



Monitoring the water level of Jareh Dam reservoir by integrating Sentinel-2 images and the random forest algorithm

Javad Zahiri^{*1} 

¹ Associate Professor, Department of Water Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran, E-mail: j.zahiri@asnrukh.ac.ir

ARTICLE INFO	ABSTRACT
Article type: Research Paper Article history Received: 3 June 2026 Revised: 5 July 2026 Accepted: 5 July 2026 Published online: 27 July 2026 Keywords: Machine Learning, Remote Sensing, Spectral Indices, Uncertainty Analysis, Water Resources Management. Citation: Zahiri, J. (2026). Monitoring the water level of Jareh Dam reservoir by integrating Sentinel-2 images and the random forest algorithm. <i>Iranian Journal of Rainwater Catchment Systems</i>, 14(2), 99-116. DOR: 20.1001.1.24235970.1405.14.2.7.6 Publisher: Iranian Rainwater Catchment Systems Association	Reservoirs play a key role in providing drinking water, agriculture, hydropower generation, and flood control by enabling the storage, regulation, and distribution of freshwater. However, sustainable reservoir operation depends on accurate data on water level and surface area. Traditional field measurement methods, despite their high accuracy, are not efficient for widespread and continuous reservoir monitoring—especially in arid and semi-arid regions—due to high costs, logistical constraints, and lack of access to remote areas. In this study, an integrated framework was developed for daily reservoir water level estimation at the Jarreh Dam reservoir by combining Sentinel-2 imagery, the ALOS PALSAR Digital Elevation Model (DEM), and the Random Forest algorithm. The NDWI (Normalized Difference Water Index) and MNDWI (Modified Normalized Difference Water Index) spectral indices were used to extract the water body and calculate surface water area. Water edge elevation was extracted by applying the DEM to the reservoir boundary pixels. Three different scenarios were designed: satellite-derived features (modeled water level from DEM, NDWI, MNDWI, and reservoir area), along with measured water level data from 5 days and 10 days prior. The data were split into training (80%) and testing (20%) sets and then standardized. Results showed that the Random Forest model in the first scenario achieved acceptable performance (test RMSE = 1.33 m). However, adding water level data from 5 days prior (second scenario) significantly improved performance, reducing the test RMSE to 0.74 m and achieving an NSE (Nash–Sutcliffe efficiency coefficient) value of 0.92. The third scenario showed no meaningful improvement over the second scenario. Uncertainty assessment using out-of-bag error indicated that the second and third scenarios had narrower uncertainty bands (approximately 1.40 m for the 90% confidence interval) compared to the first scenario (1.65 m). However, the first scenario enables reservoir water level estimation using solely remote sensing data, without the need for in-situ measurements, and thus holds particular practical significance for regions lacking gauge stations. The sensitivity analysis revealed that the model is most dependent on measured water levels, followed by water level and reservoir area extracted from satellite imagery, which play the most substantial role in determining model outputs.
© Author(s) 	

***Corresponding author:** Javad Zahiri

Address: Department of Water Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran.

Tel: +989166531896

Email: : j.zahiri@asnrukh.ac.ir

Monitoring the water level of Jareh Dam reservoir by integrating Sentinel-2 images and the random forest algorithm

Javad Zahiri^{*1} 

¹ Associate Professor, Department of Water Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran, E-mail: j.zahiri@asnruk.ac.ir

EXTENDED ABSTRACT

Introduction: Water is a fundamental resource for sustaining ecosystems, food security, and human livelihoods. However, its uneven global distribution poses significant challenges for water resources management. Reservoirs play a key role in addressing these challenges by enabling the storage, regulation, and distribution of freshwater for drinking water, agriculture, hydropower, flood control, and industrial processes. Despite the construction of over one million dams worldwide, sustainable reservoir operation depends heavily on accurate data on water level, surface area, and storage volume. Traditional field measurements, although accurate, are often costly, logistically challenging, and impractical in remote or data-sparse regions, particularly in arid and semi-arid areas. Remote sensing offers a low-cost and effective alternative for continuous reservoir monitoring. Spectral indices such as NDWI (Normalized Difference Water Index) have been widely used to extract surface water extent from satellite imagery. Recent studies have demonstrated the value of integrating multi-source satellite data with cloud computing platforms like Google Earth Engine for large-scale reservoir monitoring. Furthermore, machine learning algorithms have shown great potential in handling nonlinear relationships in hydrological remote sensing data. Studies have successfully applied Support Vector Machines and Random Forest for water body mapping and reservoir monitoring.

Building on these advances, the present study develops an integrated framework that combines Sentinel-2 imagery, a Digital Elevation Model (DEM), and the Random Forest algorithm to estimate daily reservoir water levels without the need for in-situ bathymetric data. This approach provides an efficient, low-cost, and scalable tool for continuous reservoir monitoring, especially in regions lacking gauge stations.

Methodology: The Jarreh Dam, an earth-fill dam with a clay core and concrete face, is located 20 km northeast of Ramhormoz on the Zard River. Daily measured water level data from 2015 to 2026 were used for model training and validation. Sentinel-2 MSI Level-2A images (2015–2026) with less than 20% cloud cover were obtained from Google Earth Engine. Cloud masking was applied using the QA60 band, and bands B3 (green), B8 (NIR), and B11 (SWIR) were selected for analysis. NDWI and MNDWI (Modified Normalized Difference Water Index) spectral indices were calculated, and a threshold of 0.1 was applied to generate a binary water mask. The ALOS PALSAR DEM was used to extract water edge elevation by calculating the median elevation along the reservoir boundary, and water surface area was also estimated. Three scenarios were defined: Scenario 1 used only satellite-derived features (modeled water level, NDWI, MNDWI, area); Scenario 2 added measured water level from 5 days prior; Scenario 3 added measured water level from 5 and 10 days prior. Data were split into training (80%) and testing (20%) sets and standardized using Z-score normalization. A Random Forest regression model consisting of 150 decision trees and a minimum leaf size of 3 was trained. At each split, all available predictor variables were evaluated to identify the optimal partition based on variance reduction. Out-of-bag error was used for internal validation and uncertainty estimation (68%, 90%, and 95% confidence intervals). Model performance was evaluated using R^2 (coefficients of determination), RMSE (Root Mean Squared Error), and NSE (Nash–Sutcliffe efficiency coefficient).

Results and Discussion: Integration of Sentinel-2 and ALOS DEM data enabled accurate identification of the water-land boundary, with NDWI demonstrating superior spatial resolution for water extraction compared to MNDWI, particularly in shallow and marginal zones. Three scenarios were evaluated using the Random Forest

***Corresponding author:** Javad Zahiri

Address: Department of Water Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran.

Tel: +989166531896

Email: : j.zahiri@asnruk.ac.ir

model. Scenario 1 (satellite data only) achieved a test RMSE of 1.33 m with mild overfitting; low water levels (470-475 m) showed overestimation due to weak satellite signal reflectance, while high water levels (490-495 m) exhibited local fluctuations. Scenario 2 (satellite data + 5-day lagged measured water level) significantly improved performance, reducing test RMSE to 0.74 m (44% improvement) and achieving NSE = 0.92, with more overfitting compared to Scenario 1 (RMSE increase of 0.25 m from training to testing). Scenario 3 (adding a 10-day lag) showed no meaningful improvement over Scenario 2. Uncertainty assessment revealed that Scenarios 2 and 3 had narrower 90% confidence interval bandwidths (1.40 m) compared to Scenario 1 (1.65 m), with coverage rates of 93% close to the theoretical 90% value. Overall, the Random Forest model with a single 5-day lagged water level provides an efficient, low-cost, and generalizable tool for continuous reservoir water level monitoring.

Conclusion: This study aimed to estimate the water level of the Jarreh Dam reservoir by integrating Sentinel-2 remote sensing data, the ALOS Digital Elevation Model (DEM), and the Random Forest machine learning algorithm. The results demonstrated that combining spectral and topographic information enables accurate delineation of the water-land boundary and effective monitoring of spatial variations in the reservoir. From the scenario analysis, the first scenario demonstrated that reservoir water levels can be estimated solely from remotely sensed data, without requiring in-situ measurements. Although the second and third scenarios, which incorporated lagged water level variables, improved predictive accuracy, they showed no substantial performance advantage over the simpler persistence-based approach. The sensitivity analysis revealed that the model was most responsive to variables representing the temporal dynamics of reservoir water levels, with short-term lagged water levels exerting the greatest influence on model performance. Furthermore, the out-of-bag (OOB)-based uncertainty assessment indicated that the prediction intervals achieved coverage rates close to the nominal 90% confidence level, demonstrating the reliability of the uncertainty estimates. From a practical perspective, the proposed framework provides a cost-effective and reliable tool for continuous monitoring of reservoir water levels, particularly in arid and semi-arid regions where in-situ measurements are unavailable or difficult to obtain.

Ethical Considerations

Data availability statement: The datasets are available upon reasonable request to the corresponding author.

Funding: This research was carried out with the financial support and facilities provided by the Agricultural Sciences and Natural Resources University of Khuzestan.

Authors' contributions: **Zahiri, J.:** Conception and design, Data collection, Analysis and interpretation of results, Manuscript preparation.

Conflicts of interest: The author of this article declared no conflict of interest regarding the authorship or publication of this article.

Acknowledgment: The author expresses his gratitude for the support and facilities provided by the Agricultural Sciences and Natural Resources University of Khuzestan. He also extends his thanks and appreciation to the Khuzestan Water and Power Authority (KWPA) for providing the data used in this research.

