاخص تفاوت گیاهی نرمال‌شده (NDVI) یکی از پرکاربردترین معیارهای پوشش گیاهی است که امکان بررسی روندهای دینامیک پوشش گیاهی، سلامت و چگالی تاج گیاهان در طول زمان را فراهم می‌کند (Ahmed et al., 2024). در این مطالعه، داده‌های ماهواره‌ای سنتینل ۲ به‌طور ماهانه از ژانویه ۲۰۲۲ تا سپتامبر ۲۰۲۵ استخراج شده و مقادیرNDVI برای هر نمونه آموزشی محاسبه شد. تحلیل سری زمانی به‌دست آمده امکان مشاهده و مقایسه روندهای رشد در برنج و دیگر محصولات کشاورزی را فراهم کرده و به شناسایی دقیق‌تر الگوهای فنولوژیکی، از جمله شروع رشد، اوج سبز شدن و دوره‌های برداشت منجر شد. این روش نمایی پویا و کمی از رفتار پوشش گیاهی در طول زمان ارائه می‌دهد و به‌عنوان ابزاری مؤثر برای مدیریت و نظارت بر محصولات کشاورزی عمل می‌کند. در کشت برنج، استفاده از سری زمانی NDVI به‌ویژه اهمیت دارد، زیرا این محصول الگوی فنولوژیکی مشخصی دارد که مراحل رشد آن به‌شدت وابسته به شرایط آبی و حرارتی است. تحلیل تغییرات زمانی این شاخص امکان تعیین دقیق دوره‌های کاشت، رشد

رویشی، گل‌دهی و برداشت را با دقت بالا فراهم می‌کند (Bhattacharya, 2022). بنابراین، کاربرد داده‌های سری زمانی در سنجش از دور رویکردی کارآمد برای نظارت مداوم بر مزارع برنج، ارزیابی عملکرد و برنامه‌ریزی بهینه مدیریت منابع آب و زمین است (Yang et al., 2020).

۳-۶-۷- شاخص پوشش گیاهی بهبود یافته (Enhanced Vegetation Index(EVI))

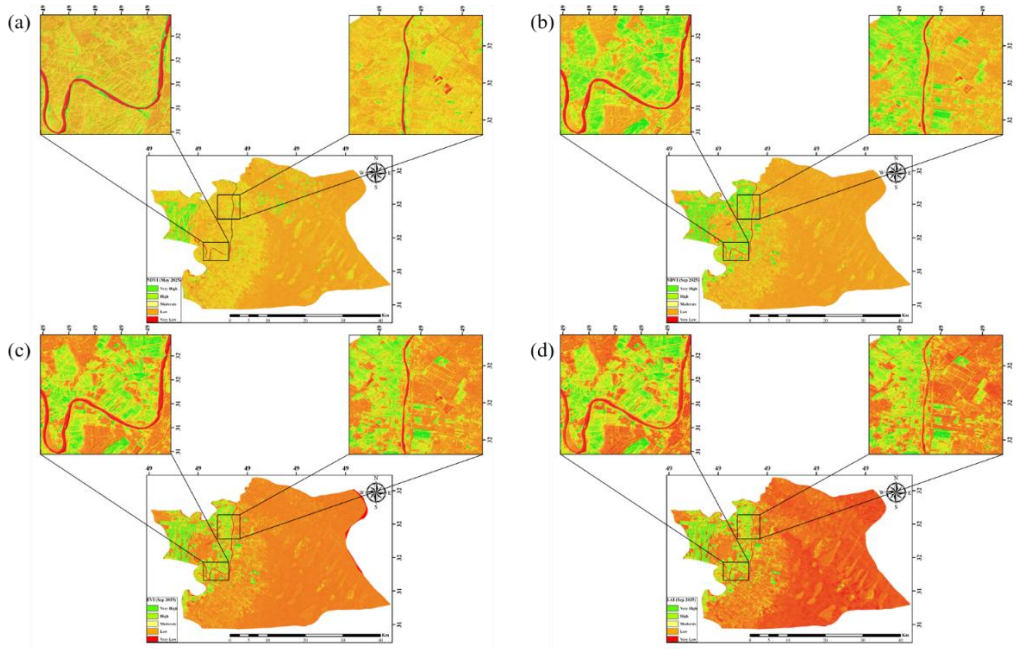
شاخص پوشش گیاهی بهبودیافته (EVI) یک روش دیگر است که به‌طور گسترده برای ارزیابی پوشش گیاهی استفاده می‌شود. این شاخص برای کاهش تأثیرات بازتابش جو و خاک طراحی شده است، در حالی که حساسیت بالاتری به چگالی پوشش گیاهی و گیاهانی با تاج‌های متراکم فراهم می‌کند (Zeng et al., 2022). این شاخص بر اساس بازتابش در باندهای قرمز، نزدیک به مادون قرمز و آبی تعریف شده است و برای بررسی تغییرات فصلی و مقایسه دقیق‌تر پوشش گیاهی به‌دلیل اصلاحات جوی و پاسخ تقویت‌شده در نواحی با پوشش گیاهی متراکم انتخاب شده است. مقادیر EVI معمولاً از ۰، که نشان‌دهنده سطوح خالی یا آب است، تا ۱+، که نشان‌دهنده نواحی با پوشش گیاهی متراکم می‌باشد، متغیر است (Vijith and Dodge-Wan, 2020).

$$EVI = \frac{2.5\times(NIR-RED)}{NIR+6\times RED-7.5\times BLUE+1} \quad \text{(رابطه ۱۷)}$$

