



The Application of Artificial Intelligence in Developing a Local Climate Change Adaptation Strategy for Qanats: Evaluating the Performance of XGBoost in Estimating the Discharge of Qaen Qanats

Mohamad Fouladi Nasrabad¹  | Mohammad Reza Farzaneh^{2*}  | Sepideh Zeraati Neyshabouri³ 

1. Ph.D. Student in Water Resources, Department of Water Engineering, University of Birjand, Birjand, Iran. Email: mohamadfouladi-nsrbd@birjand.ac.ir

2. Corresponding Author, Assistant Prof. at Research Group of Environmental Engineering and Pollution Monitoring, Research Center for Environment and Sustainable Development, RCESD, Tehran, Iran. Email: mrf.farzaneh.env@gmail.com

3. Ph.D. in Water Resources, Department of Water Engineering, Faculty of Agriculture, University of Birjand, Birjand, Iran. Email: sepideh_zeraatineyshabouri@birjand.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:

Received 27 February 2026

Revised 07 April 2026

Accepted 26 May 2026

Published Online 23 September 2026

Keywords:

Machine learning in hydrology,
Climate change adaptation,
Sensitivity analysis,
Qanat management,
Gradient boosting modeling.

ABSTRACT

Climate change, as a fundamental challenge of the present century, has made it inevitable for urban and regional policymakers to revise adaptation strategies and develop accurate prediction tools by affecting water resources in arid regions. Qanats, as strategic and vital infrastructures for water supply in settlements of Iran's arid regions, are currently facing threats due to declining groundwater levels, which doubles the need for applying artificial intelligence-based decision support systems. The present study aims to strengthen the foundations of water resources management planning by evaluating the performance of the XGBoost machine learning model in predicting the discharge of qanats in the Qaen Plain. To this end, 12-year data on qanat discharge (2007–2018), climatic variables (precipitation and temperature), and elevation were used. After preprocessing, the data were split into training (70%) and testing (30%) sets, and the model hyperparameters were tuned using RandomizedSearchCV with RMSE as the optimization objective. The evaluation results showed that XGBoost, with $R^2 \approx 0.88$ and $NS = 0.76$ in the testing phase, has high reliability for use in hydrological analyses. Based on sensitivity analysis, the optimal combination of hyperparameters was $n_estimators=500$, $max_depth=6$, $learning_rate=0.08$, and $min_child_weight=4$. However, it was observed that the model suffers from poor performance in predicting discharges exceeding 20 L/s due to the RMSE loss function and data imbalance. The findings of this study, while confirming the effectiveness of machine learning models in smartening water management, emphasize the need for caution in policymaking based on extreme flow predictions and provide an operational framework for enhancing the resilience of traditional water infrastructures against climate change.

Cite this article: Fouladi Nasrabad, M.; Farzaneh, M. R. & Zeraati Neyshabouri, S. (2026). The Application of Artificial Intelligence in Developing a Local Climate Change Adaptation Strategy for Qanats: Evaluating the Performance of XGBoost in Estimating the Discharge of Qaen Qanats. *Urban Development Policy Making*, 3 (3), 455-469. DOI: <http://doi.org/10.22034/judpm.2026.579182.1096>



© Authors retain the copyright and full publishing rights.

DOI: <http://doi.org/10.22034/judpm.2026.579182.1096>

Introduction

Climate change has emerged as one of the most pressing challenges of the twenty-first century, exerting significant pressure on water resources in arid and semi-arid regions. Qanats, as historic and strategic water-supply infrastructures in Iran's dry regions, are increasingly threatened by declining

groundwater levels, underscoring the need for artificial intelligence-based decision-support systems in water resources management. While previous studies have applied various machine learning techniques to qanat and groundwater discharge prediction, the application of XGBoost specifically for qanat discharge estimation in arid regions such as Qaen has received limited attention. This study therefore aims to evaluate the performance of the XGBoost algorithm in predicting the discharge of qanats in the Qaen Plain, Iran, as a basis for developing a localized climate change adaptation strategy for traditional water infrastructure.

Materials and Methods

This study used 12 years of qanat discharge data (2007–2018) along with climatic variables (precipitation and temperature) and elevation as a spatial parameter for the Qaen Plain in South Khorasan Province. After data collection, a preprocessing stage was carried out, including outlier detection and removal using the interquartile range (IQR) method, and data scaling through min-max normalization and Z-score standardization. The dataset was then divided chronologically into training (70%) and testing (30%) subsets using a temporal split to prevent information leakage and to realistically simulate prediction conditions. The XGBoost model was trained with hyperparameters optimized through RandomizedSearchCV using RMSE as the objective function. Model performance was assessed using RMSE, R^2 , Nash-Sutcliffe Efficiency (NSE), and Kling-Gupta Efficiency (KGE). In addition, a sensitivity analysis of the key hyperparameters (`n_estimators`, `max_depth`, `learning_rate`, and `min_child_weight`) was conducted using a five-fold temporal cross-validation approach.

Results

The results indicated that XGBoost achieved high predictive accuracy, with R^2 values of 0.875 and 0.881, NSE values of 0.757 and 0.764, and KGE values of 0.749 and 0.747 for the training and testing phases, respectively, while RMSE increased only slightly from 2.905 in training to 3.058 in testing, reflecting good model stability and generalizability. Statistical visualizations (swarm, scatter, ECDF, and violin plots) showed that the model performed very well for mid-range discharge values (0–20 L/s) but tended to underestimate extreme discharge values (above 20 L/s), a limitation attributed to the RMSE-based loss function and an imbalance in the training data toward moderate flow values. Sensitivity analysis identified the optimal hyperparameter configuration as `n_estimators` = 500, `max_depth` between 4 and 6, `learning_rate` up to approximately 0.4, and `min_child_weight` showing high sensitivity without reaching a clear optimum within the tested range, suggesting that further tuning toward higher values may still improve performance.

Discussion and Conclusion

The findings confirm that XGBoost is a reliable and effective tool for predicting qanat discharge under arid climatic conditions, supporting its use in smart, data-driven water resources management and the design of local climate change adaptation strategies. At the same time, the model's reduced accuracy in predicting extreme discharge events highlights the need for caution when using such predictions as a sole basis for policymaking related to flow extremes, which are expected to become more frequent under climate change. To address this limitation, future studies are recommended to explore alternative loss functions such as MAE or Huber loss, to enrich training datasets with more observations of high- and low-flow events, and to consider hybrid approaches combining XGBoost with models such as LightGBM or deep learning architectures. Incorporating additional explanatory variables, including water quality, land use, and drought indices, could further enhance model performance. Overall, this study positions the qanat not merely as a traditional engineering structure but as a strategic and intelligent component of climate resilience, demonstrating how the integration of advanced machine learning tools with indigenous water management knowledge can support the sustainable management of arid-region water resources.