پایش تراز آب مخزن سد جره با تلفیق تصاویر سنتینل-۲ و الگوریتم جنگل تصادفی

جواد ظهیری^{۱*}

^۱ دانشیار، گروه مهندسی آب، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران.
j.zahiri@asnruk.ac.ir

مشخصات مقاله	چکیده
نوع مقاله: پژوهشی تاریخچه مقاله دریافت: ۱۳ خرداد ۱۴۰۵ بازنگری: ۱۴ تیر ۱۴۰۵ پذیرش: ۱۴ تیر ۱۴۰۵ انتشار برخط: ۰۵ مرداد ۱۴۰۵ واژه های کلیدی: تحلیل عدم قطعیت، سنجش از دور، شاخص های طیفی، مدیریت منابع آب، یادگیری ماشین	مخازن با امکان ذخیره، تنظیم و توزیع آب شیرین، نقش کلیدی در تأمین آب شرب، کشاورزی، تولید برق آبی و کنترل سیلاب ایفا می کنند. با این حال، بهره برداری پایدار از مخازن به داده های دقیق تراز آب و مساحت سطح مخزن وابسته است. روش های سنتی اندازه گیری میدانی علی رغم دقت بالا، به دلیل هزینه زیاد، محدودیت های لجستیکی و عدم دسترسی به مناطق دورافتاده، برای پایش گسترده و مداوم مخازن به ویژه در مناطق خشک و نیمه خشک کارآمد نیستند. در این پژوهش، یک چارچوب یکپارچه برای تخمین روزانه تراز سطح آب مخزن سد جره با تلفیق تصاویر سنتینل-۲، مدل رقومی ارتفاعی ALOS PALSAR و الگوریتم جنگل تصادفی توسعه داده شد. شاخص های طیفی Normalized Difference Water Index (NDWI) و Modified Normalized Difference Water Index (MNDWI) برای استخراج پهنه آبی و محاسبه مساحت سطح آب به کار رفتند. ارتفاع لبه آب با اعمال مدل رقومی ارتفاع بر روی پیکسل های مرزی مخزن استخراج شد. سه سناریوی متفاوت شامل داده های ماهواره ای (تراز آب مدل سازی شده، NDWI، MNDWI و مساحت مخزن)، همراه با داده های تراز آب اندازه گیری شده با ۵ روز و ۱۰ روز قبل طراحی شد. داده ها با نسبت ۸۰ به ۲۰ درصد به دو مجموعه آموزش و آزمون تقسیم و سپس استاندارد شدند. نتایج نشان داد مدل جنگل تصادفی در سناریوی اول عملکرد قابل قبولی داشت (RMSE آزمون ۱/۳۳ متر)، اما افزودن داده های تراز آب ۵ روز پیش (سناریوی دوم) بهبود چشمگیری ایجاد کرد و RMSE مجموعه آزمون را به ۰/۷۴ متر کاهش داد و ضریب نش-ساتکلیف را به ۰/۹۲ رساند. سناریوی سوم بهبود معناداری نسبت به سناریوی دوم نداشت. ارزیابی عدم قطعیت با استفاده از خطای برون کیسه ای نشان داد که سناریوی دوم و سوم از پهنای باند عدم قطعیت باریک تری (حدود ۱/۴۰ متر برای بازه اطمینان ۹۰ درصد) در مقایسه با سناریو اول (۱/۶۵ متر) برخوردار هستند. با این حال، سناریوی اول امکان برآورد تراز سطح آب مخزن تنها بر اساس داده های سنجش از دور و بدون استفاده از داده های میدانی را فراهم می کند و بنابراین از نظر کاربردی برای مناطق فاقد ایستگاه اندازه گیری از اهمیت ویژه ای برخوردار است. نتایج تحلیل حساسیت نشان داد که مدل بیش از همه به پارامترهای تراز آب اندازه گیری شده وابسته است. پس از آن، پارامترهای تراز آب و مساحت مخزن استخراج شده از تصاویر ماهواره ای، بیش ترین نقش را در تعیین خروجی مدل دارند.
استناد: ظهیری، جواد (۱۴۰۵). پایش تراز آب مخزن سد جره با تلفیق تصاویر سنتینل-۲ و الگوریتم جنگل تصادفی. سامانه های سطوح آبگیر باران، ۱۱ (۳)، ۹۹-۱۱۶.	
DOR: 20.1001.1.24235970.1405.14.2.7.6	
ناشر: انجمن علمی سیستم های سطوح آبگیر باران ایران	© نویسندگان



مقدمه

آب منبعی اساسی برای پایداری بوم‌سازگان‌ها، امنیت غذایی و حمایت از معیشت انسانی است. یکی از مهم‌ترین چالش‌های موجود در زمینه منابع آب، توزیع نامناسب آن در سطح جهان است که اغلب محدودیت‌های قابل توجهی برای برنامه‌ریزی و مدیریت این منابع ایجاد می‌کند (Sheffield et al., 2018; Codjia et al., 2025). مخازن نقش مهمی در مواجهه با این چالش‌ها ایفا می‌کنند، زیرا امکان ذخیره، تنظیم و توزیع آب شیرین را برای کاربردهای متنوع از جمله تأمین آب شرب، کشاورزی، تولید انرژی برق‌آبی، شیلات و فرآیندهای صنعتی فراهم می‌کنند (Wada et al., 2017). این مخازن اجزای اساسی سیستم منابع آب را تشکیل می‌دهند و به عنوان تنظیم‌کننده میان نوسانات طبیعی هیدرولوژیکی و تقاضای انسانی عمل می‌کنند. علاوه بر این اهمیت سیستمی آن‌ها در تثبیت دسترسی منطقه‌ای به آب، تغذیه آب‌های زیرزمینی، کاهش سیلاب و سازگاری با تغییرات اقلیمی از طریق تعدیل تغییرات فصلی و رخدادهای حادی مورد تأکید قرار گرفته است (Donchyts et al., 2022). ساخت و بهره‌برداری از بیش از یک میلیون سد خدمات متنوعی را برای جمعیت رو به رشد انسانی فراهم کرده است (Lehner et al., 2011). در مقیاس جهانی، آب مخازن حدود ۳۰ تا ۴۰ درصد از اراضی آبیاری شده و ۲۰ درصد از انرژی برق‌آبی جهان را فراهم می‌سازد، و کارکردهای مفید دیگری از جمله کنترل سیلاب، ناپوری و تفریح را نیز پشتیبانی می‌کند (Demirbas, 2009). در عین حال، مخازن چرخه هیدرولوژیکی را به طور قابل توجهی تغییر داده و تأثیرات شدیدی بر پویایی بوم‌سازگان‌ها و رژیم‌های رودخانه‌ای داشته‌اند (Deng et al., 2020).

مدیریت مؤثر مخازن مستلزم دسترسی به اطلاعات دقیق و به‌هنگام از ویژگی‌های فیزیکی آن‌ها، از جمله مساحت سطح آب، تراز و حجم ذخیره است (Rodríguez-Alarcón and Lozano, 2017; Codjia et al., 2025). اگرچه این اطلاعات به‌طور سنتی از طریق اندازه‌گیری‌های میدانی و ایستگاه‌های هیدرومتری جمع‌آوری می‌شوند، اما این روش‌ها به دلیل هزینه‌های بالا، محدودیت‌های زمانی، دشواری دسترسی و گاه ملاحظات سیاسی یا امنیتی، قابلیت پایش گسترده و مستمر بسیاری از مخازن را ندارند (Eldardiry and Hossain, 2021). این محدودیت‌ها به‌ویژه در مورد مخازن جدید یا مناطق دورافتاده که اطلاعات آن‌ها به‌طور کامل در دسترس نیست، محسوس‌تر بوده و توسعه روش‌های جایگزین مبتنی بر سنجش از دور را ضروری ساخته است (Deng et al., 2020).

در سال‌های اخیر، سنجش از دور به دلیل توانایی در پایش گسترده، مستمر و کم‌هزینه منابع آب، به یکی از مهم‌ترین ابزارهای ارزیابی مخازن تبدیل شده است (Zahiri et al., 2025). بخش قابل توجهی از مطالعات اولیه بر استخراج پهنه‌های آبی با استفاده از شاخص‌های طیفی مبتنی بر باندهای مرئی و مادون قرمز و تلفیق این شاخص‌ها متمرکز بوده‌اند (Gao et al., 2012; Zhang et al., 2017). در این میان، شاخص تفاضل نرمال شده آب (NDWI) و سایر شاخص‌های مشابه، به دلیل حساسیت کم‌تر نسبت به پوشش گیاهی و توانایی مناسب در تفکیک آب از سایر کاربری‌ها، کاربرد گسترده‌ای یافته‌اند (Feyisa et al., 2014). شاخص NDWI با بهره‌گیری از اختلاف بازتاب باند سبز و مادون قرمز نزدیک، بازتاب پوشش گیاهی را کاهش داده و پهنه‌های آبی را برجسته می‌کند (Yao et al., 2022).

هم‌زمان با توسعه سنجنده‌های ماهواره‌ای و سامانه‌های رایانش ابری، تمرکز پژوهش‌ها از استخراج صرف پهنه آبی به سمت پایش کمی ویژگی‌های مخازن و تحلیل سری‌های زمانی بلندمدت تغییر یافته است. برای نمونه، Zhang et al. (2017) چارچوبی مبتنی بر Google Earth Engine ارائه کرد که با استخراج مساحت مخازن از تصاویر Landsat و برآورد تبخیر، امکان تحلیل منطقه‌ای مخازن را فراهم ساخت. Deng et al. (2020) نیز با تلفیق سری زمانی NDWI حاصل از تصاویر MODIS و مدل رقومی ارتفاع SRTM، پایگاه داده‌ای شامل ۱۴۹ مخزن ایجاد کردند که تغییرات فصلی و روند افزایشی ذخیره آب را با دقت مناسبی نشان داد. در مطالعه‌ای جدیدتر، Chang et al. (2025) با ادغام داده‌های چندماهواره‌ای با قدرت تفکیک مکانی و زمانی متفاوت، شاخص RS-HRDI را توسعه دادند که فاصله زمانی بین مشاهدات مخازن را از مقیاس ماهانه به حدود چهار روز کاهش داد و امکان پایش سریع رخدادهای خشکسالی را فراهم کرد. این مطالعات نشان می‌دهند که ترکیب داده‌های چندمنبعی و بهره‌گیری از محیط‌های پردازش ابری، محدودیت‌های زمانی و مکانی پایش مخازن را تا حد زیادی کاهش داده است.

روش‌های یادگیری ماشین که به دلیل شناسایی الگوها و استخراج ویژگی‌ها در شناخت سیستم‌های اقلیمی کارآمد هستند (Sadian and Nemati Shishehgaran, 2026)، به واسطه مدل‌سازی روابط غیرخطی، توجه گسترده‌ای در مطالعات منابع آب نیز پیدا کرده‌اند (Zahiri and Mirzaei, 2025). برای مثال، Mahmood et al. (2025) با استفاده از شاخص NDWI و مدل ماشین بردار پشتیبان، تغییرات سه دریاچه مهم عراق را بر اساس تصاویر Sentinel-2 پایش کردند و نتایج مناسبی در شناسایی تغییرات سطح آب به دست آوردند. Amer et al. (2025) نیز با استفاده از تصاویر Landsat و سه الگوریتم KNN، جنگل تصادفی و مدل ترکیبی KNN-RF، ویژگی‌های ژرفاسنجی سد بنی‌هارون را برآورد کردند و نشان دادند که مدل جنگل تصادفی و به‌ویژه مدل ترکیبی، دقت بالاتری نسبت به سایر روش‌ها دارند. این


مطالعات بیانگر آن است که تلفیق داده‌های سنجش از دور با الگوریتم‌های یادگیری ماشین، قابلیت بالایی در استخراج ویژگی‌های هیدرولوژیکی مخازن دارد.