۴- نتایج و بحث

۴-۱- مقایسه و تحلیل پیوسته شاخص‌های NDVI، EVI و LAI در پایش کشت شلتوک

پایش مراحل رشد شلتوک در محدوده مورد مطالعه، واقع در شمال شهرستان باوی و اراضی پیرامون رودخانه کارون، با استفاده از شاخص‌های NDVI، EVI و LAI امکان بررسی تغییرات زمانی پوشش گیاهی و ویژگی‌های فنولوژیک شلتوک را فراهم می‌کند (شکل ۳). هر یک از این شاخص‌ها به جنبه‌های متفاوتی از سبزینگی، ساختار و تراکم تاج‌پوشش حساس هستند و بررسی هم‌زمان آن‌ها می‌تواند تفسیر جامع‌تری از تغییرات رشد شلتوک ارائه دهد. در آغاز فصل کشت، هم‌زمان با آبگیری مزارع و نشاکاری، مقدار NDVI نسبتاً پایین است (شکل ۳-a). این وضعیت را می‌توان به شرایط آبگرفته مزارع، حضور آب سطحی و توسعه محدود تاج‌پوشش گیاهی در مراحل اولیه رشد نسبت داد. در این مرحله، EVI به دلیل حساسیت کمتر نسبت به اثرات پس‌زمینه خاک و برخی عوامل مؤثر بر بازتابش سطح، می‌تواند تغییرات اولیه پوشش گیاهی را بهتر نشان دهد. LAI نیز در همین دوره روند افزایشی تدریجی را آغاز می‌کند که بیانگر شروع توسعه سطح برگ و افزایش تدریجی تراکم پوشش گیاهی است. در مرحله رشد کامل، یعنی از تیر تا مرداد، هر سه شاخص افزایش قابل‌توجهی نشان می‌دهند؛ به‌گونه‌ای که اوج سبزینگی در NDVI (شکل ۳-b)، EVI (شکل ۳-c) و LAI (شکل ۳-d) در ماه سپتامبر مشهود است. مقادیر NDVI و EVI معمولاً در محدوده ۰/۷ تا ۰/۹ قرار می‌گیرند و LAI به حدود ۵ تا ۶ می‌رسد که نشان‌دهنده افزایش تراکم تاج‌پوشش و توسعه سطح برگ در دوره اوج رشد است. با این حال، NDVI در این محدوده به اشباع طیفی نزدیک می‌شود و حساسیت آن نسبت به تغییرات جزئی در تراکم پوشش گیاهی کاهش می‌یابد، در حالی که EVI می‌تواند اطلاعات مکملی درباره تغییرات ساختاری و تراکم تاج‌پوشش فراهم کند. بر اساس تحلیل همبستگی انجام‌شده، LAI با EVI همبستگی بیشتری نسبت به NDVI نشان داد. این رابطه را می‌توان به حساسیت EVI به تغییرات ساختاری و تراکم پوشش گیاهی و ارتباط LAI با سطح برگ نسبت داد. در پایان فصل رشد و مرحله برداشت، کاهش سبزینگی و تغییر ساختار تاج‌پوشش با کاهش مقادیر هر سه شاخص همراه است. در این دوره، NDVI و EVI روندی نزولی و هم‌زمان نشان می‌دهند و LAI نیز به‌سرعت کاهش می‌یابد که بیانگر کاهش تراکم و فعالیت پوشش گیاهی در مراحل پایانی رشد است. در مجموع، اگرچه NDVI شاخص مناسبی برای بررسی کلی تغییرات سبزینگی است، EVI می‌تواند در شرایط رطوبتی و آبگرفتگی مزارع شلتوک اطلاعات مکملی درباره تغییرات تاج‌پوشش فراهم کند. بنابراین، استفاده توأمان از EVI و LAI در کنار NDVI می‌تواند تفسیر تغییرات رشد و پایش مراحل فنولوژیک شلتوک را نسبت به استفاده از یک شاخص منفرد بهبود دهد.

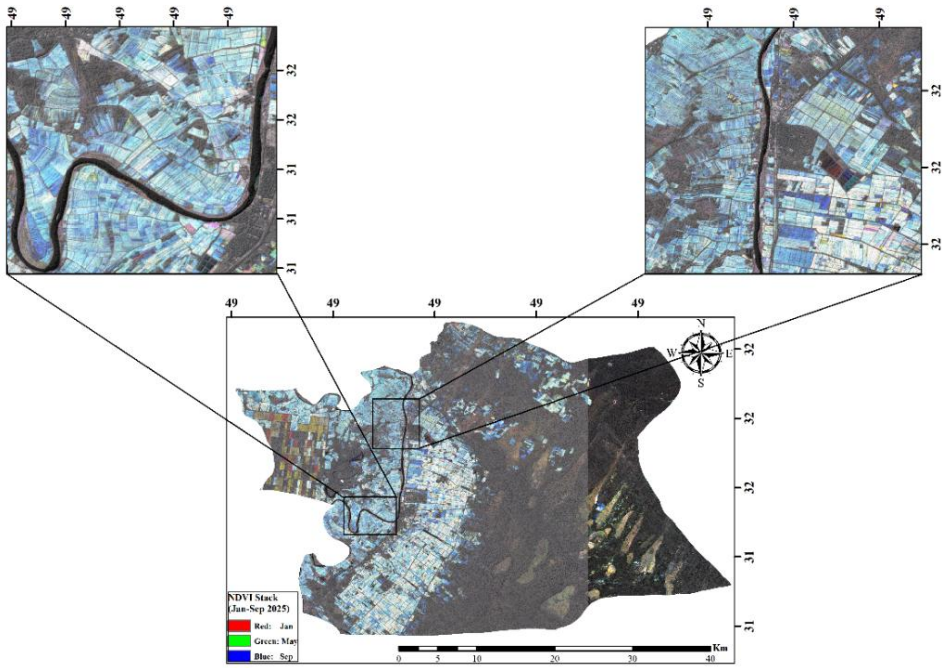


شکل ۳- پایش زمانی-مکانی مزارع شلتوک با استفاده از شاخص‌های مختلف پوشش گیاهی: (a) NDVI در ماه می ۲۰۲۵، (b) NDVI در ماه سپتامبر ۲۰۲۵، (c) EVI در ماه سپتامبر ۲۰۲۵، و (d) LAI در ماه سپتامبر ۲۰۲۵.

Fig. 3. Spatiotemporal monitoring of rice paddies using various vegetation indices: (a) NDVI in May 2025, (b) NDVI in September 2025, (c) EVI in September 2025, and (d) LAI in September 2025.

۴-۲- تحلیل سری زمانی و پشته‌سازی تصاویر NDVI در شناسایی کشت شلتوک

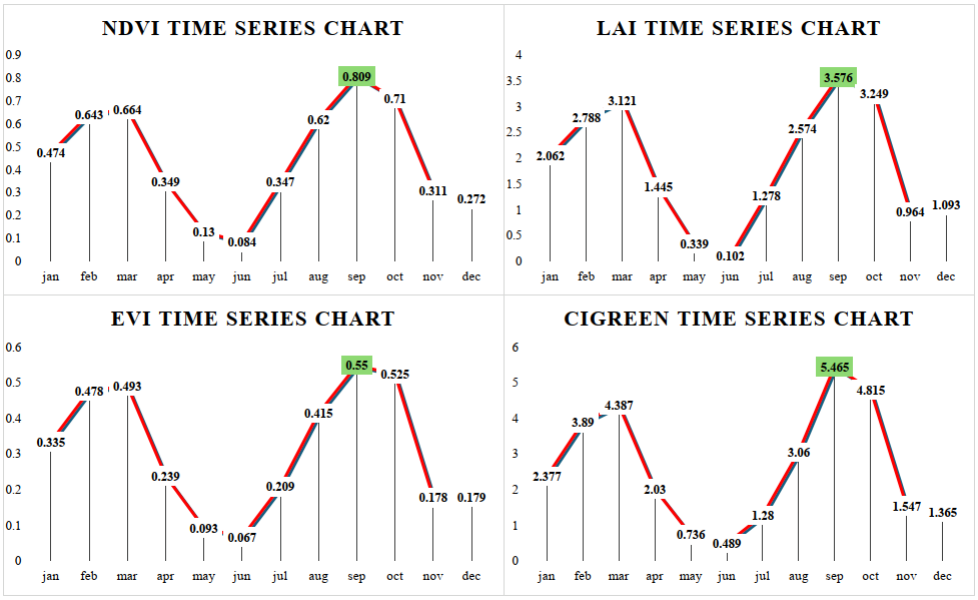
پایش زمانی پوشش گیاهی با استفاده از NDVI یکی از روش‌های کارآمد برای شناسایی و تفکیک الگوی کشت شلتوک در محدوده مورد مطالعه، واقع در شمال شهرستان باوی و اراضی پیرامون رودخانه کارون، محسوب می‌شود. با توجه به چرخه فنولوژیک شلتوک در این محدوده، تحلیل رفتار زمانی NDVI امکان تمایز این محصول از سایر کاربری‌های زراعی را فراهم می‌کند (جدول ۱). در این پژوهش، تصاویر NDVI استخراج‌شده از داده‌های سنتینل-۲ در دوره ژانویه ۲۰۲۲ تا سپتامبر ۲۰۲۵ برای بررسی الگوی فنولوژیک شلتوک به‌کار گرفته شدند. نتایج تحلیل سری زمانی نشان داد که شلتوک در محدوده مورد مطالعه دارای الگوی رشد فصلی مشخصی است؛ به‌گونه‌ای که مرحله آبگیری و استقرار اولیه در فصل بهار با مقادیر پایین NDVIآغاز می‌شود، در تابستان روند افزایشی مشخصی دارد و در پایان فصل رشد و هم‌زمان با برداشت، کاهش می‌یابد. بررسی سری زمانی NDVI نشان داد که بیشترین مقدار سبزینگی در ماه سپتامبر مشاهده می‌شود. این مقدار نشان‌دهنده اوج سبزینگی و افزایش تراکم تاج‌پوشش شلتوک در دوره رشد است؛ بر این اساس، ماه سپتامبر به‌عنوان نماینده مرحله رشد کامل شلتوک در سال ۲۰۲۵ در نظر گرفته شد. در گام بعد، تصاویر NDVI ماهانه از ژانویه تا سپتامبر ۲۰۲۵ تهیه و با استفاده از روش پشته‌سازی (Stacking) در قالب یک ترکیب چندلایه سازمان‌دهی شدند تا تغییرات زمانی پوشش گیاهی در یک ساختار پیوسته قابل تحلیل باشد (شکل ۴). این ترکیب زمانی لایه‌ها امکان مشاهده هم‌زمان روند رشد شلتوک در طول فصل زراعی را فراهم کرد. در این ترکیب، پهنه‌های دارای مقادیر بالاترNDVI ، متناظر با مراحل دارای تراکم بیشتر پوشش گیاهی، با طیف رنگی نزدیک به بنفش نمایش داده شدند. برای آماده‌سازی داده‌های آموزشی طبقه‌بندی، نمونه‌های مربوط به مزارع شلتوک نیز با توجه به الگوی زمانی و طیفی NDVI انتخاب شدند. این رویکرد موجب شد انتخاب نمونه‌ها بر اساس رفتار فنولوژیک محصول در طول فصل، و نه صرفاً بر مبنای بازتاب طیفی در یک تاریخ منفرد، انجام شود.