کاربرد هوش مصنوعی در تدوین استراتژی بومی سازگاری با تغییر اقلیم قنات: ارزیابی عملکرد XGBoost در تخمین دبی قنات قاین

محمد فولادی نصرآباد^۱ | محمدرضا فرزانه^{۲*} | سپیده زراعتی نیشابور^۳

۱. دانشجوی دکتری منابع آب، گروه مهندسی آب، دانشگاه بیرجند، بیرجند، ایران. رایانامه: mohamadfouladi-nsrbd@birjand.ac.ir

۲. نویسنده مسئول، استادیار گروه پژوهشی مهندسی محیط زیست و پایش آلودگی، پژوهشکده محیط زیست و توسعه پایدار، تهران، ایران. رایانامه: mrf.farzaneh.env@gmail.com

۳. دانش آموخته دکتری منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. رایانامه: sepideh_zeraatineyshabouri@birjand.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:

پژوهشی

تاریخ های مقاله:

تاریخ دریافت: ۱۴۰۴/۱۲/۰۸

تاریخ بازنگری: ۱۴۰۵/۰۱/۱۸

تاریخ پذیرش: ۱۴۰۵/۰۳/۰۵

تاریخ انتشار: ۱۴۰۵/۰۷/۰۱

کلیدواژه:

یادگیری ماشین در هیدرولوژی،

سازگاری با تغییر اقلیم،

تحلیل حساسیت،

مدیریت قنات،

مدل سازی گرادین بوسینگ.

تغییر اقلیم به عنوان چالشی بنیادین در قرن حاضر، با تحت تأثیر قرار دادن منابع آب مناطق خشک، بازنگری در راهبردهای سازگاری و توسعه ابزارهای پیش‌بینی دقیق را برای سیاستگذاران شهری و منطقه‌ای اجتناب‌ناپذیر کرده است. قنات به عنوان زیرساخت‌های استراتژیک و حیاتی در تأمین آب سکونتگاه‌های مناطق خشک ایران، امروزه با تهدیدهای ناشی از کاهش تراز آب‌های زیرزمینی روبه‌رو هستند که این امر لزوم به‌کارگیری سیستم‌های پشتیبان تصمیم‌گیری مبتنی بر هوش مصنوعی را دوجندان می‌کند. پژوهش حاضر با هدف تقویت مبانی برنامه‌ریزی مدیریت منابع آب، به بررسی عملکرد مدل یادگیری ماشین XGBoost در پیش‌بینی دبی قنات دشت قاین پرداخته است. در این راستا، از داده‌های ۱۲ ساله آینده قنات (۱۳۸۶ - ۱۳۹۷)، متغیرهای اقلیمی بارش و دما و متغیر ارتفاع استفاده شد که پس از پیش‌پردازش، داده‌ها به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم و فراسنجه‌های مدل با روش RandomizedSearchCV و هدف بهینه‌سازی RMSE تعیین شدند. نتایج حاصل از ارزیابی مدل نشان داد XGBoost با مقادیر R^2 حدود ۰/۸ و معیار NS برابر با ۰/۷۶ در بخش آزمون، از قابلیت اعتماد بالایی برای استفاده در تحلیل‌های هیدرولوژیکی برخوردار است. بر اساس تحلیل حساسیت، ترکیب بهینه فراسنجه‌ها شامل $\text{max_depth}=6$ ، $\text{a_estimators}=500$ و $\text{learning_rate}=0.08$ و $\text{min_child_weight}=4$ حاصل شد؛ با این وجود، مشاهده شد که مدل در پیش‌بینی دبی‌های فراتر از ۲۰ لیتر بر ثانیه به دلیل تابع خطای RMSE و عدم تعادل داده‌ها دچار ضعف است. یافته‌های این پژوهش ضمن تأیید کارایی مدل‌های یادگیری ماشین در هوشمندسازی مدیریت آب، بر ضرورت احتیاط در سیاستگذاری‌های مبتنی بر پیش‌بینی جریان‌های حدی تأکید دارد و چارچوبی عملیاتی برای ارتقای تاب‌آوری زیرساخت‌های سستی آب در برابر تغییرات اقلیمی ارائه می‌دهد.

استناد: فولادی نصرآباد، محمد؛ فرزانه، محمدرضا و زراعتی نیشابور، سپیده (۱۴۰۵). کاربرد هوش مصنوعی در تدوین استراتژی بومی سازگاری با تغییر اقلیم قنات: ارزیابی عملکرد XGBoost در تخمین دبی قنات قاین. *سیاستگذاری پیشرفت شهری*، ۳ (۳) ۴۵۵-۴۶۹.

DOI: <http://doi.org/10.22034/judpm.2026.579182.1096>

© نویسندگان

DOI: <http://doi.org/10.22034/judpm.2026.579182.1096>



۱. مقدمه

تغییر اقلیم به عنوان یکی از چالش‌های مهم قرن بیست‌ویکم، تأثیرات گسترده و عمیقی بر چرخه آب جهانی و منابع آبی منطقه‌ای وارد می‌کند [۱ و ۲]. این پدیده با تغییر الگوهای بارش، افزایش شدت و فراوانی پدیده‌های حدی هیدرولوژیکی و نوسانات دمایی، به تشدید تنش آبی در مناطق خشک و نیمه‌خشک منجر می‌شود [۳ و ۴]. براساس گزارش‌های هیئت بین‌الدولی تغییر اقلیم (IPCC)، پیش‌بینی می‌شود که این مناطق در دهه‌های آینده با کاهش قابل توجه منابع آب تجدیدپذیر مواجه شوند [۵ و ۶]. اثرات تغییر اقلیم بر منابع آب زیرزمینی نیز به‌ویژه در مناطق خشک قابل توجه است. کاهش تغذیه آبخوان‌ها، تغییر رژیم‌های هیدرولوژیکی و افزایش تبخیر و تعرق، به کاهش سطح آب‌های زیرزمینی و در نتیجه، کاهش آبدی منابع آب سنتی مانند چشمه‌ها و قنوات منجر می‌شود [۱ و ۳]. این روند نه تنها امنیت آب شرب جوامع محلی را تهدید می‌کند، بلکه پایداری کشاورزی و معیشت میلیون‌ها نفر در جهان را نیز در معرض خطر قرار می‌دهد [۴ و ۷].