مرور مطالعات پیشین نشان می‌دهد که اگرچه پیشرفت‌های قابل توجهی در پایش مخازن با استفاده از سنجش از دور و الگوریتم‌های یادگیری ماشین حاصل شده است، اما بخش عمده این پژوهش‌ها بر استخراج پهنه آبی، برآورد مساحت سطح آب یا تخمین حجم ذخیره متمرکز بوده‌اند. از سوی دیگر، در بسیاری از مطالعات، مدل‌های توسعه یافته به داده‌های ژرفاسنجی و اندازه‌گیری‌های میدانی وابسته بوده‌اند که کاربرد آن‌ها را در مخازن فاقد ایستگاه‌های پایش یا مناطق با دسترسی محدود کاهش می‌دهد. همچنین، تلفیق هم‌زمان تصاویر ماهواره‌ای، مدل‌های رقومی ارتفاعی و الگوریتم‌های یادگیری ماشین همراه با تحلیل‌های عدم قطعیت و تحلیل حساسیت برای برآورد مستقیم تراز سطح آب، در قالب یک چارچوب عملیاتی و قابل تکرار، کمتر مورد توجه قرار گرفته است. بر همین اساس، نوآوری پژوهش حاضر در توسعه یک چارچوب یکپارچه مبتنی بر تلفیق تصاویر Sentinel-2، مدل رقومی ارتفاعی و الگوریتم جنگل تصادفی برای برآورد تراز سطح آب مخازن بدون نیاز به داده‌های ژرفاسنجی میدانی است. در این چارچوب، اطلاعات توپوگرافی حاصل از مدل رقومی ارتفاعی با ویژگی‌های استخراج‌شده از تصاویر Sentinel-2 و قابلیت مدل‌سازی غیرخطی الگوریتم جنگل تصادفی تلفیق شده‌اند تا امکان برآورد دقیق تراز سطح آب فراهم شود. هدف این پژوهش، ارائه و ارزیابی یک روش سریع، کم‌هزینه، خودکار و قابل تکرار برای پایش تراز سطح آب مخازن، به‌ویژه مخازن فاقد ایستگاه‌های آب‌سنجی، است. انتظار می‌رود چارچوب پیشنهادی علاوه بر کاهش وابستگی به برداشت‌های میدانی، امکان پایش مستمر و دقیق مخازن را در مقیاس‌های زمانی و مکانی مختلف فراهم کرده و به‌عنوان ابزاری کارآمد در مدیریت منابع آب مورد استفاده قرار گیرد.

مواد و روش

منطقه مورد مطالعه

سد مخزنی جره از نوع خاکی با هسته رسی و رویه بتنی است و در فاصله ۲۰ کیلومتری شمال شرقی رامهرمز و ۱۱۰ کیلومتری شمال شرقی اهواز، نزدیک روستای جره بر روی رودخانه زرد (یکی از سرشاخه‌های رودخانه اله) احداث شده است. این سد با ارتفاع ۹۳ متر از پی، طول تاج ۷۲۰ متر و ضخامت ۱۰ متر در تاج، حجم کلی مخزن ۳۰۷ میلیون متر مکعب را با حجم زنده ۱۹۷ و حجم مرده ۱۱۰ میلیون متر مکعب ایجاد کرده است. سیلاب کنترل شده توسط سد ۸۲ میلیون متر مکعب بوده و عمر مفید آن ۵۰ سال برآورد می‌شود. شبکه آبیاری مرتبط با این سد، زمینی به مساحت خالص ۱۸۰۰۰ هکتار را با تراکم کشت ۱۰۵ درصد پوشش می‌دهد و نیاز آبی آن ۲۵۸ میلیون متر مکعب در سال است (Taghian, 2001). نمایی از موقعیت قرارگیری مخزن سد جره در شکل ۱ ارائه شده است.



شکل ۱- نمایی از موقعیت جغرافیایی مخزن سد جره

Figure 1- A view of the geographic location of Jarreh Reservoir Dam

داده‌های مورد استفاده و متغیرهای ورودی

در این مطالعه از داده‌های روزانه تراز سطح آب مخزن سد جره در بازه زمانی ۱۳۹۴ تا ۱۴۰۵ به عنوان داده‌های مشاهداتی برای آموزش و آزمون مدل‌ها تحت سناریوهای مختلف استفاده شده است. این داده‌ها از سازمان آب و برق خوزستان تهیه شده‌اند و به صورت اندازه‌گیری‌های مستقیم تراز آب مخزن (بر حسب متر نسبت به سطح مبنای دریا) ثبت شده‌اند. با توجه به روزانه بودن سری زمانی تراز آب، هم‌زمان‌سازی داده‌های مشاهداتی با تصاویر Sentinel-2 بر اساس تطبیق مستقیم تاریخ انجام شد و مقدار ثبت‌شده در روز گذر ماهواره به عنوان مقدار متناظر با هر تصویر استفاده شد.

در این پژوهش از مجموعه تصاویر سنتینل-۲ (سنجنده MSI، سطح پردازش Level-2A) استفاده شد که از پایگاه داده Google Earth Engine دریافت شد. این پایگاه داده به دلیل سهولت تجزیه و تحلیل داده‌های بلندمدت و هم‌چنین در دسترس بودن بسیاری از مجموعه داده‌ها مورد استفاده قرار گرفت (Jahani et al., 2024). جهت کاهش تأثیرات جوی در تصاویر سنتینل-۲، از الگوریتم Sen2Cor استفاده می‌شود تا دقت تحلیل‌ها افزایش یابد (Koohani et al., 2025). این تصحیحات به صورت خودکار در سامانه Google Earth Engine صورت می‌پذیرد. از جمله برجسته‌ترین ویژگی‌های ماهواره سنتینل-۲، قدرت تفکیک زمانی بالای آن با دوره بازگشت ۵ روزه است که دسترسی به تصاویر را در فواصل زمانی کوتاه امکان‌پذیر می‌سازد (Rao et al., 2024). سنتینل-۲ به دلیل قدرت تفکیک مکانی مناسب و باندهای طیفی مرتبط با مطالعات منابع آب، کاربرد گسترده‌ای در پایش سطوح آبی دارد (Bhangale et al., 2020).

به منظور شبیه‌سازی تراز سطح آب مخزن، از باندهای B3 (مربوط به طیف سبز با طول موج مرکزی ۵۶۰ نانومتر و قدرت تفکیک ۱۰ متر)، B8 (طیف فروسرخ نزدیک با طول موج ۸۴۲ نانومتر و قدرت تفکیک ۱۰ متر) و B11 (طیف فروسرخ کوتاه با طول موج ۱۶۱۰ نانومتر و قدرت تفکیک ۲۰ متر) استفاده شد. باندهای یادشده از مهم‌ترین باندهای مورد کاربرد برای محاسبه شاخص‌های مرتبط با پهنه‌های آبی محسوب می‌شوند (Yang et al., 2024). تصاویر مورد استفاده مربوط به بازه زمانی ۱۳۹۴ تا ۱۴۰۵ هستند. به منظور کاهش اثر پوشش ابری، تنها تصاویری با درصد ابر کمتر از ۲۰ درصد مورد استفاده قرار گرفتند. پس از کنار گذاشتن تصاویر دارای پوشش ابر بیش از ۲۰ درصد، یک تابع ماسک ابر روی هر تصویر سنتینل-۲ اعمال شد تا پیکسل‌های واقع بر روی سطح مخزن که دارای ابر هستند، حذف شوند. در این مرحله از باند QA60 جهت شناسایی پیکسل‌های ابری استفاده شد. روش‌های مبتنی بر QA60 یکی از متداول‌ترین روش‌های حذف ابر در تصاویر Sentinel-2 محسوب می‌شوند (Corbane et al., 2020). در ادامه، تصاویر ماسک‌شده به سه باند B3، B8 و B11 محدود شدند تا حجم داده‌ها کاهش یابد. از آنجا که محصول سنتینل-۲ در سطح پردازش Level-2A دارای تصحیح اتمسفری است، هیچ گونه تصحیح جوی دیگری روی تصاویر اعمال نشد (Yang et al., 2024).

در این مطالعه، به منظور استخراج مرز آب مخزن سد از عوارض خشکی مجاور در تصاویر سنتینل-۲، از دو شاخص طیف‌سنجی تفاضل نرمال‌شده آب^۱ (NDWI) و تفاضل نرمال‌شده آب اصلاح‌شده^۲ (MNDWI) استفاده شد که براساس رابطه‌های (۱) و (۲) محاسبه می‌شوند. مبنای نظری انتخاب این دو شاخص، تمایز بنیادین آن‌ها در باندهای طیفی به کاررفته و کاربردهای آن در شناسایی عوارض آبی با عمق و بستر متفاوت است. شاخص NDWI علی‌رغم کارایی در پهنه‌های آبی باز و عمیق، در محیط‌های شهری و نواحی کم‌عمق به دلیل هم‌پوشانی طیفی با سطوح مصنوعی، با خطای شناسایی همراه است (Xu., 2007; McFeeters., 1996). در مقابل، شاخص MNDWI با بهره‌گیری از باند SWIR، کنتراست طیفی بین آب و سطوح انسان‌ساخت را افزایش داده و عملکرد مؤثرتری در حذف نویز عوارض شهری ارائه می‌دهد (Xu., 2006; Ali et al., 2019).

$$NDWI = \frac{B3 - B8}{B3 + B8} \quad (۱)$$

$$MNDWI = \frac{B3 - B11}{B3 + B11} \quad (۲)$$

به منظور تفکیک نهایی آب و خشکی، از آستانه‌گذاری^۳ بر روی این شاخص‌ها استفاده شد. مقدار آستانه بر اساس آزمون‌های تجربی و تطابق بصری با تصاویر سنجنده تعیین شد (NDWI > 0.1 و MNDWI > 0). به عنوان کلاس آب در نظر گرفته شد. سپس نتایج به ماسک باینری آب - خشکی (آب = ۱، خشکی = ۰) تبدیل شد. در مرحله بعد، مرز مکانی پهنه آب با استخراج پیکسل‌های مرزی از ماسک باینری به دست آمد. این پیکسل‌ها شامل سلول‌هایی هستند که در مجاورت هر دو کلاس آب و خشکی قرار دارند و به عنوان خط مرزی مخزن در هر تاریخ زمانی تعریف شدند. برای تبدیل مرز دوبعدی به تراز ارتفاعی، لایه مرزی استخراج‌شده بر روی مدل رقومی ارتفاع ALOS

^۱ Normalized Difference Water Index (NDWI)


^۲ Modified Normalized Difference Water Index (MNDWI)

^۳ thresholding

PALSAR (DEM) اعمال شد و مقادیر ارتفاعی متناظر با پیکسل‌های مرزی استخراج شد. به‌منظور کاهش اثر نویز پیکسلی و خطاهای ناشی از ناهموازی‌های محلی، از میانه مقادیر ارتفاعی در طول مرز به‌عنوان نماینده تراز سطح آب در هر تاریخ استفاده شد. این فرآیند برای تمام تصاویر زمانی تکرار شد و سری زمانی تراز سطح آب مخزن تولید شد. همچنین مساحت سطح آب نیز از جمع مساحت پیکسل‌های آب برآورد شد. در نهایت، متغیرهای استخراج‌شده شامل تراز آب، شاخص NDWI، شاخص MNDWI و مساحت سطح آب برای کلیه تصاویر سنتینل-۲ پالایش شده در سامانه Google Earth Engine تهیه شد. در مرحله پیش‌پردازش داده‌های استخراج‌شده، رکوردهای ناقص حذف و مقادیر متنی به عددی تبدیل شدند.