شکل ۴- شناسایی دینامیک رشد شلتوک از طریق تحلیل سری زمانی NDVI و ساخت ترکیب زمانی لایه‌ها.
Fig. 4. Paddy rice growth dynamics revealed through NDVI time-series analysis and stacked temporal layers.

جدول ۱- تحلیل فنولوژی برنج با استفاده از دوره‌های سری زمانی.
Table 1- Analysis of rice phenology using time series periods.

Month	NDVI Mean	EVI Mean	LAI Mean	CIgreen Mean	تفسیر
ژانویه	0.474	0.335	2.062	2.377	پوشش گیاهی بسیار کم، زمین‌های خوابیده یا لخت
فوریه	0.643	0.478	2.788	3.89	رشد کم، جوانه‌زنی اولیه در نهالستان‌ها
مارس	0.664	0.493	3.121	4.387	رشد کم تا متوسط، در حال رشد نشاها
آوریل	0.349	0.239	1.445	2.03	رشد متوسط، شروع مرحله رویشی
مه	0.13	0.093	0.339	0.736	رشد رویشی اولیه، افزایشNDVI/EVI
ژوئن	0.084	0.067	0.102	0.489	رشد رویشی ادامه دارد، LAIدر حال افزایش
ژوئیه	0.347	0.209	1.278	1.28	رشد رویشی سریع، بسته شدن تاج گیاهان
اوت	0.62	0.415	2.574	3.06	حداکثر توسعه رویشی در حال نزدیک شدن
سپتامبر	0.809	0.55	3.576	5.465	اوج رشد، حداکثر قابل تشخیص بودن، بالاترین مقادیرNDVI/EVI/LAI/CIgreen
اکتبر	0.71	0.525	3.249	4.815	شروع پیری، کاهش شاخص‌ها
نوامبر	0.311	0.178	0.964	1.547	پیری دیرهنگام، دوره برداشت
دسامبر	0.272	0.179	1.093	1.365	زمین‌های لخت، پس از برداشت

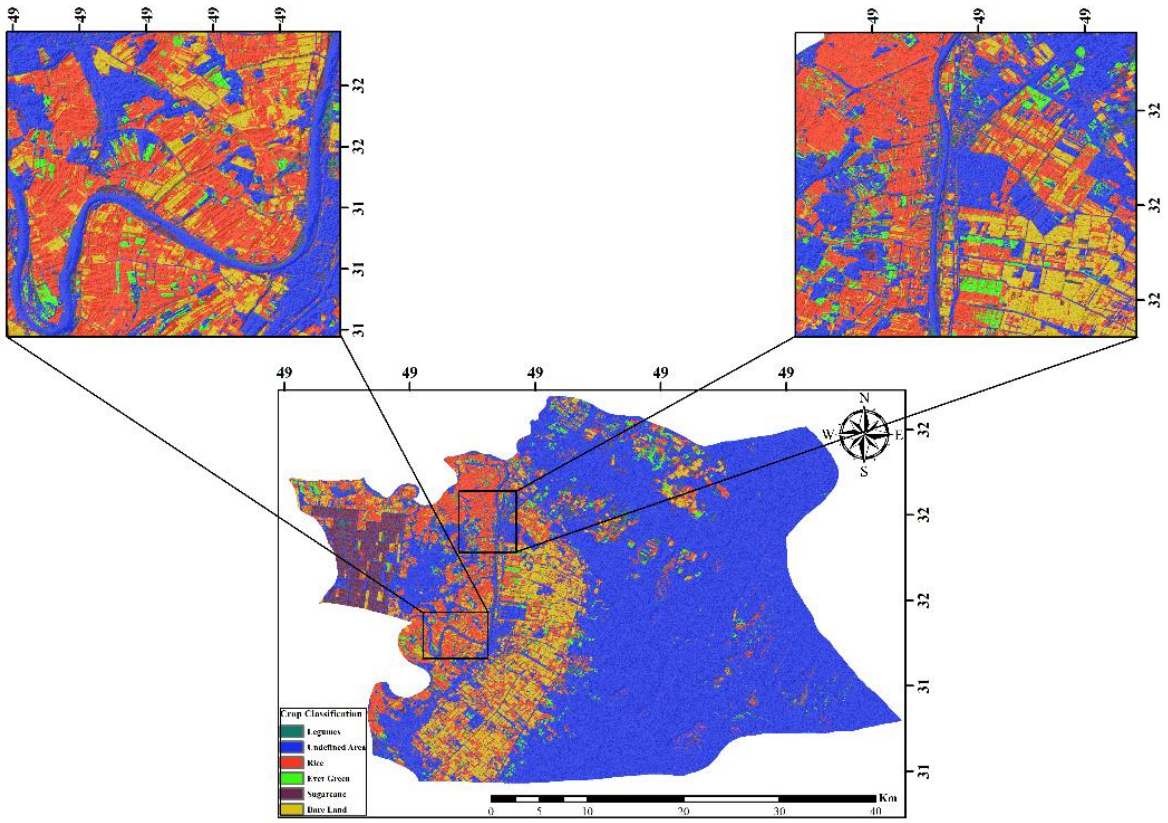


شکل ۵- تغییرات سری زمانی شاخص‌های پوشش گیاهی NDVI، EVI، LAI و Cigreen در طول سال جهت پایش فنولوژی و شناسایی کشت شلتوک در محدوده مورد مطالعه.

Fig.5. Annual time-series variations of vegetation indices (NDVI, EVI, LAI, and CIgreen) for monitoring phenology and identifying paddy rice cultivation in the study area.