یکی از راهبردهای مهم سازگاری با تغییر اقلیم، حفظ و احیای سیستم‌های آب سنتی مانند قنوات است که نه تنها از نظر فنی کارآمد، بلکه از نظر اقتصادی و زیست‌محیطی نیز پایدار هستند [۸ و ۹]. قنوات به عنوان فناوری بومی و سازگار با محیط، قابلیت تطبیق با شرایط متغیر اقلیمی را دارد و می‌توانند نقش مهمی در تأمین امنیت آبی مناطق خشک ایفا کنند [۹ و ۱۰]. قنات به عنوان شاخص‌ترین میراث بومی سازگاری با کم‌آبی، به گذار از مدیریت سنتی به الگوهای مدیریتی هوشمند نیاز دارد. تدوین استراتژی‌های بومی سازگاری با تغییر اقلیم، امروزه مستلزم فراتر رفتن از روش‌های کلاسیک و بهره‌گیری از توانمندی‌های هوش مصنوعی است؛ چرا که الگوریتم‌های هوشمند قادرند با تحلیل پیچیدگی‌های رفتار آبخوان‌ها، الگوهای پنهان در نوسانات دبی قنوات را شناسایی کنند و به بستری برای تصمیم‌گیری‌های علمی بدل شوند. به بیان دیگر، کاربرد هوش مصنوعی نه تنها به افزایش دقت برآورد منابع آبی کمک می‌کند، بلکه به عنوان یک پیشران استراتژیک، امکان بازتولید دانش بومی قنات را در قالب راهکارهای نوین سازگاری فراهم می‌سازد. در حال حاضر، حدود ۳۵ هزار رشته قنات در سراسر ایران شناسایی شده است که سهم قابل توجهی در تأمین آب زیرزمینی دارند. میزان برداشت سالانه آب از قنات‌های ایران بین ۶ تا ۸ میلیارد متر مکعب برآورد می‌شود. استان‌های خراسان رضوی، یزد، کرمان و خراسان جنوبی بیشترین تعداد قنات را دارند، به طوری که استان خراسان جنوبی با بیش از ۴ هزار رشته قنات معمولاً در رتبه چهارم کشور قرار می‌گیرد [۱۱ و ۱۲].

دشت قاین در استان خراسان جنوبی، با اقلیمی خشک و نیمه‌خشک و میانگین بارش محدود، از دیرباز حیات اقتصادی و اجتماعی خود را مدیون شبکه گسترده قنات بوده است. با این حال، تغییر اقلیم، کاهش منابع آب زیرزمینی و افزایش تقاضا، ضرورت پیش‌بینی دقیق دبی قنات را برای مدیریت بهینه و پایدار این منابع ارزشمند بیش از پیش آشکار کرده است. در این راستا، توسعه ابزارهای مدل‌سازی پیشرفته برای پیش‌بینی رفتار قنات در شرایط متغیر اقلیمی، نقش کلیدی در برنامه‌ریزی و اجرای راهبردهای سازگاری دارد [۱۳ و ۱۴].

در سال‌های اخیر، پیشرفت‌های چشمگیر در هوش مصنوعی و یادگیری ماشین، ابزارهای نوینی برای مدل‌سازی هیدرولوژیکی فراهم کرده‌اند. مطالعات نشان داده‌اند الگوریتم‌هایی مانند تقویت شدید گرادیان (به اختصار XGBoost)، به دلیل توانایی پردازش داده‌های پیچیده و غیرخطی، در پیش‌بینی پدیده‌های هیدرولوژیکی مانند دبی رودخانه‌ها و آب‌های زیرزمینی موفق عمل کرده‌اند. این مدل با ترکیب درخت‌های تصمیم‌گیری و تکنیک‌های تقویت گرادیان، به دلیل سرعت زیاد، دقت قابل اعتماد و توانایی استخراج الگوهای پنهان، به یکی از ابزارهای محبوب در مطالعات هیدرولوژیکی تبدیل شده است [۱۵].

پژوهش‌های داخلی در حوزه هیدرولوژی و قنات‌ها نشان می‌دهد تمرکز مطالعات از روش‌های ترکیبی و هوشمند به سمت مدل‌های پیشرفته‌تری حرکت کرده است. در این زمینه، سامانی و همکاران (۲۰۲۳) در پژوهشی به ارزیابی عملکرد پنج مدل یادگیری ماشین شامل شبکه عصبی مصنوعی، سیستم استنتاج عصبی - فازی، روش گروهی پردازش داده، برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان در پیش‌بینی جریان آب قنات در آبخوان چالندی ایران پرداختند. مطالعه ایشان با استفاده از داده‌های ماهانه ۱۴ ساله (۲۰۰۷-۲۰۲۱) نشان داد ترکیب تبدیل موجک با مدل‌های یادگیری ماشین به بهبود چشمگیر دقت پیش‌بینی جریان آب قنات برای افق‌های زمانی یک تا سه ماهه منجر می‌شود. در میان مدل‌های مورد بررسی، مدل ترکیبی به‌دست‌آمده

از روش گروهی پردازش داده‌ها و تبدیل موجک (به اختصار WT-GMDH) با مقادیر خطای جذر میانگین مربعات (RMSE) برابر با ۱۴/۴۶، خطای میانگین مطلق (MAE) برابر با ۱۰/۷۸، ضریب تعیین (R^2) برابر با ۰/۹۳ و ضریب نش - ساتکلیف (NSE) برابر با ۰/۸۵ بهترین عملکرد را در پیش‌بینی یک‌ماهه جریان آب قنات از خود نشان داد [۱۶]. هم‌زمان با این پژوهش، پیرائی و همکاران (۲۰۲۳) با بهره‌گیری از XGBoost توانستند دقت قابل توجهی در پیش‌بینی بار رسوبی به دست آورند و اذعان داشتند که XGBoost می‌تواند به عنوان ابزاری مؤثر و قابل اعتماد در مدیریت منابع آب و کنترل رسوبات در رودخانه‌ها مورد استفاده قرار گیرد [۱۷]. همچنین، سفیرا و همکاران (۲۰۲۴) در پژوهش خود با استفاده از الگوریتم XGBoost و ادغام داده‌های هیدروکلیمایی مدل‌های سطح زمین Noah، شکاف داده‌ای بین ماهواره‌های GRACE و GRACE-FO را پوشش دادند و توانستند تغییرات مکانی - زمانی ذخیره آب زمینی را با دقت بالا مدل‌سازی کنند. نتایج پژوهش آن‌ها با معیارهای آماری قوی مانند ضریب همبستگی ۰/۹۴۳ و کارایی نش - ساتکلیف ۰/۸۸۷ نشان‌دهنده کارآمدی این روش در تحلیل منابع آب در مقیاس محلی بود [۱۸]. درنهایت، خسروی و همکاران (۲۰۲۶) در مطالعه‌ای به بررسی عملکرد مدل‌های آر، ما و آرما (AR، MA و ARMA) در پیش‌بینی آبدی قنات بلده فردوس پرداختند. پژوهش یادشده بر تحلیل داده‌های ماهانه ۲۰ساله (۲۰۰۰-۲۰۲۰) مبتنی بود. نتایج پژوهش یادشده نشان داد مدل ۲AR با کمترین مقدار معیار آکائیک به عنوان مدل بهینه انتخاب شد. اما در مقایسه با مدل‌های هوشمند مورد استفاده در مطالعات پیشین (مانند ANFIS و WT-GMDH)، دقت کمتری در پیش‌بینی بلندمدت از خود نشان داد. این موضوع بیانگر محدودیت مدل‌های خطی سنتی در مدل‌سازی پویایی‌های غیرخطی سیستم‌های آب زیرزمینی است [۱۹].