مدل رقومی ارتفاع

به‌منظور استخراج ارتفاع سطح آب مخزن، از مدل رقومی ارتفاعی حاصل از ماهواره ALOS و سنسور PALSAR (ALOS-PALSAR DEM)^۱ استفاده شد. این مدل رقومی یک محصول توپوگرافی جهانی با قدرت تفکیک مکانی حدود ۱۲/۵ متر است که توسط سازمان فضایی ژاپن (JAXA) تولید شده است. این مدل رقومی ارتفاعی بر اساس داده‌های راداری باند L (با طول موج بلند) تهیه شده که قابلیت نفوذ از میان پوشش گیاهی و ثبت ارتفاع زمین را دارد. نمونه‌ای از تصویر ماهواره سنتینل-۲ مخزن سد جره به همراه مدل رقومی ارتفاعی ALOS-PALSAR در شکل ۲ ارائه شده است.



شکل ۲- تصویر ماهواره‌ای سنتینل-۲ (a) و مدل رقومی ارتفاع ALOS-PALSAR (b) مخزن سد جره

Figure 2- Sentinel-2 satellite image (a) and ALOS-PALSAR digital elevation model (b) of Jarreh Dam Reservoir

مدل رگرسیون جنگل تصادفی

الگوریتم جنگل تصادفی که توسط Breiman (2001) معرفی شد، مبتنی بر مجموعه‌ای از درخت‌های تصمیم است که برای مسائل رگرسیون و طبقه‌بندی به کار می‌رود. در این روش، هر درخت به‌صورت مستقل بر روی یک نمونه بوت‌استرپ از داده‌های آموزشی ساخته می‌شود و در هر گره، زیرمجموعه‌ای تصادفی از متغیرهای ورودی برای یافتن بهترین تقسیم مورد بررسی قرار می‌گیرد. خروجی نهایی مدل در مسائل رگرسیون از میانگین‌گیری پیش‌بینی تمامی درخت‌ها حاصل می‌شود، که این امر موجب کاهش واریانس و بهبود پایداری مدل می‌شود (Ahmadi et al., 2023).

در این مطالعه، مدل جنگل تصادفی در محیط Google Earth Engine پیاده‌سازی شد. در فرآیند ساخت هر درخت، در هر گره تنها سه متغیر ورودی به‌صورت تصادفی انتخاب و بهترین تقسیم بر اساس آن‌ها تعیین شد. حداقل تعداد نمونه در هر گره انتهای برابر با ۳ در نظر گرفته شد و مدل با ۱۵۰ درخت تصمیم و نمونه‌گیری بوت‌استرپ^۲ از داده‌های آموزشی ایجاد شد.

در این مطالعه، به‌منظور بررسی تأثیرپذیری سیستم هیدرولوژیکی از داده‌های گذشته، متغیرهای تأخیری (۵ روز و ۱۰ روز قبل) از داده‌های واقعی تراز سطح آب مخزن ایجاد شدند. این متغیرها از طریق مقایسه و همسان‌سازی زمانی بر مبنای تاریخ دقیق هر تصویر، به مجموعه

^۱ Advanced Land Observing Satellite-Phased Array type L-band Synthetic Aperture Radar

^۲ sampling with replacement

داده افزوده شدند. سه سناریوی متفاوت جهت بررسی تاثیر متغیرهای تأخیری بر روی عملکرد مدل جنگل تصادفی تعریف شد. در سناریوی اول تنها از داده‌های سنجش از دور (تراز آب، شاخص NDWI، شاخص MNDWI و مساحت سطح آب) استفاده شد. در سناریو دوم علاوه بر داده‌های ماهواره‌ای، از تراز آب ۵ روز قبل و در سناریو سوم علاوه بر تراز آب ۵ روز قبل، تراز آب ۱۰ روز قبل نیز به متغیرهای ورودی اضافه شد. برای جلوگیری از اثر مقیاس‌های متفاوت متغیرهای ورودی، تمامی متغیرها با استفاده از استانداردسازی Z-Score نرمال‌سازی شدند. لازم به تأکید است که محاسبه میانگین و انحراف معیار صرفاً بر اساس مجموعه آموزش انجام شد و سپس همان پارامترهای به‌دست آمده برای نرمال‌سازی مجموعه آزمون نیز به کار گرفته شد. این رویکرد از ورود اطلاعات مجموعه آزمون به فرآیند آموزش و در نتیجه بروز نشت داده جلوگیری می‌کند. با توجه به ماهیت سری‌زمانی داده‌ها، کل بازه زمانی مطالعه به دو بخش شامل ۸۰ درصد ابتدایی (مرداد ۱۳۹۴ تا آبان ۱۴۰۳) به‌عنوان مجموعه آموزش و ۲۰ درصد انتهایی (آذر ۱۴۰۳ تا اردیبهشت ۱۴۰۵) به‌عنوان مجموعه آزمون تقسیم شد تا از نشت اطلاعات آینده جلوگیری شود. در این چارچوب، هیچ‌گونه هم‌پوشانی زمانی بین داده‌های آموزش و آزمون وجود نداشت.

تخمین عدم قطعیت

به‌منظور کمی‌سازی عدم قطعیت پیش‌بینی‌ها، از برآورد خطای برون کیسه‌ای^۱ (OOB) که به‌طور درونی در الگوریتم جنگل تصادفی محاسبه می‌شود، استفاده شد. در پیاده‌سازی انجام‌شده در محیط Google Earth Engine، بخشی از داده‌های آموزشی که در ساخت هر درخت انتخاب نشدند، به‌عنوان نمونه‌های برون کیسه‌ای در نظر گرفته شدند. سپس این نمونه‌ها توسط درخت‌هایی که در آموزش آن‌ها نقشی نداشتند پیش‌بینی شدند و اختلاف بین مقادیر مشاهده‌شده و پیش‌بینی‌شده، مبنای محاسبه خطای OOB قرار گرفت. پس از آموزش مدل، مقدار OOB Mean Squared Error از خروجی مدل استخراج و ریشه آن به‌عنوان $RMSE_{OOB}$ محاسبه شد. این شاخص به‌عنوان برآوردی از پراکندگی خطاهای پیش‌بینی و عدم قطعیت کلی مدل در نظر گرفته شد، زیرا بدون نیاز به مجموعه اعتبارسنجی مستقل، برآوردی تقریباً ناریب از خطای تعمیم‌پذیری مدل ارائه می‌کند (Rajanala et al., 2022).

سپس با فرض نرمال بودن توزیع خطاهای پیش‌بینی، برای هر مقدار برآوردشده تراز سطح آب مخزن، بازه‌های اطمینان ۶۸، ۹۰ و ۹۵ درصد مطابق رابطه زیر محاسبه شد:

$$CI_i = \hat{y}_i \pm Z_{\alpha/2} \times RMSE_{OOB} \quad (3)$$

که در آن، CI_i بازه اطمینان پیش‌بینی برای مشاهده i ، $\hat{y}_i$ مقدار پیش‌بینی‌شده توسط مدل، $Z_{\alpha/2}$ ضریب متناظر با سطح اطمینان موردنظر (برای سطوح ۶۸، ۹۰ و ۹۵ درصد به‌ترتیب برابر با ۱، ۱/۶۴۵ و ۱/۹۶) و $RMSE_{OOB}$ ریشه میانگین مربعات خطای برون کیسه‌ای است.

تحلیل حساسیت

اهمیت جایگشت^۲ به‌عنوان روشی مستقل از نوع مدل داده‌کاوی، با اندازه‌گیری افزایش خطای پیش‌بینی پس از برهم‌زدن تصادفی مقادیر هر متغیر ورودی در مجموعه صحت‌سنجی محاسبه شد. ابتدا خطای مبنای خروجی مدل آموزش‌دیده به‌دست آمد و سپس هر متغیر به‌صورت جداگانه جایگشت داده شد؛ افزایش خطا نسبت به حالت مبنای به‌عنوان شاخص اهمیت آن متغیر در نظر گرفته شد. این روش بدون نیاز به آموزش مجدد مدل، نقش نسبی ویژگی‌ها را ارزیابی کرده و اثر هر ورودی را به‌صورت مستقل بررسی می‌کند. با وجود حساسیت به همبستگی بین متغیرها و اندازه نمونه، این روش به دلیل سادگی و تفسیرپذیری بالا کاربرد گسترده‌ای دارد (Föge and Pauly, 2026).

ارزیابی عملکرد مدل

جهت برآورد میزان کارایی مدل‌های مختلف، در این تحقیق از معیارهای آماری از قبیل ضریب تعیین^۳ (R^2)، خطای جذر میانگین مربعات^۴ (RMSE) و ضریب ناش-ساتکلیف^۵ (NSE) استفاده شده است. معادلات مربوط به معیارهای آماری مورد استفاده به‌صورت زیر است:

$$R^2 = \left(\frac{\sum (Wl_{me} - \overline{Wl_{me}})(Wl_{es} - \overline{Wl_{es}})}{\sqrt{\sum (Wl_{me} - \overline{Wl_{me}})^2} \sqrt{\sum (Wl_{es} - \overline{Wl_{es}})^2}} \right)^2 \quad (4)$$

^۱ Out-of-Bag

^۲ Permutation importance

^۳ Coefficients of determination

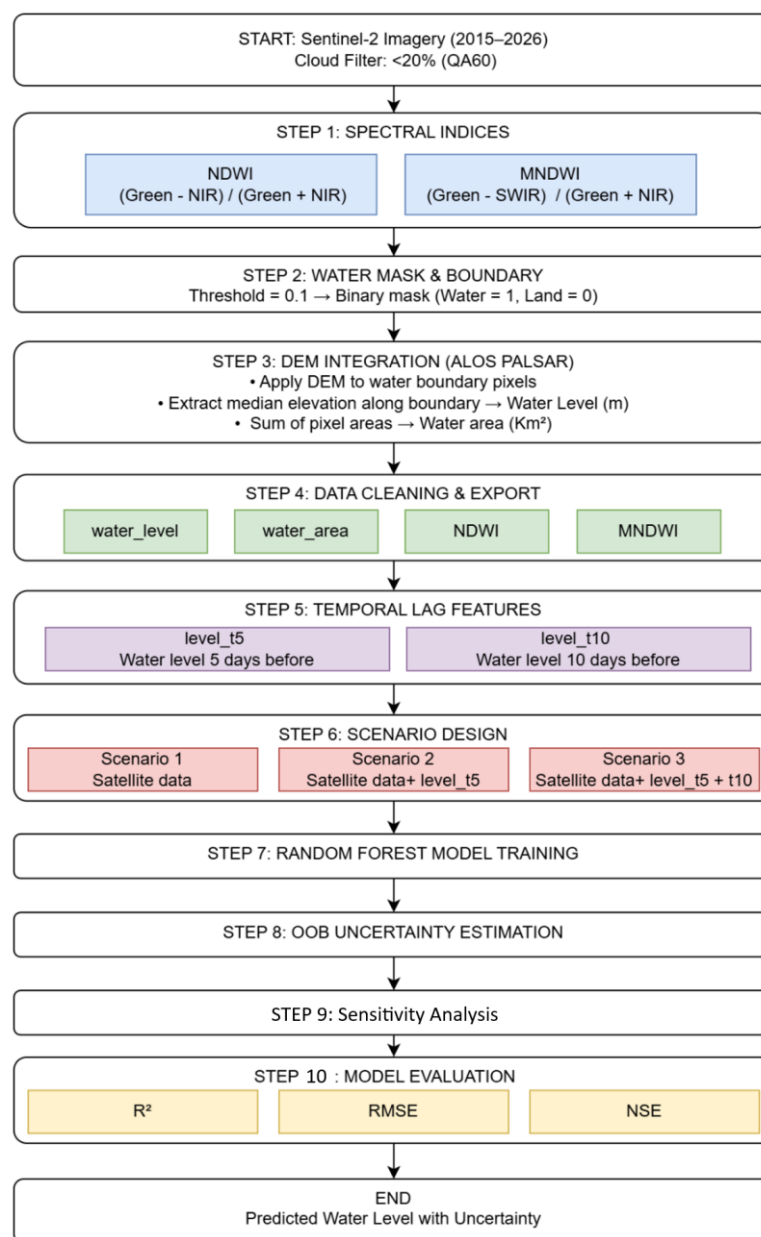
^۴ Root mean squared error

^۵ Nash-Sutcliffe efficiency

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Wl_{me} - Wl_{es})^2}{N}} \quad (5)$$

$$NSE = 1 - \frac{\sum (Wl_{me} - Wl_{es})^2}{\sum (Wl_{me} - \overline{Wl_{me}})^2} \quad (6)$$