۴-۳- طبقه‌بندی تصاویر در محدوده مورد مطالعه

برای انجام طبقه‌بندی نهایی در محدوده مورد مطالعه، نمونه‌های آموزشی مربوط به کلاس‌های مختلف شامل شلتوک، کشت‌های تابستانه نوع اول و دوم، پوشش‌های همیشه‌سبز، کشت‌های زمستانه و اراضی بدون کشت، با داده‌های حاصل از برداشت میدانی تلفیق شدند تا مجموعه‌ای از نمونه‌های آموزشی و اعتبارسنجی برای طبقه‌بندی کاربری اراضی منطقه فراهم شود. این نمونه‌ها با استفاده از روش تصادفی‌سازی به دو بخش تقسیم شدند؛ به‌طوری‌که ۷۵ درصد نمونه‌ها برای آموزش مدل و ۲۵ درصد برای اعتبارسنجی مستقل در نظر گرفته شد. به‌منظور استخراج ویژگی‌های طیفی و ساختاری پوشش گیاهی، شاخص‌های NDVI، EVI، WDVI، LAI و CIgreen از تصاویر اپتیکی سنتینل-۲ استخراج شدند. شاخص سطح برگ (LAI) برای سه بازه اصلی فصل رشد شامل بهار، تابستان و پاییز در سال ۲۰۲۵ محاسبه و به‌ترتیب با نام‌های فنی laiSpr، laiSum و laiFall ذخیره شد. به همین ترتیب، شاخص کلروفیل سبز (CIgreen) نیز برای بازه‌های زمانی مذکور استخراج و با نام‌های CIspr، CIsum و CIfall ثبت گردید. به‌منظور افزایش قابلیت تفکیک‌پذیری کلاس‌های کاربری، داده‌های راداری سنتینل-۱ با قطبش‌های VV و VH نیز به‌عنوان ویژگی‌های مکمل مورد استفاده قرار گرفتند. برای این منظور، میانه مقادیر بازتاب راداری در بازه زمانی ژانویه تا سپتامبر ۲۰۲۵ محاسبه شد. سپس، ویژگی‌های حاصل از داده‌های اپتیکی و راداری در قالب یک تصویر ترکیبی ادغام شدند تا اطلاعات طیفی، ساختاری و راداری در یک مجموعه ورودی واحد تجمیع شود. در ادامه، نمونه‌های آموزش و اعتبارسنجی از تصویر ترکیبی استخراج و ویژگی‌های منتخب به‌عنوان متغیرهای ورودی مدل طبقه‌بندی استفاده شدند. برای اجرای طبقه‌بندی نهایی، الگوریتم جنگل تصادفی با استفاده از ۱۰۰ درخت تصمیم آموزش داده شد. ارزیابی عملکرد مدل با استفاده از نمونه‌های آموزشی و مجموعه مستقل اعتبارسنجی و از طریق تشکیل ماتریس خطا انجام گرفت (جداول ۲ و ۳). بر اساس نتایج ارزیابی، عملکرد مدل در تفکیک کلاس‌های مورد مطالعه بررسی شد و نقشه طبقه‌بندی نهایی در محیط Google Earth Engine تولید گردید. در مرحله پس‌پردازش، به‌منظور کاهش لکه‌های کوچک و افزایش انسجام فضایی نقشه، چندضلعی‌های با مساحت کمتر از یک هکتار از نقشه نهایی حذف شدند (شکل ۶).



شکل ۶- روند اجرای طبقه‌بندی نهایی و تولید نقشه مزارع شلتوک در محدوده مورد مطالعه.

Fig. 6. Final classification procedure and paddy field map production in the study area.

جدول ۲ - مقایسه عملکرد مدل‌ها برای طبقه‌بندی محصول در محدوده مورد مطالعه.

Table 2 - Comparison of the performance of models for product classification in the study area.

مدل	دقت تولیدکننده(PA)	دقت مصرف‌کننده(CA)	ضریب کاپا	دقت کلی(OA)	بهترین مدل
RF	[0,1,1,0.571,0.923,1,1]	[0,1,0714,1,1,1,075]	0.9151	0.9310	✅
SVM	[0.923,1,0.429,0.538,0.786,1]	[0,0.8,0.417,1,1,0.917,0.667]	0.7074	0.7586	
KNN	[0,0.846,1,0.714,0.923,1,1]	[0,1,0.833,1,0.923,0.875,0.857]	0.8934	0.9138	

جدول ۳- ماتریس درهم‌ریختگی مدل‌ها برای طبقه‌بندی محصولات در محدوده مورد مطالعه.

Table 3- Confusion matrix of models for classifying products in the studied area.

Model	RF				SVM				KNN			
Class	TP	FP	TN	FN	TP	FP	TN	FN	TP	FP	TN	FN
wintCrop	0	0	58	0	0	0	58	0	0	0	58	0
summer1	13	0	45	0	12	3	42	1	11	0	45	2
summer2	5	2	51	0	5	7	46	0	5	1	52	0
everGreen	4	0	51	3	3	0	51	4	5	0	51	2
Wintcrop2	12	0	45	1	7	0	45	6	12	1	44	1
noCrop	14	0	44	0	11	1	43	3	14	2	42	0