علاوه بر مطالعات داخلی، در سطح بین‌المللی نیز مطالعات متعددی کاربرد XGBoost را در کاربردهای گسترده هیدرولوژیکی تأیید کرده‌اند. جیانگ و همکاران (۲۰۲۲) نخستین مطالعه را در این بازه زمانی ارائه دادند که تأیید می‌کند XGBoost ابزاری کارآمد برای ارزیابی ویژگی‌های خشک‌سالی هیدرولوژیکی با استفاده از داده‌های GNSS است [۲۰]. وو و همکاران (۲۰۲۲) نیز در پژوهش خود به شناسایی نشت‌ها در شبکه‌های توزیع آب با استفاده از الگوریتم XGBoost پرداختند. آن‌ها با به‌کارگیری این الگوریتم یادگیری ماشین توانستند نشت‌های آب را با دقت بالا تشخیص دهند و عملکرد شبکه‌های توزیع آب را بهبود بخشند. نتایج این مطالعه نشان داد XGBoost ابزار مؤثری برای پایش و مدیریت شبکه‌های آب شهری است و می‌تواند به کاهش هدررفت آب و افزایش بهره‌وری سیستم‌های توزیع کمک کند [۲۱]. همچنین، ژو و همکاران (۲۰۲۲) در مطالعه‌ای با به‌کارگیری XGBoost، مدل دقیقی برای پیش‌بینی جریان رواناب در مقیاس بلوک ارائه کردند که نشان داد پیکرندی‌های مختلف ساختمان‌ها می‌تواند تأثیر قابل توجهی بر مدیریت رواناب و کاهش خطر سیلاب‌های شهری داشته باشد [۲۲]. علی و همکاران (۲۰۲۳) با به‌کارگیری XGBoost برای تحلیل خشک‌سالی در حوضه آبریز ایندوس، بهبود قابل توجهی در دقت پیش‌بینی فراسنجه‌های هیدرولوژیکی گزارش کردند [۲۳]. به عنوان مثال، ژانگ و همکاران (۲۰۲۵) در مطالعه خود (منطقه مطالعاتی فلات تبت) از XGBoost برای شبیه‌سازی تغییرات ذخیره آب زمینی (TWS) با دقت بالا استفاده کردند و اذعان داشتند که این مدل می‌تواند حتی در مناطق با توزیع نامناسب ایستگاه‌های سامانه‌های ناوبری ماهواره‌ای جهانی (GNSS) نتایج قابل اعتمادی تولید کند [۲۴].


علی‌رغم کاربردهای موفق XGBoost در حوزه‌های مختلف منابع آب در ایران و جهان، استفاده از آن برای پیش‌بینی دبی قنات در مناطق خشک مانند قاین کمتر مورد توجه قرار گرفته است و تحقیقات انجام‌شده عموماً روی کارایی سایر روش‌های هوش مصنوعی و یادگیری ماشین یا مدل‌های دیگر متمرکز بوده‌اند. این در حالی است که ویژگی‌های منحصر به فرد XGBoost از قبیل مقاومت در برابر داده‌های نویزی، قابلیت مدیریت متغیرهای زیاد و عملکرد بالا در مسائل پیش‌بینی سری زمانی، آن را به گزینه‌ای جذاب برای مدل‌سازی دبی قنات در شرایط اقلیمی ناپایدار تبدیل می‌کند [۱۵]. علاوه بر این، با توجه به ضرورت توسعه ابزارهای مدل‌سازی قابل اعتماد برای پشتیبانی از برنامه‌ریزی سازگاری با تغییر اقلیم، کاربرد مدل‌های پیشرفته یادگیری ماشین مانند XGBoost می‌تواند نقش مهمی در بهبود دقت پیش‌بینی دبی قنات و در نتیجه، ارتقای تصمیم‌گیری‌های مدیریتی ایفا کند.

پژوهش حاضر با هدف ارزیابی توانایی مدل XGBoost در برآورد دبی قنوات دشت قاین طراحی شده است؛ چراکه قنات به عنوان یکی از ارکان اساسی استراتژی بومی سازگاری با تغییر اقلیم در مناطق خشک ایران، نقش کلیدی در تأمین پایدار آب و تاب‌آوری جوامع محلی ایفا می‌کند. در این راستا، برآورد دقیق و قابل اعتماد دبی قنات، پیش‌نیاز اساسی برای تدوین هرگونه برنامه مدیریتی و راهبرد سازگاری مبتنی بر این میراث هیدرولیکی کهن محسوب می‌شود. داده‌های مورد استفاده شامل آمار آبدی ۱۲ ساله قنات (۱۳۸۶ تا ۱۳۹۷)، داده‌های بارش و دمای ماهانه و فراسنجه‌های مکانی مانند ارتفاع هستند. نتایج این تحقیق نه تنها درک بهتری از کارایی XGBoost در تخمین دبی قنات ارائه می‌دهد، بلکه نشان می‌دهد چگونه بهره‌گیری از هوش مصنوعی می‌تواند به عنوان ابزاری کارآمد در خدمت استراتژی‌های بومی و دانش سنتی قرار گیرد. یافته‌های این پژوهش می‌تواند به عنوان راهکاری علمی برای مدیریت پایدار منابع آب در مناطق خشک و نیمه‌خشک و توسعه راهبردهای بومی سازگاری با تغییر اقلیم مبتنی بر حفاظت و بهره‌برداری بهینه از قنات مورد استفاده قرار گیرد.

۲. مواد و روش‌ها

۲-۱. منطقه مطالعه شده

دشت قاین، واقع در استان خراسان جنوبی، نمونه بارزی از مناطق خشک و نیمه‌خشک ایران است که با چالش‌های جدی در مدیریت منابع آبی دست‌وپنجه نرم می‌کند. این منطقه که در مختصات جغرافیایی ۳۳ درجه و ۴۳ دقیقه عرض شمالی و ۵۹ درجه و ۱۱ دقیقه طول شرقی قرار گرفته، با میانگین بارش سالانه‌ای کمتر از ۱۰۰ میلی‌متر و متوسط دمای سالانه حدود ۲۰ درجه سانتی‌گراد، شرایط اقلیمی دشواری را تجربه می‌کند. تبخیر شدید همراه با خاک‌های رسی - شنی که ظرفیت نگهداری آب پایینی دارند، وابستگی این منطقه به منابع آبی زیرزمینی به‌ویژه قنات را به امری حیاتی تبدیل کرده است [۲۵].