در معادلات فوق Wl_{es} و Wl_{me} به ترتیب مقادیر تراز مخزن اندازه‌گیری شده و محاسبه شده، $\overline{Wl_{es}}$ و $\overline{Wl_{me}}$ به ترتیب میانگین تراز مخزن اندازه‌گیری شده و محاسبه شده و N تعداد نمونه‌های اندازه‌گیری است. RMSE هم بعد با مقادیر ورودی بوده و مقادیر کوچک‌تر آن نشان‌دهنده خطای کمتر مدل است. هر چه ضریب R^2 به یک نزدیک‌تر باشد، نشان‌دهنده تطابق بهتر بین نتایج مدل و مقادیر مشاهداتی است. NSE یک معیار نرمال شده است که نشان‌دهنده بزرگی نسبی واریانس باقیمانده در مقایسه با واریانس داده‌های مشاهده شده است. بر اساس مطالعات صورت گرفته $NSE > 0.7$ نشان‌دهنده خوب بودن نتایج بوده، $0.4 < NSE \leq 0.7$ نشان‌دهنده رضایت‌بخش بودن نتایج و مقادیر $NSE \leq 0.4$ بیان‌گر ضعیف بودن مدل‌سازی است (Zahiri et al., 2020). نمودار جریانی مربوط به مطالعه صورت گرفته در شکل ۳ ارائه شده است.




شکل ۳- نمودار جریانی روش استخراج تراز آب مخزن سد جره با استفاده از شاخص‌های طیفی و مدل جنگل تصادفی

Figure 3- Flowchart of the water level extraction method for Jarreh Dam reservoir using spectral indices and Random Forest model

نتایج و بحث

به کارگیری همزمان تصاویر Sentinel-2 و داده‌های ALOS DEM امکان استخراج مرز آب و تحلیل توپوگرافی مخزن را فراهم نمود. مقایسه نتایج حاصل از شاخص‌های NDWI و MNDWI نشان داد که اگرچه هر دو شاخص دارای رزولوشن مکانی یکسان بوده و تابع باندهای سنجنده Sentinel-2 هستند، اما در این مطالعه NDWI توانایی بهتری در نمایش پیوستگی و وضوح مرز آب - خشکی نسبت به MNDWI نشان داد. در نتیجه، مرز استخراج شده بر اساس NDWI دارای لبه‌های واضح‌تر در محدوده مخزن بوده و برای استخراج خط ساحلی مورد استفاده قرار گرفت (شکل ۴). این یافته‌ها با نتایج مطالعه Zou et al. (2018) همخوانی دارد که نشان می‌دهد شاخص NDWI در مقایسه با MNDWI کارایی بهتری در تفکیک پهنه آبی مخازن سدهای بزرگ دارد. به‌طور مشابه، مطالعه‌ای که بر روی سه دریاچه حدیثه، ثرثار و رزازه در عراق انجام شده است، کارایی شاخص NDWI در پایش تغییرات سطح آب با استفاده از تصاویر لندست و سنتینل-۲ را تأیید می‌کند (Mahmood et al., 2025). اگرچه هدف پژوهش مذکور برآورد تغییرات مساحت سطح آب بوده و با هدف مطالعه حاضر که برآورد تراز آب مخزن سد است، تفاوت اساسی دارد، اما هر دو مطالعه نشان می‌دهند که فناوری‌های سنجش از دور و شاخص‌های طیفی نظیر NDWI ابزاری کارآمد، کم‌هزینه و قابل دسترس برای پایش منابع آب در مناطق خشک و نیمه‌خشک محسوب می‌شوند.




شکل ۴- شاخص MNDWI (a) و شاخص NDWI (b) مخزن سد جره در تاریخ ۱۴۰۴/۱۲/۲۴
Figure 4- MNDWI index (a) and NDWI index (b) of Jarreh Dam Reservoir on March 15, 2026

نتایج مدل جنگل تصادفی برای سه سناریوی مورد استفاده در شکل ۵ ارائه شده است. در سناریو اول، مدل جنگل تصادفی تنها بر اساس ویژگی‌های استخراج شده از داده‌های ماهواره‌ای شامل تراز سطح آب مخزن، مساحت مخزن، شاخص‌های NDWI و MNDWI آموزش دیده است. نتایج شکل ۵ (a) نشان می‌دهد که در محدوده ترازهای پایین (حدود ۴۷۰ تا ۴۷۵ متر) مدل تمایل به بیش‌برآوردی^۱ دارد. این امر ممکن است ناشی از آن باشد که در شرایط کم‌آبی، انعکاس سیگنال ماهواره‌ای از سطح آب ضعیف‌تر شده و احتمالاً تحت تأثیر پدیده‌هایی مانند خیس بودن خاک حاشیه، پوشش گیاهی کم‌ارتفاع یا امواج سطحی قرار می‌گیرد. مدل جنگل تصادفی این بازتاب‌های مخدوش را به‌عنوان تراز بالاتر تفسیر می‌کند، زیرا در داده‌های آموزشی خود الگوی متناظری با این وضعیت به اندازه کافی ندیده است. در محدوده ترازهای بالا (حدود ۴۹۰ تا ۴۹۵ متر)، مدل نوسانات و پرش‌های کوچک موضعی^۲ را نشان می‌دهد. علت این رفتار این است که در سطوح سیلابی و پرآبی، تغییرات تراز بسیار سریع رخ می‌دهد. بدون وجود داده اندازه‌گیری شده زمینی که روند واقعی را تأیید کند، مدل جنگل تصادفی به تغییرات جزئی در ورودی‌های ماهواره‌ای (که ممکن است ناشی از ابر، زاویه دید ماهواره یا تلاطم سطح آب باشد) حساسیت بیش از حد نشان داده و دچار نوسان می‌شود. الگوی خطای مشاهده شده در این مطالعه نشان می‌دهد که کاهش دقت مدل در ترازهای حداقل و حداکثر مخزن، صرفاً ناشی از نوسانات تصادفی نیست، بلکه بیانگر محدودیت مدل در بازنمایی شرایط حدی سامانه‌های هیدرولوژیکی است. این رفتار در بسیاری از مدل‌های داده‌محور مشاهده شده است؛ به‌طوری‌که این مدل‌ها معمولاً در محدوده میانی دامنه داده‌ها از دقت بالاتری برخوردارند، اما با نزدیک شدن به مقادیر حدی،

¹ Overestimation

² Local fluctuations

به دلیل پیچیدگی بیش‌تر فرآیندهای هیدرولوژیکی و محدود بودن نمونه‌های آموزشی، عملکرد آن‌ها کاهش می‌یابد. اگرچه اغلب مطالعات موجود در این زمینه بر پیش‌بینی دبی رودخانه و رخداد‌های سیلابی متمرکز بوده‌اند، اما الگوی کاهش دقت مدل‌ها در شرایط حدی، یک ویژگی مشترک در مدل‌سازی سامانه‌های هیدرولوژیکی است. به عنوان نمونه، Zhang et al. (2026) با مقایسه هفت مدل یادگیری ماشین در حوضه Boluo واقع در جنوب چین و با تمرکز بر پیش‌بینی جریان سیلاب، نشان دادند که اگرچه مدل LSTM بهترین عملکرد کلی را ارائه می‌دهد، اما با افزایش شدت جریان، دقت آن به‌طور محسوسی کاهش یافته و مقدار ضریب کارایی برای دبی‌های بالاتر از صدک‌های ۹۰، ۹۵ و ۹۹ به‌ترتیب به ۰/۸۶، ۰/۸۰ و ۰/۴۵ تنزل می‌یابد. هم‌چنین، Guo et al. (2024) با ارزیابی عملکرد ۲۳ مدل هیدرولوژیکی بزرگ‌مقیاس در ۶۳۳ حوضه جهان گزارش کردند که این مدل‌ها در شرایط حدی دارای خطای سیستماتیک هستند؛ به‌گونه‌ای که دبی‌های بالا را بین ۱۵ تا ۷۰ درصد بیش‌برآورد و دبی‌های پایین را بین ۲۰ تا ۸۰ درصد کم‌برآورد می‌کنند.



شکل ۵- نتایج مدل جنگل تصادفی سناریو اول (a)، سناریو دوم (b)، سناریو سوم (c)

Figure 5- Results of the Random Forest model for Scenario 1 (a), Scenario 2 (b), Scenario 3 (c)

در سناریو دوم علاوه بر داده‌های ماهواره‌ای، از تراز اندازه‌گیری شده با تأخیر ۵ روزه استفاده شده است (شکل ۵ (b)). در این سناریو، در محدوده ترازهای پایین، بیش‌برآوردی نسبت به سناریو اول کاهش یافته است. دلیل آن این است که داده اندازه‌گیری شده با تأخیر ۵ روزه، شرایط واقعی تراز سطح آب در ۵ روز گذشته را در اختیار مدل قرار می‌دهد. این اطلاعات زمینه‌ای باعث می‌شود مدل پیش‌بینی واقع‌بینانه‌تری ارائه دهد. علاوه بر این، در محدوده ترازهای بالا، نوسانات کوچک کاهش یافته است. داده‌های واقعی با تأخیر ۵ روزه روند کلی صعودی یا نزولی را در اختیار مدل قرار می‌دهد، اما برای حذف کامل پرش‌های لحظه‌ای کافی نیست، زیرا در شرایط سیلابی، تراز می‌تواند ظرف کم‌تر از ۵ روز تغییرات شدید داشته باشد و مدل همچنان برای تطبیق با این تغییرات سریع کمی دچار تأخیر می‌شود.