۴-۴- شناسایی کشت شلتوک و تولید نقشه نهایی

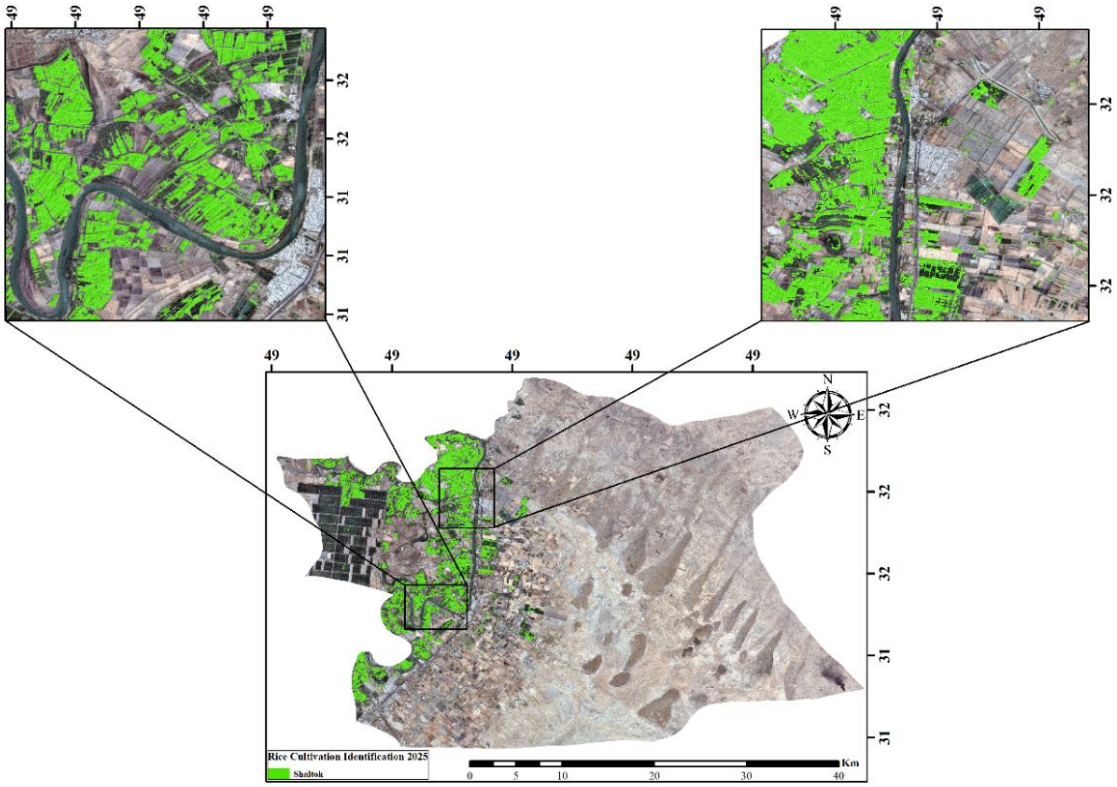
در این مرحله، فرایند شناسایی و تفکیک اراضی زیرکشت شلتوک در شهرستان باوی و اراضی پیرامون رودخانه کارون با استفاده از تلفیق داده‌های اپتیکی و راداری انجام شد. هدف، استخراج الگوی مکانی اراضی زیرکشت شلتوک در دوره اوج رشد و تهیه نقشه نهایی پراکنش این محصول در سال ۲۰۲۵ بود. با توجه به نتایج تحلیل فنولوژیک و سری زمانی NDVI، بازه زمانی اوایل تیر تا اوایل شهریور ۲۰۲۵ به‌عنوان دوره مناسب برای استخراج ویژگی‌های راداری و شناسایی شلتوک در نظر گرفته شد. بر این اساس، تصاویر سنتینل-۱ با دو قطبش VV و VH در بازه زمانی ۰۱-۰۷-۲۰۲۵ تا ۰۱-۰۹-۲۰۲۵ انتخاب و پردازش شدند. سپس، با استفاده از تابع آماری میانه، داده‌های راداری این دوره تجمیع و پس از اعمال برش مکانی، باندهای VV و VH به مجموعه ویژگی‌های مورد استفاده در طبقه‌بندی افزوده شدند.در ادامه، یک تصویر ترکیبی شامل ویژگی‌های استخراج‌شده از داده‌های اپتیکی، از جمله LAI و CIgreen، و ویژگی‌های راداری VV و VH ایجاد شد. این تلفیق با هدف استفاده هم‌زمان از اطلاعات طیفی و ساختاری پوشش گیاهی و ویژگی‌های بازتاب راداری در فرایند طبقه‌بندی انجام گرفت. نمونه‌های زمینی مربوط به کلاس‌های مختلف کاربری اراضی از این مجموعه داده استخراج و برای آموزش و ارزیابی مدل مورد استفاده قرار گرفتند. نمونه‌ها به‌صورت تصادفی به دو مجموعه شامل ۷۵ درصد داده‌های آموزشی و ۲۵ درصد داده‌های اعتبارسنجی مستقل تقسیم شدند. برای طبقه‌بندی نهایی، الگوریتم جنگل تصادفی با ۱۰۰ درخت تصمیم بر روی مجموعه داده ترکیبی آموزش داده شد. مدل با استفاده از ویژگی‌های اپتیکی و راداری، کلاس‌های مختلف کاربری اراضی را تفکیک کرد و عملکرد آن با استفاده از مجموعه مستقل اعتبارسنجی، ماتریس خطا و شاخص دقت کلی ارزیابی شد. در نهایت، نقشه طبقه‌بندی در محیط Google Earth Engine تولید شد و با اعمال یک فیلتر مکانی، قطعات با مساحت کمتر از یک هکتار از نقشه حذف شدند تا لکه‌های کوچک و پراکنده کاهش یافته و انسجام فضایی نقشه افزایش یابد (شکل ۷). بر اساس نقشه نهایی، مساحت اراضی شناسایی‌شده به‌عنوان کشت شلتوک در سال ۲۰۲۵ برابر با ۷۴۵۷ هکتار برآورد شد. این مقدار، برآورد سطح زیرکشت شلتوک بر اساس طبقه‌بندی تصاویر ماهواره‌ای و فرایند پس‌پردازش مکانی است و نشان‌دهنده الگوی مکانی اراضی شناسایی‌شده در محدوده مورد مطالعه است. نقشه نهایی علاوه بر ارائه اطلاعات مکانی درباره پراکنش شلتوک، می‌تواند به‌عنوان یک لایه پایه برای مطالعات بعدی، از جمله مدل‌سازی هیدرولوژیک، برآورد نیاز آبی و تحلیل فضایی الگوی مصرف آب در منطقه مورد استفاده قرار گیرد. همچنین، این داده مکانی می‌تواند در کنار اطلاعاتی مانند تبخیر–تعرق، اقلیم، خاک و سامانه‌های آبیاری، برای پشتیبانی از پایش اراضی شالیزاری و برنامه‌ریزی منابع آب به‌کار گرفته شود.

۵- جنبه‌های کاربردی

نتایج این پژوهش می‌تواند به‌عنوان یک لایه اطلاعاتی مکانی ـ زمانی برای پشتیبانی از تصمیم‌گیری در مدیریت اراضی شالیزاری و منابع آب در مناطق وابسته به رودخانه کارون مورد استفاده قرار گیرد. نقشه نهایی تهیه‌شده برای سال ۲۰۲۵، با برآورد سطح زیرکشت ۷۴۵۷ هکتار، امکان تعیین و به‌روزرسانی سطح واقعی کشت شلتوک و شناسایی پراکنش فضایی آن را فراهم می‌کند. این اطلاعات می‌تواند مبنایی برای مقایسه تغییرات سطح زیرکشت، شناسایی نواحی دارای تمرکز کشت و پایش توسعه یا کاهش اراضی شالیزاری در دوره‌های مختلف باشد. از منظر مدیریت منابع آب، اطلاعات سطح و پراکنش مکانی شالیزارها می‌تواند به‌عنوان یکی از ورودی‌های برنامه‌ریزی برای برآورد نیاز آبی و تخصیص منابع آب در سطح منطقه مورد استفاده قرار گیرد. به‌ویژه در محدوده‌هایی که کشت شلتوک وابستگی بالایی به منابع آب سطحی دارد، اطلاع از سطح واقعی اراضی زیرکشت می‌تواند به تصمیم‌گیری درباره نحوه توزیع منابع آب میان نواحی کشاورزی و اولویت‌بندی برنامه‌های مدیریتی کمک کند. با این حال، نتایج این پژوهش به‌تنهایی بیانگر میزان مصرف واقعی آب یا صرفه‌جویی در مصرف آب نیست و برای چنین ارزیابی‌هایی باید با داده‌های هواشناسی، خاک، تبخیر–تعرق و اطلاعات آبیاری تلفیق شود. تحلیل سری زمانی شاخص‌های NDVI ، EVI و LAIطی دوره ۲۰۲۲ تا ۲۰۲۵ نیز امکان استخراج الگوی زمانی رشد شلتوک و تعیین دوره اوج سبزینگی را فراهم

کرده است. این اطلاعات می‌تواند در کنار داده‌های اقلیمی و اطلاعات نیاز آبی گیاه برای برنامه‌ریزی زمان‌بندی آبیاری و پایش شرایط رشد مورد استفاده قرار گیرد. همچنین، مقایسه الگوی زمانی رشد با تقویم کشت می‌تواند به شناسایی تغییرات زمانی در استقرار و توسعه شالیزارها و بهبود برنامه‌ریزی عملیات کشاورزی کمک کند.