شکل ۱. موقعیت جغرافیایی دشت و آبخوان قاین در استان خراسان جنوبی و کشور ایران

در این پژوهش، برای بررسی دقیق وضعیت منابع آبی و تحلیل تأثیر تغییر اقلیم، از مجموعه‌ای جامع از داده‌ها استفاده شد که شامل آمار آبدی ۱۲ ساله قنات (۱۳۸۶ - ۱۳۹۷)، داده‌های ماهانه بارش و دما از ایستگاه‌های هواشناسی محلی، و اطلاعات ارتفاعی و موقعیت مکانی قنات بود. به این صورت که داده‌های بارش، دما و ارتفاع به عنوان متغیرهای پیش‌بینی‌کننده و داده دبی قنات به عنوان متغیر پیش‌بینی‌شونده در مدل یادگیری لحاظ شده است.

۲-۲. الگوریتم XGBoost

در سال ۲۰۱۶، چن و گس‌ترین (Chen and Guestrin, 2016) الگوریتم XGBoost را به عنوان یک روش پیشرفته برای حل مسائل طبقه‌بندی و رگرسیون معرفی کردند که به سرعت به دلیل کارایی محاسباتی بالا مورد توجه پژوهشگران قرار گرفت. این الگوریتم با استفاده از فنون یادگیری افزایشی، مجموعه‌ای از مدل‌های ضعیف را به صورت هوشمندانه ترکیب می‌کند تا در نهایت به یک مدل پیش‌بین قوی دست یابد [۲۶ و ۲۷]. از جمله مزایای کلیدی این روش می‌توان به قابلیت پردازش موازی، انعطاف‌پذیری ساختاری بالا و سیستم اعتبارسنجی داخلی اشاره کرد که همگی به تولید نتایج دقیق‌تر منجر می‌شوند. هسته اصلی عملکرد XGBoost بر محاسبه خطای باقی‌مانده و بهبود تدریجی مدل از طریق ساختارهای درختی استوار است. این الگوریتم با به کارگیری سه راهبرد مهم شامل تنظیم تابع هدف، کنترل نرخ یادگیری و نمونه‌برداری انتخابی، به طور مؤثری از مشکل بیش‌برازش جلوگیری می‌کند. ویژگی‌های منحصر به فرد یادشده، همراه با بهینه‌سازی مصرف حافظه، XGBoost را به انتخابی ایده‌آل برای کار با مجموعه داده‌های حجیم تبدیل کرده است [۲۶ و ۲۷].

۲-۳. پیش‌پردازش داده‌ها

داده‌های جمع‌آوری شده شامل آبدهی قنات، بارش، دما و ارتفاع، قبل از ورود به مدل XGBoost، تحت فرایند پیش‌پردازش قرار گرفتند. این مرحله شامل سه بخش اصلی بود: حذف داده‌های پرت و نوفه، نرمال‌سازی داده‌ها و تقسیم داده‌ها به دو بخش آموزش و آزمون.

۲-۴. شناسایی و حذف داده‌های پرت

در مرحله پیش‌پردازش داده‌ها، ابتدا داده‌های پرت و نوفه شناسایی و حذف شد. داده‌های پرت به مقادیری گفته می‌شوند که به طور قابل توجهی با الگوی کلی داده‌ها تفاوت دارند و می‌توانند نتایج مدل‌سازی را به شدت تحت تأثیر قرار دهند. حضور این داده‌ها ممکن است باعث انحراف معیارهای ارزیابی و کاهش دقت پیش‌بینی‌های مدل شود. به همین دلیل، حذف آن‌ها گامی ضروری در بهبود کیفیت داده‌ها و افزایش قابلیت اطمینان مدل محسوب می‌شود [۲۸].

برای شناسایی داده‌های پرت، از روش‌های آماری قوی مانند تحلیل چارک‌ها^۱ و محاسبه فاصله بین چارکی^۲ (IQR) استفاده شد. در این روش، ابتدا چارک‌های اول (Q1)، دوم (میانه یا Q2) و سوم (Q3) محاسبه می‌شوند. سپس، IQR که برابر با تفاوت Q3 و Q1 است، به عنوان معیاری برای تشخیص داده‌های پرت در نظر گرفته می‌شود. معمولاً مقادیری که خارج از محدوده $(Q1 - 1.5 \times IQR)$ تا $(Q3 + 1.5 \times IQR)$ قرار بگیرند، به عنوان داده‌های پرت شناسایی و از مجموعه داده حذف می‌شوند. این روش به دلیل سادگی و اثربخشی بالا، به طور گسترده در مطالعات مختلف مورد استفاده قرار می‌گیرد [۲۹ و ۳۰].

۲-۵. نرمال‌سازی و استانداردسازی داده‌ها

در گام بعدی، نرمال‌سازی داده‌ها انجام شد. نرمال‌سازی داده‌ها به بهبود عملکرد مدل و افزایش سرعت همگرایی آن کمک می‌کند. با نرمال‌سازی، مقادیر داده‌ها در یک محدوده مشخص قرار می‌گیرند و تأثیر متغیرهای با مقیاس بزرگ بر مدل کاهش می‌یابد [۲۹ و ۳۰]. در این پژوهش، برای نرمال‌سازی داده‌ها از روش کمینه - بیشینه^۳ استفاده شد که یکی از روش‌های متداول برای تغییر مقیاس داده‌ها به یک بازه مشخص، معمولاً بین ۰ و ۱ است. این روش با محاسبه نسبت اختلاف هر مقدار از حداقل داده‌ها به دامنه کلی داده‌ها (تفاوت بین کمینه و بیشینه) کار می‌کند [۲۹ و ۳۰]. به بیان دیگر، برای هر مقدار (x) از یک ویژگی، مقدار نرمال‌شده x' از رابطه ۱ محاسبه می‌شود.

$$x' = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (1)$$

1. Quartile analysis
2. Interquartile range
3. Min-Max

در مرحله تکمیلی، استانداردسازی شاخص زد (z) نیز روی داده‌ها اعمال شد. در این روش، هر مقدار ویژگی با استفاده از رابطه ۲ محاسبه می‌شود:

$$Z = (x - \mu) / \sigma \quad (2)$$

در رابطه بالا x مقدار اولیه، μ میانگین و σ انحراف معیار کل داده‌هاست.