در سناریو سوم علاوه بر داده‌های ماهواره‌ای از تراز آب اندازه‌گیری شده با تأخیر ۵ و ۱۰ روزه استفاده شده است (شکل ۵ (c)). رفتار کلی مدل در این سناریو شباهت زیادی به سناریو دوم دارد، هرچند در این سناریو، پرش‌های موجود در محدوده ترازهای بالا در مقایسه با سناریو دوم اندکی کاهش یافته است. دلیل آن این است که با داشتن دو تأخیر زمانی، مدل نرخ تغییر تراز را نیز تشخیص می‌دهد. این اطلاعات به مدل کمک می‌کند تا تغییرات شدید ناگهانی ناشی از نویز ماهواره‌ای را از تغییرات واقعی سریع ناشی از سیلاب تفکیک کند.

نتایج تحلیل‌های آماری صورت گرفته در جدول ۱ ارائه شده است. مقدار RMSE در سناریو اول، مجموعه آزمون برابر $1/33$ متر است که نسبت به دو سناریوی دیگر بالاتر بوده و نشان‌دهنده خطای بیش‌بینی بیشتر است. ضریب تعیین (R^2) و ضریب نش-ساتکلیف (NSE) بیانگر عملکرد مطلوب مدل است که می‌تواند برای کاربردهای عملی مانند هشدار سیل یا مدیریت منابع آب مناسب باشد. افزایش ۳۲ درصدی RMSE در داده‌های آزمون، حاکی از وجود بیش‌برازش خفیف در مدل است. اضافه کردن تراز اندازه‌گیری شده با تأخیر ۵ روزه به ورودی‌های مدل باعث بهبود در تمام شاخص‌های آماری شده است به گونه‌ای که مقدار RMSE در مجموعه آزمون به $0/74$ متر کاهش یافته که نسبت به سناریوی اول حدود ۴۴ درصد بهبود را نشان می‌دهد. ضریب نش-ساتکلیف مجموعه آزمون به $0/92$ رسیده است که بیانگر آن است که مدل تقریباً تمام واریانس داده‌ها را توضیح می‌دهد. تفاوت RMSE از آموزش به آزمون تنها $0/25$ متر است که میزان بیش‌برازش کمی را نشان می‌دهد. این نتایج ثابت می‌کند که مدل جنگل تصادفی با تنها یک ویژگی تأخیری، توانسته است خطای بیش‌بینی را به میزان قابل قبولی کاهش داده و عملکردی پایدار و تعمیم‌پذیر ارائه دهد. مقایسه سناریوهای دوم و سوم نشان می‌دهد که افزودن تأخیر ۱۰ روزه تأثیر چشمگیری بر عملکرد مدل ندارد؛ با این حال، افزایش تعداد متغیرهای ورودی می‌تواند منجر به کاهش قدرت تعمیم‌دهی مدل جنگل تصادفی شود. همچنین، مقایسه RMSE در این دو سناریو حاکی از آن است که در سناریوی سوم، افزایش متغیرهای ورودی موجب بروز بیش‌برازش بیش‌تری شده است.

جدول ۱- تحلیل آماری نتایج حاصل از جنگل تصادفی جهت تخمین تراز سطح آب مخزن سد جره

Table 1- Statistical analysis of Random Forest results for estimating Jarreh Dam reservoir water level

Scenario	Train			Test			All data		
	R^2	RMSE (m)	NSE	R^2	RMSE (m)	NSE	R^2	RMSE (m)	NSE
Scenario 1	0.98	1.01	0.97	0.83	1.33	0.80	0.95	1.07	0.94
Scenario 2	0.99	0.49	0.99	0.93	0.74	0.92	0.98	0.54	0.98
Scenario 3	0.99	0.45	0.99	0.93	0.76	0.92	0.98	0.51	0.98
Persistence	-	-	-	0.93	0.75	0.92	-	-	-

به‌منظور ارزیابی ارزش افزوده مدل جنگل تصادفی، عملکرد آن با رویکرد ساده‌تر مبتنی بر تداوم (Persistence) مقایسه شد. در این مدل، مقدار تراز سطح آب در هر تاریخ برابر با مقدار مشاهده شده در پنج روز قبل فرض شد؛ زیرا در سناریوهای دوم و سوم، نزدیک‌ترین اطلاعات زمانی در دسترس نیز مربوط به پنج روز قبل بود. نتایج نشان داد که مدل Persistence دارای RMSE برابر $0/75$ متر است، درحالی‌که مدل جنگل تصادفی در سناریوهای دوم و سوم به‌ترتیب RMSE برابر با $0/74$ و $0/76$ متر در مرحله آزمون را به دست آورد. مقایسه این نتایج نشان می‌دهد که افزودن متغیرهای تأخیری به مدل جنگل تصادفی، در مقایسه با مدل پایه Persistence، بهبود قابل‌توجهی در دقت پیش‌بینی ایجاد نکرده است. این موضوع بیانگر آن است که با وجود افزایش پیچیدگی مدل و استفاده از اطلاعات زمانی، عملکرد پیش‌بینی تقریباً در همان سطح مدل پایه باقی مانده است. با این حال، هدف اصلی این پژوهش توسعه مدلی برای برآورد تراز سطح آب مخازن در شرایط فاقد داده‌های ترازسنجی بوده است؛ از این‌رو، سناریوی اول که صرفاً بر پایه متغیرهای استخراج‌شده از تصاویر ماهواره‌ای توسعه یافته

است، به‌عنوان سناریوی اصلی پژوهش در نظر گرفته می‌شود. سناریوهای دوم و سوم صرفاً به‌منظور بررسی تأثیر ورود اطلاعات زمانی تراز سطح آب (تاخیرهای ۵ و ۱۰ روزه) بر عملکرد مدل و تحلیل نقش حافظه هیدرولوژیکی مخزن طراحی شده‌اند و هدف آن‌ها ارائه یک مدل عملیاتی برای کاربرد در مخازن فاقد ایستگاه اندازه‌گیری نبوده است.

(Amer et al., 2025) از مدل جنگل تصادفی برای برآورد تراز سد Beni Haroun در الجزایر با استفاده از تراز سطح آب محاسباتی استفاده کردند. در آن پژوهش، مقادیر RMSE برای مراحل آموزش و آزمون به‌ترتیب ۱/۹۵ و ۵/۱۶ متر گزارش شده است. مقایسه سناریوی اول مطالعه حاضر که تنها از داده‌های ماهواره‌ای جهت برآورد تراز سطح مخزن سد جره استفاده شده است، با مطالعه (Amer et al., 2025) نشان می‌دهد که مدل پیشنهادی چه در مرحله آموزش و چه در مرحله آزمون از دقت بالاتری برخوردار است. علاوه‌براین اختلاف بین خطای آموزش و آزمون در مطالعه حاضر (۰/۳۲ متر) کمتر از مطالعه اشاره شده با اختلاف ۳/۲۱ متر است که نشان‌دهنده تعمیم‌پذیری بهتر و پایداری بیش‌تر مدل توسعه‌یافته در این پژوهش است. در مقایسه با پژوهش (Sagawa et al., 2019) که با استفاده از مدل‌های یادگیری ماشین و ۱۳۵ تصویر لندست-۸ برای تخمین عمق آب‌های کم‌عمق (۰ تا ۲۰ متر) در پنج منطقه آزمایشی به RMSE برابر ۱/۴۱ متر دست یافتند، نتایج مطالعه حاضر از دقت قابل قبولی برخوردار است. لازم به ذکر است که (Sagawa et al., 2019) از داده‌های ژرفاسنجی دقیق و پرتراکم به‌عنوان داده‌های مرجع برای آموزش و اعتبارسنجی مدل خود استفاده کردند، درحالی‌که در مطالعه حاضر به‌دلیل محدودیت دسترسی به داده‌های توپوگرافی، از مدل رقومی ارتفاعی ALOS برای استخراج تراز لبه آب استفاده شد. با توجه به این تفاوت اساسی در کیفیت داده‌های مرجع، دستیابی به RMSE حدود ۱/۰۷ متر در مطالعه حاضر عملکردی بسیار رضایت‌بخش محسوب می‌شود و نشان‌دهنده کارایی رویکرد ارائه‌شده حتی در شرایط دسترسی محدود به داده‌های میدانی دقیق است. البته باید توجه داشت در مطالعه حاضر از داده‌های سنتینل-۲ استفاده شده است که در مقایسه با داده‌های لندست-۸ از قدرت تفکیک مکانی بالاتری برخوردار هستند که همین مسئله در دقت بالای مدل حاضر موثر بوده است. مقایسه آماری نتایج پژوهش حاضر با مطالعه (Codjia et al., 2025) که بر روی ۲۰ مخزن در بورکینافاسو با استفاده از الگوریتم جنگل تصادفی و تصاویر سنتینل-۲ انجام شده است، نشان‌دهنده عملکرد رقابتی مدل توسعه یافته است. در مطالعه مذکور NRMSE معادل ۳/۵۳ درصد گزارش شده است درحالی‌که در پژوهش حاضر، مقدار NRMSE برابر ۴/۱۵ درصد محاسبه شد که اگرچه ۰/۶۲ درصد بالاتر از مطالعه مورد اشاره است، اما هر دو مقدار در محدوده عالی (زیر ۵ درصد) قرار داشته و نشان‌دهنده دقت قابل قبول هر دو رویکرد است. تفاوت اساسی دو مطالعه در آن است که (Codjia et al., 2025) رابطه خطی بین مساحت سطح آب به‌دست آمده از تصاویر ماهواره‌ای و تراز سطح آب با توجه به داده‌های میدانی را برقرار نموده است، درحالی‌که پژوهش حاضر، از مدل رقومی ارتفاعی ALOS برای استخراج مستقیم تراز آب از روی توپوگرافی بستر بهره گرفته است.