تلفیق داده‌های اپتیکی سنتینل-۲ با داده‌های راداری سنتینل-۱ و پردازش سری زمانی در محیط گوگل ارث انجین، ظرفیت لازم برای پایش دوره‌ای و نسبتاً سریع اراضی شالیزاری را فراهم می‌کند. استفاده هم‌زمان از اطلاعات طیفی و راداری، امکان بهره‌گیری از اطلاعات مکمل مربوط به وضعیت پوشش گیاهی، ساختار سطح و شرایط رطوبتی را فراهم کرده و می‌تواند در پایش مناطقی که استفاده صرف از تصاویر اپتیکی با محدودیت مواجه است، مفید باشد. بنابراین، چارچوب ارائه‌شده قابلیت توسعه به یک سامانه پایش دوره‌ای سطح زیرکشت و وضعیت رشد شلتوک را دارد؛ هرچند ایجاد یک سامانه عملیاتی مستلزم به‌روزرسانی منظم داده‌ها، خودکارسازی فرایند پردازش و اعتبارسنجی مستقل در دوره‌های زمانی و مناطق مختلف است. از نظر مدیریتی، نقشه سطح زیرکشت و اطلاعات فنولوژیک حاصل از این پژوهش می‌تواند در کنار سایر لایه‌های اطلاعاتی، برای ارزیابی الگوی کشت و بررسی تناسب سطح کشت محصولات آب‌بر با ظرفیت منابع آب منطقه نیز به کار گرفته شود. از این طریق، پایش مستمر پراکنش شالیزارها می‌تواند به شناسایی روندهای تغییر الگوی کشت و فراهم‌کردن شواهد مکانی برای سیاست‌گذاری و برنامه‌ریزی منابع آب کمک کند. در مجموع، کاربرد اصلی چارچوب پیشنهادی، تبدیل داده‌های ماهواره‌ای چندمنبعی و اطلاعات سری زمانی به اطلاعات قابل استفاده درباره سطح، پراکنش فضایی و روند زمانی رشد شلتوک است؛ اطلاعاتی که می‌تواند به‌عنوان پشتیبان تصمیم در پایش سطح زیرکشت، برنامه‌ریزی آبیاری، مدیریت و تخصیص منابع آب و ارزیابی الگوی کشت در مناطق کشاورزی وابسته به منابع آب سطحی مورد استفاده قرار گیرد.



شکل ۷- نقشه نهایی پراکنش کشت شلتوک در شهرستان باوی و اراضی پیرامون رودخانه کارون در سال ۲۰۲۵.
Fig. 7. Final map of paddy rice distribution in Bavi County and the surrounding areas of the Karun River, 2025.

۶- نتیجه‌گیری

این پژوهش با رویکرد چندمنبعی و با هدف شناسایی، نقشه‌برداری و پایش مراحل رشد کشت شلتوک در شمال شهرستان باوی و اراضی پیرامون رودخانه کارون انجام شد. در این مطالعه، داده‌های اپتیکی سنتینل-۲، داده‌های راداری سنتینل-۱ و روش‌های یادگیری ماشین در محیط Google Earth Engineبه‌منظور استخراج ویژگی‌های طیفی، ساختاری و زمانی پوشش گیاهی و تفکیک اراضی زیرکشت شلتوک به کار گرفته شدند. همچنین، با استفاده از سری زمانی شاخص‌های NDVI، EVI و LAI در دوره ۲۰۲۲ تا ۲۰۲۵، الگوی زمانی رشد و تغییرات فنولوژیک شلتوک در محدوده مورد مطالعه بررسی شد. نتایج تحلیل فنولوژیک نشان داد که شلتوک دارای الگوی زمانی مشخصی از تغییرات سبزینگی است و بیشترین مقادیر شاخص‌های پوشش گیاهی در دوره اوج رشد مشاهده می‌شود. بر اساس سری زمانی NDVI ، بیشترین مقدار سبزینگی در ماه سپتامبر ۲۰۲۵ ثبت شد و این دوره به‌عنوان یکی از زمان‌های مناسب برای تفکیک مکانی اراضی شلتوک در نظر گرفته شد. بررسی هم‌زمان NDVI، EVI و LAI نیز نشان داد که استفاده توأمان از شاخص‌های مختلف می‌تواند اطلاعات مکملی درباره تغییرات تراکم و ساختار پوشش گیاهی در مراحل مختلف رشد شلتوک فراهم کند.در بخش طبقه‌بندی، عملکرد الگوریتم‌های KNN، SVM و جنگل تصادفی مورد مقایسه قرار گرفت. نتایج نشان داد که هر سه الگوریتم قابلیت تفکیک کلاس‌های مختلف کاربری اراضی را دارند؛ با این حال، RF در مجموعه داده مورد استفاده عملکرد مناسب‌تری نشان داد و به‌عنوان مدل نهایی برای تهیه نقشه پراکنش شلتوک انتخاب شد. در طبقه‌بندی نهایی، ویژگی‌های استخراج‌شده از داده‌های اپتیکی سنتینل-۲ با ویژگی‌های راداری سنتینل-۱ شامل قطبش‌های VV و VHتلفیق شدند. استفاده از این ترکیب چندمنبعی امکان بهره‌گیری هم‌زمان از اطلاعات طیفی پوشش گیاهی و اطلاعات مرتبط با ساختار و شرایط سطح را فراهم کرد و به تفکیک بهتر کلاس‌های کاربری اراضی کمک نمود. ارزیابی مدل با استفاده از داده‌های اعتبارسنجی مستقل، ماتریس درهم‌ریختگی، دقت کلی و ضریب کاپا انجام شد. مدل نهایی جنگل تصادفی به دقت کلی ۹۱/۵۱ درصد و ضریب کاپای ۰/۹۳۱۰ دست یافت که نشان‌دهنده عملکرد مناسب مدل در تفکیک کلاس‌های مورد مطالعه است. بر اساس نقشه نهایی حاصل از طبقه‌بندی و پس‌پردازش مکانی، مساحت اراضی شناسایی‌شده به‌عنوان شلتوک در سال ۲۰۲۵ برابر با ۷۴۵۷ هکتار برآورد شد. این مقدار، برآورد سطح زیرکشت بر اساس داده‌های ماهواره‌ای و طبقه‌بندی انجام‌شده است و باید به‌عنوان یک برآورد سنجش‌ازدوری از سطح اراضی شناسایی‌شده تفسیر شود. از دیدگاه کاربردی، نتایج این پژوهش نشان می‌دهد که تلفیق داده‌های سنتینل-۱ و سنتینل-۲ با تحلیل سری زمانی شاخص‌های گیاهی و الگوریتم‌های یادگیری ماشین می‌تواند یک چارچوب مناسب برای پایش مکانی و زمانی اراضی شالیزاری فراهم کند. نقشه نهایی و لایه‌های اطلاعاتی تولیدشده می‌توانند به‌عنوان داده پایه در سامانه‌های پشتیبان تصمیم برای مدیریت اراضی کشاورزی و منابع آب مورد استفاده قرار گیرند. این اطلاعات می‌تواند در به‌روزرسانی سطح و پراکنش اراضی شالیزاری، پایش تغییرات سطح زیرکشت، بررسی تغییرات الگوی کشت و پشتیبانی از برنامه‌ریزی منابع آب در محدوده وابسته به رودخانه کارون کاربرد داشته باشد. همچنین، در صورت تلفیق نقشه پراکنش شلتوک با داده‌های تبخیر–تعرق، اقلیم، خاک و اطلاعات مربوط به سامانه‌های آبیاری، می‌توان از این اطلاعات برای برآورد نیاز آبی، تحلیل الگوی مصرف آب و پشتیبانی از برنامه‌ریزی و تخصیص منابع آب استفاده کرد. در مجموع، نتایج پژوهش بیانگر آن است که استفاده هم‌زمان از اطلاعات طیفی، راداری و زمانی، در کنار الگوریتم‌های یادگیری ماشین، ظرفیت مناسبی برای پایش شلتوک و تولید اطلاعات مکانی مورد نیاز برای مدیریت کشاورزی و منابع آب دارد. توسعه این رویکرد به سمت پایش‌های دوره‌ای و سامانه‌های عملیاتی مستلزم به‌روزرسانی منظم داده‌ها، خودکارسازی فرایند پردازش و طبقه‌بندی و اعتبارسنجی مستقل در دوره‌ها و مناطق مختلف است.