۲-۶. تقسیم داده‌ها

در این پژوهش، پس از انجام مراحل پیش‌پردازش و نرمال‌سازی داده‌ها، رویکردی نظام‌مند برای تقسیم داده‌ها به کار گرفته شد که هم از نظر آماری صحیح باشد و هم شرایط واقعی پیش‌بینی را به‌درستی شبیه‌سازی کند. داده‌ها به صورت زمانی و با حفظ ترتیب تاریخی به دو بخش مجزا تقسیم شدند، به طوری که ۷۰ درصد ابتدایی داده‌ها به عنوان مجموعه آموزش و ۳۰ درصد پایانی به عنوان مجموعه آزمون در نظر گرفته شدند. این روش تقسیم زمانی^۱ به طور خاص طراحی شده تا از هرگونه نشت اطلاعات بین دو مجموعه جلوگیری کند، مسئله‌ای که در صورت بی‌توجهی می‌تواند به برآوردهای بیش از حد خوش‌بینانه از عملکرد مدل منجر شود [۳۰].

انتخاب نسبت ۷۰ به ۳۰ برای تقسیم داده‌ها بر اساس ملاحظات کارشناسی و مطابقت با استانداردهای رایج در مطالعات یادگیری ماشین انجام شده است. این نسبت از یک سو حجم کافی از داده‌ها را برای آموزش مؤثر مدل فراهم می‌کند و از سوی دیگر، نمونه‌های آزمون کافی برای ارزیابی معنادار آماری در اختیار قرار می‌دهد [۲۹]. نتایج حاصل از این روش‌شناسی نه تنها برای اهداف پژوهشی معتبر است، بلکه می‌تواند مبنای قابل اعتمادی برای تصمیم‌گیری‌های عملیاتی در مدیریت منابع آب باشد.

۲-۷. مدل‌سازی با XGBoost و بهینه‌سازی فراسنجه‌ها

پژوهش حاضر با بهره‌گیری از چارچوب پیشرفته XGBoost به مدل‌سازی و پیش‌بینی داده‌های پیچیده پرداخته است. XGBoost به عنوان یک الگوریتم تقویت گرادیان، با ترکیب بهینه‌ای از درختان تصمیم ضعیف، مدل‌های پیش‌بینی دقیقی ایجاد می‌کند که در برابر مشکلات رایجی مانند بیش‌برازش مقاوم هستند. برای یافتن مقادیر بهینه این فراسنجه‌ها، از روش RandomizedSearchCV استفاده شده که با نمونه‌گیری هوشمند از فضای فراسنجه‌ها، هم دقت بالا و هم کارایی محاسباتی مطلوبی ارائه می‌دهد.

تابع زیان در این پژوهش بر پایه معیار RMSE طراحی شده که از رابطه ۳ محاسبه می‌شود و به دلیل حساسیت به خطاهای بزرگ و تفسیرپذیری آسان، معیار مناسبی برای سنجش دقت مدل است [۳۱].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

۲-۸. معیارهای ارزیابی عملکرد مدل

برای اطمینان از جامعیت ارزیابی، علاوه بر معیار RMSR مجموعه‌ای از معیارهای تکمیلی شامل NSE (برای سنجش نسبت به مدل پایه، رابطه ۴)، R^2 (برای اندازه‌گیری تناسب کلی مدل، رابطه ۵) و KGE (برای ارزیابی توانمندی همبستگی، تغییرپذیری و بایاس، رابطه ۶) به کار گرفته شده‌اند [۳۲ - ۳۴].

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

$$KGE = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad (۶)$$

در معادلات بالا، y_{max} بیشینه مقدار مشاهده شده، y_{min} کمینه مقدار مشاهده شده، y_i مقدار مشاهده شده (واقعی) برای نمونه i ام، $\hat{y}_i$ مقدار پیش‌بینی شده برای نمونه i ام، $\bar{y}$ میانگین مقادیر مشاهده شده، $\bar{\hat{y}}$ میانگین مقادیر پیش‌بینی شده، r ضریب همبستگی پیرسون بین مقادیر مشاهده شده و پیش‌بینی شده، α نسبت ضریب تغییرات پیش‌بینی به ضریب تغییرات مشاهده شده (معیار تغییرپذیری) و β نسبت میانگین پیش‌بینی به میانگین مشاهده شده (معیار بایاس) هستند.

۲-۹. تحلیل حساسیت فراسنجه‌ها

در این پژوهش، تحلیل حساسیت فراسنجه‌های مدل XGBoost با رویکردی نظام‌مند و با استفاده از روش اعتبارسنجی متقاطع زمانی انجام شد تا تأثیر چهار فراسنجه کلیدی $\max_depth$ ، learning_rate و $\min_child_weight$ بر دقت پیش‌بینی آینده قنات در منطقه قاین به‌دقت بررسی شود. فرایند تحلیل با تعیین محدوده‌های مناسب برای هر فراسنجه آغاز شد. برای اجرای تحلیل حساسیت، از روش RandomizedSearchCV استفاده شد که در چارچوب اعتبارسنجی متقاطع زمانی با ۵ لایه اجرا شد. این روش به‌خصوص برای داده‌های سری زمانی مانند داده‌های آینده قنات که وابستگی زمانی دارند، طراحی شده است و از نشت اطلاعات بین داده‌های آموزش و آزمون جلوگیری می‌کند. در هر مرحله از اعتبارسنجی متقاطع، مدل روی ۴ لایه آموزش داده شده و روی لایه پنجم ارزیابی می‌شد تا اطمینان حاصل شود که ارزیابی‌ها در شرایطی مشابه با پیش‌بینی‌های واقعی انجام می‌پذیرد.

۳. نتایج و بحث


به منظور بررسی عملکرد مدل XGBOOST در برآورد دبی قنات دشت قاین، داده‌های آینده قنات، بارش و دمای دشت قاین طی سال‌های ۱۳۸۶ تا ۱۳۹۷ تهیه و عملیات پیش‌پردازش روی آن انجام گرفت و سپس عملکرد مدل XGBOOST با استفاده از معیارهای ارزیابی R^2 ، NS، NRMSE و KGE در دو بخش آموزش و آزمون به نسبت ۷۰ به ۳۰ بررسی شد. درخور یادآوری است که به دلیل اعمال اثر مکانی قنات، فراسنجه ارتفاع (موقعیت مکانی هر قنات) نیز در فرایند آموزش مدل استفاده شد. فراسنجه‌های مدل XGBOOST با استفاده از روش RandomizedSearchCV و با تابع هدف RMSE بهینه‌سازی شدند. جدول ۱ مقادیر معیارهای ارزیابی در بخش آموزش و آزمون دبی قنات را نشان می‌دهد.