ارزیابی عدم قطعیت

ارزیابی تخمین‌های عدم قطعیت حاصل از خطای OOB برای سناریوهای مختلف در جدول ۲ ارائه شده است. خطای OOB برای تعریف بازه پیش‌بینی براساس رابطه (۳) به کار رفت که در آن مقدار $Z_{\alpha/2}$ بر اساس سطح اطمینان موردنظر تعیین شد. اعتبارسنجی بازه‌های عدم قطعیت با اعمال این بازه‌ها بر مجموعه آزمون مستقل و محاسبه درصد مشاهدات واقعی قرارگرفته در داخل بازه پیش‌بینی^۱ انجام شد. همچنین، به‌منظور بررسی تعمیم‌پذیری مدل، مقدار پوشش برای مجموعه آموزش نیز گزارش شده است. سناریوی اول با $RMSE_{OOB}$ برابر ۱/۰۲ متر، بیش‌ترین خطای پیش‌بینی و پهن‌ترین بازه اطمینان ۹۰ درصدی (۱/۶۵ متر) را نشان داد. با این وجود، پوشش مشاهده‌شده در مجموعه آزمون برابر ۹۱ درصد بود که تطابق مناسبی با سطح اطمینان هدف (۹۰ درصد) دارد و بیانگر اعتبار مناسب بازه‌های پیش‌بینی است. در سناریوهای دوم و سوم، $RMSE_{OOB}$ به ۰/۸۵ متر کاهش یافت و نسبت خطا به میانگین متغیر هدف از ۰/۲۲ به ۰/۱۸ رسید. هم‌زمان، پهنای بازه اطمینان ۹۰ درصدی به ۱/۴۰ متر کاهش یافت که بیانگر کاهش حدود ۱۵ درصدی عدم قطعیت پیش‌بینی نسبت به سناریوی اول است. علاوه‌براین، پوشش بازه اطمینان در مجموعه آزمون به ۹۳ درصد رسید که اختلاف اندکی با سطح اطمینان اسمی (۹۰ درصد) دارد و نشان می‌دهد بازه‌های عدم قطعیت برآوردشده از قابلیت پوشش مناسبی برای مقادیر واقعی برخوردار هستند. این نتایج نشان می‌دهد که استفاده از داده‌های زمینی با تأخیر زمانی، علاوه‌بر کاهش خطای پیش‌بینی، موجب کاهش پهنای بازه‌های عدم قطعیت همراه با حفظ پوشش مناسب شده است.

¹ Coverage

جدول ۲- تحلیل آماری نتایج حاصل از جنگل تصادفی جهت تخمین تراز سطح آب مخزن سد جره

Table 2- Statistical analysis of Random Forest results for estimating water level at Jarreh Dam reservoir

Scenario	Bandwidth (m)			OOB Coverage (%)		OOB RMSE (m)	OOB RMSE as % of mean target
	68%	90%	95%	Train	Test		
Scenario 1	1.01	1.65	1.98	94	91	1.02	0.22
Scenario 2	0.85	1.40	1.67	99	93	0.85	0.18
Scenario 3	0.85	1.40	1.67	99	93	0.85	0.18

تحلیل حساسیت بر اساس روش اهمیت جایگشتی

اهمیت جایگشتی متغیرهای ورودی بر اساس نتایج مدل و با استفاده از شش ویژگی مؤثر در برآورد تراز سطح آب مخزن سد جره محاسبه شد. در این رویکرد، اهمیت هر متغیر بر مبنای افزایش خطای RMSE در مجموعه صحت‌سنجی پس از جایگشت تصادفی مقادیر آن متغیر و نرمال‌سازی به‌صورت نسبت سهم از کل افزایش خطا تعیین شد (جدول ۳). بر اساس نتایج، بیش‌ترین سهم مربوط به تراز سطح آب با تأخیر زمانی ۵ روزه بوده است، که نشان‌دهنده وابستگی قوی مدل به پویایی زمانی سطح آب مخزن است. پس از آن، تراز سطح آب با تأخیر ۱۰ روزه و تراز سطح آب استخراج‌شده از تصاویر ماهواره‌ای در رتبه‌های بعدی قرار دارند. مساحت مخزن اثر متوسطی بر خروجی مدل نشان داده است، درحالی‌که شاخص‌های NDWI و MNDWI کم‌ترین سهم را در بهبود عملکرد مدل داشته‌اند. این نتایج بیانگر آن است که رفتار سری زمانی تراز آب نقش غالبی در پیش‌بینی دارد، به‌طوری‌که متغیرهای با تأخیر زمانی نسبت به شاخص‌های طیفی تأثیر بیش‌تری بر عملکرد مدل دارند. همچنین با توجه به سهم پایین NDWI و MNDWI، می‌توان از این متغیرها در راستای ساده‌سازی ساختار مدل صرف‌نظر نمود، هرچند این شاخص‌ها در مراحل اولیه استخراج پهنه آبی و برآورد تراز مخزن نقش زیرساختی دارند.

جدول ۳- نتایج تحلیل حساسیت بر اساس روش اهمیت جایگشتی بر روی پارامترهای ورودی مدل جنگل تصادفی

Table 3- Permutation importance sensitivity analysis results for Random Forest input parameters

Input parameters	Extracted Water Level	Water Level (5-day Lag)	Water Level (10-day Lag)	Reservoir Surface Area	NDWI	MNDWI
Proportion of Total Δ RMSE (%)	16.3	43.2	18.3	11.0	6.0	5.2

نتیجه‌گیری

این پژوهش با هدف برآورد تراز آب مخزن سد جره با استفاده از تلفیق داده‌های سنجنش از دور (Sentinel-2)، مدل رقومی ارتفاعی ALOS و الگوریتم یادگیری ماشین جنگل تصادفی انجام شد. یافته‌های اصلی نشان داد که ترکیب داده‌های طیفی و توپوگرافی امکان استخراج دقیق مرز آب - خشکی و پایش تغییرات مکانی مخزن را فراهم می‌کند. در میان شاخص‌های طیفی، NDWI عملکرد بهتری نسبت به MNDWI در تفکیک پهنه‌های آبی، به‌ویژه در نواحی کم‌عمق و حاشیه‌ای مخزن، نشان داد. از منظر تحلیل سناریوها، سناریوی اول امکان برآورد تراز سطح آب مخزن تنها بر اساس داده‌های سنجنش از دور و بدون استفاده از داده‌های میدانی را فراهم می‌کند و بنابراین از نظر کاربردی برای مناطق فاقد ایستگاه اندازه‌گیری از اهمیت ویژه‌ای برخوردار است. در مقابل، سناریوهای دوم و سوم که شامل متغیرهای تأخیری هستند، اگرچه موجب بهبود دقت شدند، اما از نظر عملکرد تفاوت قابل توجهی با رویکرد ساده‌تر مبتنی بر تداوم نشان ندادند، که بیانگر محدودیت ارزش افزوده داده‌های تراز سطح آب تأخیری در مدل جنگل تصادفی است.

در تحلیل حساسیت، مشخص شد که مدل نسبت به متغیرهای مرتبط با تغییرات زمانی سطح آب بسیار حساس است و بیش‌ترین تغییر در عملکرد مدل ناشی از افزودن یا حذف متغیرهای تراز سطح آب است. در مقابل، شاخص‌های طیفی حساسیت کم‌تری در بهبود عملکرد نهایی مدل نشان دادند، درحالی‌که نقش آن‌ها در استخراج اولیه پهنه آبی ضروری است. ارزیابی عدم قطعیت مبتنی بر OOB نیز نشان داد که در تمام سناریوها، بازه‌های پیش‌بینی دارای پوشش نزدیک به سطح اطمینان اسمی ۹۰ درصد بوده و از قابلیت اطمینان مناسبی برخوردارند. از نظر کاربردی، چارچوب پیشنهادی می‌تواند به‌عنوان یک ابزار کم‌هزینه و قابل اتکا برای پایش پیوسته تراز آب مخازن سدها در مناطق خشک و نیمه‌خشک مورد استفاده قرار گیرد، به‌ویژه در شرایطی که داده‌های ایستگاهی در دسترس نیست. با این حال، مطالعه حاضر محدود به یک حوضه و یک بازه زمانی مشخص است و تعمیم‌پذیری آن به سایر مناطق نیازمند بررسی‌های بیش‌تر است. در تحقیقات آینده می‌توان از مدل‌های یادگیری عمیق، داده‌های چندسنسوره و روش‌های پیشرفته‌تر تحلیل عدم قطعیت برای بهبود دقت و پایداری نتایج استفاده کرد.

علاوه بر این، پیشنهاد می‌شود پارامترهای تکمیلی نظیر دبی ورودی به مخزن، دبی خروجی، و داده‌های هواشناسی (دما، بارش و تبخیر) نیز به عنوان ورودی‌های مدل در نظر گرفته شوند تا امکان بررسی جامع‌تر عوامل مؤثر بر تغییرات تراز سطح مخازن سدها فراهم آید.

ملاحظه‌های اخلاقی

دسترسی به داده‌ها: داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.
حمایت مالی: این پژوهش با حمایت‌های مالی و تسهیلات معاونت پژوهشی و فناوری دانشگاه علوم کشاورزی و منابع طبیعی خوزستان انجام شده است.

مشارکت نویسندگان: **ظہیری، ج.:** مفهوم‌سازی، مدیریت پروژه، تحلیل‌های نرم‌افزاری، نگارش مقاله.
تضاد منافع: نویسنده این مقاله اعلام می‌دارد که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارد.
سپاس‌گزاری: نویسنده مراتب قدردانی خود را از حمایت‌ها و تسهیلات فراهم‌شده توسط دانشگاه علوم کشاورزی و منابع طبیعی خوزستان ابراز می‌دارند. هم‌چنین از سازمان آب و برق خوزستان به دلیل ارائه داده‌های مورد استفاده در این پژوهش تشکر و سپاس‌گزاری می‌شود.

منابع

- احمدی، م.، کاویانی، ع.، رضانی اعتدالی، ه.، و توکلی، ع. (۱۴۰۲). شبیه‌سازی عملکرد گندم دیم با استفاده از شاخص‌های خشکسالی و با بکارگیری روش شبکه عصبی مصنوعی، جنگل تصادفی و رگرسیون بردار پشتیبان (مطالعه موردی: شهرستان سقز). *تحقیقات منابع آب ایران*، ۱۹(۴)، ۹۵-۱۰۹. doi: 10.22034/IWRR.2023.177606
- تقیان، ع. (۱۳۷۹). مکان‌گزینی سد جره از نگاه آمایش سرزمین. *اطلاعات جغرافیایی*، ۳۶(۳)، ۵۱-۵۵. doi: 20.1001.1.25883860.1379.9.36.9.7.55-51
- جهانی، م.، دستورانی، م.، و راشکی، ع. (۱۴۰۳). پیش‌بینی جریان‌های سیلابی بر اساس راهکار ترکیبی داده‌های گوگل ارث انجین و مدل‌های هوش مصنوعی. *سامانه‌های سطوح آبگیر باران*، ۱۲(۴)، ۷۲-۵۱. doi: 20.1001.1.24235970.1403.12.4.6.5.72-51
- سعدیان، ع.، و نعمتی شیشه‌گران، ن. (۱۴۰۴). مقایسه عملکرد روش‌های یادگیری ماشین در ریزمقیاس‌نمایی متغیرهای بارش و دمای شبیه‌سازی شده توسط مدل‌های اقلیمی. *سامانه‌های سطوح آبگیر باران*، ۱۳(۴)، ۱۰۹-۱۳۳. doi: 20.1001.1.24235970.1404.13.4.1.7.109-133
- کوهانی، محمد، بهمنش، جواد، و رضوردی‌نژاد، وحید (۱۴۰۴). تحلیل تغییرات مساحت و کیفیت آب تالاب‌های حوزه آبریز گدارچای. *سامانه‌های سطوح آبگیر باران*، ۱۳(۱)، ۶۷-۸۴. doi: 20.1001.1.24235970.1404.13.1.5.5.67-84