مراجع

Abdi-Dehkordi, M., Bozorg-Haddad, O., Salavitabar, A., 2021. Developing a sustainability assessment framework for integrated management of water resources systems using distributed zoning and system dynamics approaches. Environment, Development and Sustainability 23, 16246–16282. https://doi.org/10.1007/s10668-021-01340-0

Ahmed, Z., Jing, L., Naeem, M., Tahir, M., Qurat-ul-Ain, Zafar, M., 2024. Analyzing vegetation health dynamics across seasons and regions through NDVI and climatic variables. Scientific Reports 14, 11775. https://doi.org/10.3390/s41598-024-62464-7

Almalki, R., Khaki, M., Saco, P. M., Rodriguez, J.F., 2022. Monitoring and Mapping Vegetation Cover Changes in Arid and Semi-Arid Areas Using Remote Sensing Technology: A Review. *Remote Sensing 14*(20), 5143. https://doi.org/10.3390/rs14205143

Bahiraie, M., Hosseini, S.M., Hossein-Panahi, B., 2025. Groundwater resources exploitation management in response to water scarcity challenges in Khuzestan Province, Iran. *Journal of Groundwater Science and Engineering 13*(3), 268-285. https://doi.org/10.26599/JGSE.2025.9280054

Bauer-Marschallinger, B., Cao, S., Navacchi, C., Reimer, C., Pfeil, I., Hochstöger, S., Paulik, C., Brombacher, J., Melzer, T., Milovac, J., Cisneros, S., Sabel, D., Schlaffer, S., Haub, M., Hochschild, J., Wallisch, A., Brocca, L., Salach, A., Milenkovic, M., Notarnicola, C., Angileri, V., Wagner, W., 2021. The normalised Sentinel-1 Global Backscatter Model, mapping Earth's land surface with C-band microwaves. Scientific Data 8, 277. https://doi.org/10.1038/s41597-021-01059-7

Bhattacharya, A., 2022. Effect of Low-Temperature Stress on Germination, Growth, and Phenology of Plants: A Review. In: Physiological Processes in Plants Under Low Temperature Stress. Springer, Singapore, pp. 1–106. https://doi.org/10.1007/978-981-16-9037-2_1

Caruso, G., Palai, G., Tozzini, L., D'Onofrio, C., Gucci, R., 2023. The role of LAI and leaf chlorophyll on NDVI estimated by UAV in grapevine canopies. Scientia Horticulturae 322, 112398. https://doi.org/10.1016/j.scienta.2023.112398

Dakhili, M., Zahiri, J., Cheraghi, M., Moradi, S., 2025. Assessment of agricultural drainage water quality for irrigation reuse using hydrochemical indices (case study: Bavi County, Khuzestan). Iranian Journal of Soil and Water Research 56(7), 1949–1966. https://doi.org/10.22059/ijswr.2025.394995.669936

Eyni-Nargeseh, H., Asgharipour, M.R., Rahimi-Moghaddam, S., Gilani, A., Damghani, A. M., Azizi, K., 2023. Which rice farming system is more environmentally friendly in Khuzestan province, Iran? A study based on emergy analysis. Ecological Modelling 481, 110373. https://doi.org/10.1016/j.ecolmodel.2023.110373

Falcioni, R., Santos, G.L.A.A.d., Crusiol, L. G.T., Antunes, W.C., Chicati, M.L., Oliveira, R.B.d., Demattê, J.A.M., Nanni, M.R., 2023. Non−Invasive Assessment, Classification, and Prediction of Biophysical Parameters Using Reflectance Hyperspectroscopy. Plants 12(13), 2526. https://doi.org/10.3390/plants12132526

Foody, G.M., 2023. Challenges in the real-world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient. PLOS ONE 18(10), e0291908. https://doi.org/10.1371/journal.pone.0291908

Gharibreza, M., Soleimani, F., Soozangar, F., 2023. Environmental geochemistry and ecological risk for aquatic life and human health of the Karun River (Iran). International Journal of Environmental Science and Technology 20, 1801–1822. https://doi.org/10.1007/s13762-022-04703-w

Gong, Y., Yang, K., Lin, Z., Chen, X., Zhao, C., 2021. Remote estimation of leaf area index (LAI) with unmanned aerial vehicle (UAV) imaging for different rice cultivars throughout the entire growing season. Plant Methods 17, 88. https://doi.org/10.1186/s13007-021-00789-4

Granata, F., Zhu, S., Di Nunno, F., 2025. Hydrological extremes in the Mediterranean basin: interactions, impacts, and adaptation in the face of climate change. Regional Environmental Change 25, 100. https://doi.org/10.1007/s10113-025-02432-7

Han, J., Zhu, J., Cao, X., Xi, L., Qi, Z., Li, Y., Wang, X., Zou, J., 2025. Extraction of sparse vegetation cover in deserts based on UAV remote sensing. Remote Sensing 17(15), 2665. https://doi.org/10.3390/rs17152665

Hassan, M.A., Chang, C.Y.Y., 2025. PhenoGazer: A high-throughput phenotyping system to track plant stress responses using hyperspectral reflectance, nighttime chlorophyll fluorescence and RGB imaging in controlled environments. Plant Phenomics 7(2), 100047. https://doi.org/10.1016/j.plaphe.2025.100047

Huang, S., Tang, L., Hupy, J.P., 2021. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. Journal of Forestry Research 32, 1–6. https://doi.org/10.1007/s11676-020-01155-1

Kabelizadeh, M., Rangzan, K., Rashidian, M., Delfan, H., 2018. Estimation of total dissolved solids and turbidity of water in Karkheh and Dez dams and the Great Karun River using Sentinel-2 satellite images. Advanced Applied Geology 8(4), 17-27. https://doi.org/10.22055/aag.2019.24426.1807

Karimi, M., Ahmadi Nadoushan, M., Chavoshi, E., 2025. A decade-long spatial analysis of opportunistic rice cultivation in a water-stressed agricultural landscape. Environmental Monitoring and Assessment 197, 216. https://doi.org/10.1007/s10661-025-13656-9

Kior, A., Sukhov, V., Sukhova, E., 2021. Application of Reflectance Indices for Remote Sensing of Plants and Revealing Actions of Stressors. Photonics 8(12), 582. https://doi.org/10.3390/photonics8120582

Kurbanov, R.K., Zakharova, N.I., 2020. Application of vegetation indexes to assess the condition of crops. Agricultural Machinery and Technologies 14(4), 4–11. https://doi.org/10.22314/2073-7599-2020-14-4-4-11

Liu, S., Jin, X., Nie, C., Wang, S., Yu, X., Cheng, M., Yang, G., Liu, Y., 2021. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms. Plant Physiology 187(3), 1551–1576. https://doi.org/10.1093/plphys/kiab322