جدول ۱. مقادیر معیارهای ارزیابی در بخش آموزش و تست فراسنجه‌های رطوبت نسبی و دمای میانه


معیار ارزیابی (Evaluation criteria)	آبدهی (Discharge)	
	Train	Test
RMSE	2.905	3.058
R^2	0.875	0.881
NSE	0.757	0.764
KGE	0.749	0.747

نتایج ارزیابی عملکرد مدل XGBoost در برآورد دبی قنات دشت قاین نشان می‌دهد این مدل از دقت و کارایی بالایی برخوردار است. مقادیر R^2 نزدیک به ۰/۹ در هر دو بخش آموزش و آزمون، بیانگر تطابق قابل توجه بین مقادیر پیش‌بینی شده و مقادیر مشاهداتی است. این موضوع نشان می‌دهد مدل توانسته است الگوهای موجود در داده‌ها را به‌خوبی شناسایی و بازتولید کند. همچنین، تغییرات اندک معیارهای ارزیابی مانند RMSE که از ۲۵/۹۰۵ در بخش آموزش به ۳/۰۵۸ در بخش آزمون رسیده، بیانگر پایداری و تعمیم‌پذیری مطلوب مدل است. این ثبات عملکرد در بخش‌های مختلف داده‌ها، نشان‌دهنده قابلیت اعتماد مدل در شرایط مختلف است. علاوه بر این، مقادیر NS و KGE نیز عملکرد قابل قبول مدل را تأیید می‌کنند و نمایانگر دقت و کارایی مناسبی مدل در برآورد دبی قنات محدوده مطالعاتی هستند.

برای بررسی دقیق‌تر عملکرد مدل، از نمودارهای آماری خوشه‌ای، پراکندگی، تابع توزیع تجمعی تجربی و ویولن در بخش‌های آموزش و آزمون استفاده شد (شکل‌های ۲ و ۳).



شکل ۲. مقایسه توزیع مقادیر آبدهی مشاهده‌شده و شبیه‌سازی‌شده قنات با استفاده از نمودارهای آماری (Swarm, KDE, ECDF) و Violin در بخش آموزش




شکل ۳. مقایسه توزیع مقادیر آبدهی مشاهده‌شده و شبیه‌سازی‌شده قنات با استفاده از نمودارهای آماری (Swarm, KDE, ECDF) و Violin در بخش آزمون

با توجه به شکل‌های ۲ و ۳، مدل در بازه‌های میانی دبی (۰ تا ۲۰ لیتر بر ثانیه) عملکرد بسیار خوبی دارد و می‌تواند مقادیر را با دقت بالایی پیش‌بینی کند. با این حال، در پیش‌بینی مقادیر حدی (بیش از ۲۰ لیتر بر ثانیه) مدل دچار ضعف شده است. این ضعف می‌تواند ناشی از استفاده از تابع خطای RMSE باشد که تمایل به تولید مقادیر میانی دارد و در نتیجه، مدل را به سمت پیش‌بینی مقادیر متوسط سوق می‌دهد. بررسی دقیق خروجی‌های مدل XGBoost در برآورد دبی قنات، چه در مرحله آموزش و

چه در مرحلهٔ آزمون، تصویر نسبتاً روشنی از قوت‌ها و ضعف‌های این مدل ارائه می‌دهد. در هر دو مجموعه داده، نمودار Swarm Plot نشان می‌دهد مقادیر مشاهده‌شده دارای پراکندگی و دامنهٔ وسیع‌تری نسبت به مقادیر شبیه‌سازی‌شده هستند؛ به طوری که مدل تمایل دارد مقادیر بسیار پایین و بسیار بالا را به سمت میانه فشرده کند. نمودار Scatter Plot در هر دو مجموعه بیانگر آن است که برازش کلی مدل در بازه میانی دبی (حدود ۵ تا ۱۵ لیتر بر ثانیه) قابل قبول است و نقاط به‌خوبی در اطراف خط ۱:۱ تجمع یافته‌اند، اما در مقادیر دبی بالا (بیش از ۱۵-۲۰ لیتر بر ثانیه) انحراف محسوسی به سمت دست‌کم‌برآوردی مشاهده می‌شود و مدل قادر به یادگیری کافی از رویدادهای پیک جریان نیست؛ این موضوع در مجموعه آزمون با وجود دو نقطهٔ پرت بیشتر نمایان است. نمودار ECDF در هر دو مجموعه فاصله‌ای میان منحنی مشاهده‌شده و شبیه‌سازی‌شده را آشکار می‌کند؛ منحنی شبیه‌سازی در مقادیر کم سریع‌تر صعود می‌کند که به معنای کم‌برآوردی فراوانی دبی‌های پایین است، در حالی که در دامنهٔ بالای توزیع کندتر حرکت می‌کند و تأییدکنندهٔ ضعف مدل در بازتولید دبی‌های بالاست. بر اساس یافته‌های یادشده، برای بهبود عملکرد مدل در پیش‌بینی مقادیر حدی، ممکن است نیاز به استفاده از توابع خطای جایگزین یا روش‌های دیگر باشد.

برای بهبود دقت مدل XGBoost در پیش‌بینی دبی قنات، تحلیل حساسیت فراسنجه‌های کلیدی مدل شامل `max_depth`، `learning_rate`، `min_child_weight` و `n_estimators` با روش Cross Validation انجام شد. این یافته‌ها در نمودار تحلیل حساسیت فراسنجه‌های مدل (شکل ۴) به‌وضوح قابل مشاهده است.



شکل ۴. نمودار تحلیل حساسیت فراسنجه‌های مدل Xgboost

از آنجا که در روش تحلیل حساسیت Cross Validation، میزان حساسیت و اثرگذاری هر فراسنجه در دوره‌های آموزش مختلف مورد بررسی قرار می‌گیرد، بررسی نتایج این روش می‌تواند به تعیین محدودهٔ بهینه هر فراسنجه و همچنین، میزان حساسیت مدل نسبت به هر فراسنجه منجر شود. به این‌صورت که پهنای باند در این نمودارها، بیانگر میزان اثرگذاری آن فراسنجه در دوره‌های مختلف (هرچه پهنای باند بیشتر، اثرگذاری بیشتر) و شیب خط موجود در نمودارها بیانگر اثر هر فراسنجه در مقدار متوسط تابع خطا در دوره‌های مختلف است. به بیانی، در محل‌هایی که پهنای باند کم و مقدار تابع خطا در حداقل قرار دارد، می‌تواند محدودهٔ بهینهٔ هر فراسنجه باشد. بنابراین با توجه به شکل ۴، می‌توان گفت که فراسنجه `n_estimate` (تعداد درختان) دارای حساسیت بالا است (پهنای باند بالا) و همچنین از آنجا که در مقدار حد بالای تعیین‌شده (تعداد ۵۰۰ درخت) تابع خطا شیب منفی دارد، نشان می‌دهد این فراسنجه به مقدار بهینه نرسیده و می‌تواند تعداد درختان در فرایند آموزش افزایش یابد. بررسی تحلیل حساسیت فراسنجه `max_depth` نشان می‌دهد مدل در محدودهٔ ۰ تا ۳ به این فراسنجه حساسیت بالا نشان داده