References

- Ahmadi, M., Kaviani, A., Ramezani Etedali, H., & Tavakoli, A. (2023). Simulation of rainfed wheat yield using drought indices by employing artificial neural network, random forest and support vector regression (Case study: Saqqez City). *Iran-Water Resources Research*, 19(4), 95–109. doi: 10.22034/IWRR.2023.177606. [In Persian]
- Ali, M. I., Dirawan, G. D., Hasim, A. H., & Abidin, M. R. (2019). Detection of changes in surface water bodies urban area with NDWI and MNDWI methods. *International Journal on Advanced Science Engineering Information Technology*, 9(3), 946-951. doi: 10.18517/ijaseit.9.3.8692.
- Amer, Z., Eddine, Y. T., Moussouni, A., Mokhtari, E., Marouf, N., & Jaafari, A. (2025). Machine learning-driven bathymetric prediction and water level monitoring using satellite imagery for Beni Haroun Dam, Algeria. *Advances in Space Research*, 76(10), 6066-6085. doi: 10.1016/j.asr.2025.08.061.
- Bhangale, U., More, S., Shaikh, T., Patil, S., & More, N. (2020). Analysis of surface water resources using Sentinel-2 imagery. *Procedia Computer Science*, 171, 2645-2654. doi: 10.1016/j.procs.2020.04.287.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32. doi: 10.1023/A:1010933404324
- Chang, L., Cheng, L., Zhang, L., Han, D., Zhang, J., & Liu, P. (2025). Remote sensing-based high-resolution reservoir drought index for identifying the occurrence and propagation of hydrological droughts in a large river basin. *Remote Sensing of Environment*, 328, 114859. doi: 10.1016/J.RSE.2025.114859
- Codjia, A.K.D., Akpoti, K., Dembélé, M., Yonaba, R., Fowe, T., Sankande, S., Koissi, M.G.D.G. & Zwart, S. J. (2025). Estimating water levels in reservoirs using Sentinel-2 derived time series of surface water areas: A case study of 20 reservoirs in Burkina Faso. *International Journal of Applied Earth Observation and Geoinformation*, 139, 104523. doi: 10.1016/j.jag.2025.104523.

- Corbane, C., Politis, P., Kempeneers, P., Simonetti, D., Soille, P., Burger, A., Pesaresi, M., Sabo, F., Syrris, V. & Kemper, T. (2020). A global cloud free pixel-based image composite from Sentinel-2 data. *Data in brief*, 31, 105737. **doi:** 10.1016/j.dib.2020.105737.
- Demirbas, A. (2009). Global renewable energy projections. *Energy Sources, Part B*, 4(2), 212-224. **doi:** 10.1080/15567240701620499.
- Deng, X., Song, C., Liu, K., Ke, L., Zhang, W., Ma, R., Zhu, J., & Wu, Q. (2020). Remote sensing estimation of catchment-scale reservoir water impoundment in the upper Yellow River and implications for river discharge alteration. *Journal of Hydrology*, 585, 124791. **doi:** 10.1016/J.JHYDROL.2020.124791
- Donchyts, G., Winsemius, H., Baart, F., Dahm, R., Schellekens, J., Gorelick, N., Iceland, C. and Schmeier, S. (2022). High-resolution surface water dynamics in Earth's small and medium-sized reservoirs. *Scientific reports*, 12(1), 13776. **doi:** 10.1038/s41598-022-17074-6.
- Eldardiry, H., & Hossain, F. (2021). The value of long-term streamflow forecasts in adaptive reservoir operation: The case of the High Aswan Dam in the transboundary Nile River basin. *Journal of Hydrometeorology*, 22(5), 1099-1115. **doi:** 10.1175/JHM-D-20-0241.1.
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote sensing of environment*, 140, 23-35. **doi:** 10.1016/j.rse.2013.08.029
- Föge, N., & Pauly, M. (2026). Confidence intervals for Random Forest permutation importance with missing data. *Computational Statistics*, 41(3), 45-61. **doi:** 10.1007/S00180-026-01722-W
- Gao, H., Birkett, C., & Lettenmaier, D. P. (2012). Global monitoring of large reservoir storage from satellite remote sensing. *Water Resources Research*, 48(9). **doi:** 10.1029/2012WR012063.
- Guo, H., Hou, Y., Yang, Y., & McVicar, T. R. (2024). Global evaluation of simulated high and low flows from 23 macroscale models. *Journal of Hydrometeorology*, 25(3), 425-443. **doi:** 10.1175/JHM-D-23-0176.1
- Jahani, M., Dastorani, M.T., & Rashki, A. (2024). Prediction of flood flows based on the combined solution of Google Earth Engine data and artificial intelligence models. *Journal of Rainwater Catchment Systems*, 12(4), 51-72. **doi:** 20.1001.1.24235970.1403.12.4.6.5. [In Persian]
- Koohani, M., Behmanesh, J., & Rezaverdinejad, V. (2025). Analysis of changes in area and water quality of wetlands in the Godarchay Watershed. *Iranian Journal of Rainwater Catchment Systems*, 13(1), 67-84. **doi:** 20.1001.1.24235970.1404.13.1.5.5. [In Persian]
- Lehner, B., Liermann, C. R., Revenga, C., Vörösmarty, C., Fekete, B., Crouzet, P., Döll, P., Endejan, M., Frenken, K., Magome, J. & Nilsson, C. (2011). High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management. *Frontiers in Ecology and the Environment*, 9(9), 494-502. **doi:** 10.1890/100125
- Mahmood, M. R., Abraham, B. I., Jumaah, H. J., Alalwan, H. A., & Mohammed, M. M. (2025). Drought monitoring of large lakes in Iraq using remote sensing images and normalized difference water index (NDWI). *Results in Engineering*, 25, 103854. **doi:** 10.1016/j.rineng.2024.103854.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432. **doi:** 10.1080/01431169608948714.
- Rajanala, S., Bates, S., Hastie, T., & Tibshirani, R. (2022). Confidence Intervals for the generalization error of Random Forests. *ArXiv*, 2201.11210. **doi:** 10.48550/ARXIV.2201.11210.
- Rao, K., Cao, X., Wang, Y., Zhang, Y., Huang, H., Ma, Y., & Xu, J. (2024). Spatial-temporal distributions of phytoplankton shifting, chlorophyll-a, and their influencing factors in shallow lakes using remote sensing. *Ecological Informatics*, 82, 102765. **doi:** 10.1016/j.ecoinf.2024.102765.
- Rodríguez-Alarcón, R., & Lozano, S. (2017). SOM-based decision support system for reservoir operation management. *Journal of Hydrologic Engineering*, 22(7), 04017012. **doi:** 10.1061/(asce)he.1943-5584.0001496.
- Sadian, A., Nemati Shishehgaran, N. (2026). Comparison of machine learning methods for statistical downscaling of climate models precipitation and temperature. *Journal of Rainwater Catchment Systems*, 13(4), 7. **doi:** 20.1001.1.24235970.1404.13.4.1.7. [In Persian]
- Sagawa, T., Yamashita, Y., Okumura, T., & Yamanokuchi, T. (2019). Satellite derived bathymetry using machine learning and multi-temporal satellite images. *Remote Sensing*, 11(10), 1155. **doi:** 10.3390/rs11101155.
- Sheffield, J., Wood, E. F., Pan, M., Beck, H., Coccia, G., Serrat-Capdevila, A., & Verbist, K. J. W. R. R. (2018). Satellite remote sensing for water resources management: Potential for supporting sustainable development in data-poor regions. *Water Resources Research*, 54(12), 9724-9758. **doi:** 10.1029/2017WR022437.
- Taghian, A. (2001). Location of Jareh Dam from Spatial Planning Point of View. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 9(36), 51-55. **doi:** 20.1001.1.25883860.1379.9.36.9.7 [In Persian]

Wada, Y., Bierkens, M. F., De Roo, A., Dirmeyer, P. A., Famiglietti, J. S., Hanasaki, N., Konar, M., Liu, J., Müller Schmied, H., Oki, T., & Pokhrel, Y. (2017). Human–water interface in hydrological modelling: current status and future directions. *Hydrology and Earth System Sciences*, 21(8), 4169-4193. **doi:** 10.5194/hess-21-4169-2017.

Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033. **doi:** 10.1080/01431160600589179.

Xu, H. (2007). Extraction of urban built-up land features from Landsat imagery using a thematic-oriented index combination technique. *Photogrammetric Engineering & Remote Sensing*, 73(12), 1381-1391. **doi:** 10.14358/PERS.73.12.1381.

Yang, Y., Hou, X., Gao, W., Li, F., Guo, F., & Zhang, Y. (2024). Retrieving Lake Chla concentration from remote Sensing: Sampling time matters. *Ecological Indicators*, 158, 111290. **doi:** 10.1016/j.ecolind.2023.111290.

Yao, J., Sun, S., Zhai, H., Feger, K. H., Zhang, L., Tang, X., Li, G., & Wang, Q. (2022). Dynamic monitoring of the largest reservoir in North China based on multi-source satellite remote sensing from 2013 to 2022: Water area, water level, water storage and water quality. *Ecological Indicators*, 144, 109470. **doi:** 10.1016/J.ECOLIND.2022.109470

Zahiri, J., & Mirzaei, A. (2025). Evaluation of optimal dam release to achieve agricultural economic-ecological development from stakeholders' perspectives in the Karkheh basin, Iran. *Journal of Hydrology: Regional Studies*, 57, 102181. **doi:** 10.1016/j.ejrh.2025.102181.

Zahiri, J., Mollaei, Z., & Ansari, M. R. (2020). Estimation of suspended sediment concentration by M5 model tree based on hydrological and moderate resolution imaging spectroradiometer (MODIS) data. *Water Resources Management*, 34(12), 3725–3737. **doi:** 10.1007/S11269-020-02577-6.

Zahiri, J., Nikoo, M. R., Moradi-Sabzkouhi, A., Cheraghi, M., & Nawari, N. M. (2025). Integrating piecewise and symbolic regression with remote sensing data for spatiotemporal analysis of surface water total dissolved solids in the Karun River, Iran. *Results in Engineering*, 25, 104159. **doi:** 10.1016/J.RINENG.2025.104159.

Zhang, H., Gorelick, S. M., Zimba, P. V., & Zhang, X. (2017). A remote sensing method for estimating regional reservoir area and evaporative loss. *Journal of Hydrology*, 555, 213-227. **doi:** 10.1016/j.jhydrol.2017.10.007.

Zhang, Z., Xiao, Y., Chen, R., Long, K., Deng, H., Zheng, Z., & Liao, J. (2026). Comparative assessment of machine learning models for daily streamflow prediction in a subtropical monsoon watershed. *Scientific Reports*. **doi:** 10.1038/s41598-026-38969-8.

Zou, Z., Xiao, X., Dong, J., Qin, Y., Doughty, R. B., Menarguez, M.A., Zhang, G., & Wang, J. (2018). Divergent trends of open-surface water body area in the contiguous United States from 1984 to 2016. *Proceedings of the National Academy of Sciences*, 115(15), 3810-3815. **doi:** 10.1073/pnas.1719275115.