Naeem, S., Ali, A., Anam, S., Ahmed, M.M., 2023. An unsupervised machine learning algorithm: Comprehensive review. *International Journal of Computing and Digital Systems* 13(1), 1224-1233. https://doi.org/10.12785/ijcds/130172

Podani, J., Schmera, D., Bagella, S., 2023. Correlating variables with different scale types: A new framework based on matrix comparisons. Methods in Ecology and Evolution 14 (4), 1049–1060. https://doi.org/10.1111/2041-210X.14074

Pommé, L.-E., Bourqui, R., Giot, R., Auber, D., 2022. Relative Confusion Matrix: Efficient Comparison of Decision Models. 26th International Conference on Information Visualisation (IV), 98–103. https://doi.org/10.1109/IV56949.2022.00025

Qiao, K., Zhu, W., Xie, Z., Wu, S., Li, S., 2024. New three red-edge vegetation index (VI3RE) for crop seasonal LAI prediction using Sentinel-2 data. International Journal of Applied Earth Observation and Geoinformation 130, 103894. https://doi.org/10.1016/j.jag.2024.103894

Rabie, A.B., Elhag, M., Subyani, A. 2025. Remote sensing, GIS, and machine learning in water resources management for arid agricultural regions: A review. Water, 17(21), 3125. DOI: https://doi.org/10.3390/w17213125

Raschka, S., Patterson, J., Nolet, C., 2020. Machine learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence. Information 11 (4), 193. https://doi.org/10.3390/info11040193

Rastmanesh, F., Hasna, Z., Zarasvandi, A., 2019. Enrichment, origin, and health risk of heavy metals in rice fields: A case study of Ahvaz and Bavi counties. Advanced Applied Geology 9(1), 75-84. https://doi.org/10.22055/aag.2019.28395.1935

Richards, J.A., 2022. Supervised classification techniques. In: Richards, J. A. (Ed.), Remote Sensing Digital Image Analysis. Springer International Publishing, Cham, pp. 263–367. https://doi.org/10.1007/978-3-030-82327-6_8

Salman, H.A., Kalakech, A., Steiti, A., 2024. Random forest algorithm overview. Babylonian Journal of Machine Learning, 69–79. https://doi.org/10.58496/BJML/2024/007

Salman, H.H., Jazaa, H.S., 2023. Shatt Al-Arab River and the seawater intrusion: causes and solutions. Al-Bahir 2 (1), 6. https://doi.org/10.55810/2313-0083.1018

Sarker, I.H., 2021. Machine learning: Algorithms, real-world applications and research directions. SN Computer Science 2 (3), 1–21. https://doi.org/10.1007/s42979-021-00592-x

Shetty, S.H., Shetty, S., Singh, C., Rao, A., 2022. Supervised machine learning: algorithms and applications. In: Fundamentals and Methods of Machine and Deep Learning: Algorithms, Tools and Applications. Wiley, pp. 1–16. https://doi.org/10.1002/9781119821908.ch1

Singh, N.K., Nagahara, M., 2024. LightGBM-, SHAP-, and Correlation-Matrix-Heatmap-Based approaches for analyzing household energy data: Towards electricity self-sufficient houses. Energies 17 (17), 4518. https://doi.org/10.3390/en17174518

Sishodia, R.P., Ray, R.L., Singh, S.K., 2020. Applications of remote sensing in precision agriculture: A review. Remote Sensing 12 (19), 3136. https://doi.org/10.3390/rs12193136

Suyal, M., Goyal, P., 2022. A review on analysis of k-nearest neighbor classification machine learning algorithms based on supervised learning. International Journal of Engineering Trends and Technology 70 (7), 43–48. https://doi.org/10.14445/22315381/IJETT-V70I7P205

Varoquaux, G., Colliot, O., 2023. Evaluating machine learning models and their diagnostic value. In: Machine Learning for Brain Disorders. Springer, pp. 601–630. https://doi.org/10.1007/978-1-0716-3195-9_20

Verma, P., Raghubanshi, A., Srivastava, P.K., Raghubanshi, A.S., 2020. Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. Modeling Earth Systems and Environment 6 (2), 1045–1059. https://doi.org/10.1007/s40808-020-00740-x

Vijith, H., Dodge-Wan, D., 2020. Applicability of MODIS land cover and Enhanced Vegetation Index (EVI) for the assessment of spatial and temporal changes in strength of vegetation in tropical rainforest region of Borneo. Remote Sensing Applications: Society and Environment 18, 100311. https://doi.org/10.1016/j.rsase.2020.100311

Wang, Z., Jia, Y., Niu, C., Liu, J., Jin, J., Liao, Z., Zhang, J., 2025. Spatiotemporal variation in fractional vegetation coverage and quantitative analysis of its driving forces: A case study in the Tabu River Basin, Northern China, 1986–2023. Remote Sensing 17 (14), 2490. https://doi.org/10.3390/rs17142490

Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A.B., Qin, X., Loupian, E., 2023. Challenges and opportunities in remote sensing-based crop monitoring: A review. National Science Review 10 (4), nwac290. https://doi.org/10.1093/nsr/nwac290

Yang, C.Y., Yang, M.D., Tseng, W.C., Hsu, Y.C., Li, G.S., Lai, M.H., Lu, H.Y., 2020. Assessment of rice developmental stage using time series UAV imagery for variable irrigation management. Sensors 20 (18), 5354. https://doi.org/10.3390/s20185354

Yang, X., Zuo, X., Xie, W., Li, Y., Guo, S., Zhang, H., 2022. A correction method of NDVI topographic shadow effect for rugged terrain. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 15, 8456–8472. https://doi.org/10.1109/JSTARS.2022.3193419

Yazdanpanah Dero, Q., Sharif, M., Nikzad Samarin, A., Naseri, A.A., Mohammadi, H.R., 2025. Monitoring of water resources based on remote sensing and ground data, a comprehensive analysis of human and climate impact. Modeling Earth Systems and Environment 11 (1), 24. https://doi.org/10.1007/s40808-024-02193-y

Zeng, Y., Hao, D., Huete, A., Dechant, B., Berry, J., Chen, J.M., Chen, M., 2022. Optical vegetation indices for monitoring terrestrial ecosystems globally. Nature Reviews Earth & Environment 3 (7), 477–493. https://doi.org/10.1038/s43017-022-00298-5

Zhang, G., Ming, B., Shen, D., Xie, R., Hou, P., Xue, J., Li, S., 2021. Optimizing grain yield and water use efficiency based on the relationship between leaf area index and evapotranspiration. Agriculture 11 (4), 313. https://doi.org/10.3390/agriculture11040313

Zhang, R., Bao, X., Hong, R., He, X., Yin, G., Chen, J., Liu, G., 2024. Soil moisture retrieval over croplands using novel dual-polarization SAR vegetation index. Agricultural Water Management 306, 109159. https://doi.org/10.1016/j.agwat.2024.109159

Zhao, M., Lin, Y., Chen, H., 2020. Improving nutritional quality of rice for human health. Theoretical and Applied Genetics 133(5), 1397-1413. https://doi.org/10.1007/s00122-019-03530-x

Zheng, Z., Wu, Z., Chen, Y., Guo, C., Marinello, F., 2022. Instability of remote sensing based ecological index (RSEI) and its improvement for time series analysis. Science of the Total Environment 814, 152595. https://doi.org/10.1016/j.scitotenv.2021.152595