است و همچنین شیب منفی تابع خطا در محدوده ۴ تا ۶ به سمت مثبت میل کرده و از آنجا که در این محدوده پهنای باند نیز در حداقل ممکن است، می‌توان گفت که محدوده بهینه این فراسنجه در بازه مقادیر ۴ تا ۶ قرار دارد. با تحلیل مشابه مشابه فراسنجه Learning_Rate نیز در محدوده ۰ تا ۰/۴ می‌تواند محدوده بهینه این فراسنجه باشد. در بررسی حساسیت فراسنجه min_Child_Weight می‌توان گفت که مدل به این فراسنجه حساسیت بالایی نشان داده و از طرفی شیب خط تابع خطا در محدوده حد بالای تعیین‌شده (مقدار ۱۰) کاهشی است که نشان می‌دهد این فراسنجه به محدوده بهینه نرسیده و همچنان می‌توان برای این فراسنجه در بخش آموزش مقادیر بیشتری را در نظر گرفت.

مقایسه نتایج این پژوهش با مطالعات پیشین بیانگر آن است که مدل XGBoost در برآورد دبی قنوت عملکرد قابل قبولی داشته و یافته‌های آن با بسیاری از پژوهش‌های مشابه در حوزه منابع آب زیرزمینی همخوانی دارد. برای مثال، مقبول و همکاران (۲۰۲۴) نشان دادند XGBoost در پیش‌بینی نوسانات سطح آب زیرزمینی (به‌ویژه در مناطقی با داده‌های بارش) عملکرد دقیقی دارد (Maqbool et al., 2024). همچنین، چادهری و همکاران (۲۰۲۲) نیز تأکید کردند که بهینه‌سازی فراسنجه‌های مدل از جمله نرخ یادگیری و عمق درخت در افزایش دقت مدل مؤثر است، یافته‌ای که در پژوهش حاضر نیز با تحلیل حساسیت به اثبات رسید (Choudhary et al., 2022). به‌علاوه، پژوهش المتوکل و همکاران (۲۰۲۴) به ضعف مدل در پیش‌بینی مقادیر حدی اشاره کرده و پیشنهادهایی در زمینه تغییر توابع خطا ارائه داده است، که این نیز با یافته‌های فعلی تطابق دارد (Elmotawakkil et al., 2024). مطالعات دیگری مانند رزاق و همکاران (۲۰۲۲) و نجف‌زاده و همکاران (۲۰۲۴) نیز تأیید کرده‌اند که XGBoost در برآورد فراسنجه‌های منابع آب زیرزمینی، به‌ویژه زمانی که با داده‌های مکانی و اقلیمی ترکیب می‌شود، توانایی بالایی از خود نشان می‌دهد (Razzagh et al., 2022; Najafzadeh et al., 2024). در نهایت، وانگ و همکاران (۲۰۲۴) و رضوی ترمه و همکاران (۲۰۲۴) نیز عملکرد بالای مدل در محیط‌های خشک را با تأکید بر انتخاب ویژگی‌های ورودی مناسب تأیید کرده‌اند (Wang et al., 2024; Razavi-Termeh et al., 2024)، که مؤید نتایج پژوهش حاضر در منطقه قاین است.

۴. نتیجه‌گیری

پژوهش حاضر با ارزیابی عملکرد مدل XGBoost در پیش‌بینی دبی قنوت دشت قاین، گامی مهم به منظور استفاده از روش‌های یادگیری ماشین برای مدیریت منابع آب در مناطق خشک در مواجهه با چالش‌های تغییر اقلیم برداشت. در شرایطی که تغییر اقلیم به عنوان بزرگ‌ترین تهدید قرن حاضر، بر سیستم‌های آب سنتی مانند قنوت فشار فزاینده‌ای وارد می‌کند، توسعه ابزارهای پیش‌بینی دقیق ضروری است. یافته‌های اصلی این مطالعه نشان داد مدل XGBoost با دقت بالا (مقادیر $R^2 > 0.87$ و $NS > 0.75$) قادر به برآورد دبی قنوت در بازه‌های میانی (۰ تا ۲۰ لیتر بر ثانیه) است و می‌تواند به عنوان ابزاری قابل اعتماد در سازگاری با تأثیرات تغییر اقلیم بر منابع آب زیرزمینی مورد استفاده قرار گیرد. این نتایج، پایداری و قابلیت تعمیم مدل را در شرایط اقلیمی خشک و در حال تغییر تأیید می‌کند. با این حال، کاهش دقت مدل در پیش‌بینی مقادیر حدی (بیش از ۲۰ لیتر بر ثانیه) نشان‌دهنده محدودیت‌های ناشی از تابع خطای RMSE و احتمالاً عدم تعادل در داده‌های آموزشی است که در شرایط تغییر اقلیم و وقوع رخداد‌های حدی اهمیت ویژه‌ای دارد. تحلیل حساسیت فراسنجه‌های مدل نیز نقش کلیدی فراسنجه‌هایی مانند learning_rate و max_depth n_estimators را در بهبود دقت پیش‌بینی آشکار ساخت.

به منظور توسعه و بهبود نتایج این پژوهش در راستای سازگاری با تغییر اقلیم، پیشنهاد می‌شود در تحقیقات آینده از توابع خطای جایگزین مانند میانگین قدر مطلق خطاها^۱ (به‌اختصار MAE) یا تابع زیان^۲ استفاده شود تا سوگیری مدل در پیش‌بینی مقادیر حدی که در شرایط تغییر اقلیم احتمال وقوع بیشتری دارند، کاهش یابد. همچنین، افزایش داده‌های آموزشی در بازه‌های دبی بالا و پایین (رخداد‌های حدی) می‌تواند به بهبود تعادل داده‌ها و در نتیجه افزایش دقت مدل کمک کند. از سوی دیگر، ترکیب مدل XGBoost با سایر الگوریتم‌های یادگیری ماشین مانند ماشین تقویت گرادیان سبک^۳ (به‌اختصار LightGBM) و یا

1. Mean Absolute Error

2. Huber Loss

3. Light Gradient Boosting Machine

روش‌های یادگیری عمیق^۱ می‌تواند به افزایش دقت پیش‌بینی در شرایط پیچیده اقلیمی منجر شود. بررسی تأثیر ویژگی‌های اضافی نظیر کیفیت آب، کاربری اراضی و شاخص‌های خشک‌سالی نیز می‌تواند ابعاد جدیدی از تحلیل را به مدل اضافه کند و عملکرد آن را در پیش‌بینی تأثیرات تغییر اقلیم بهبود بخشد.

این پژوهش نشان داد مدل‌های یادگیری ماشین مانند XGBoost، علی‌رغم چالش‌های موجود، ابزاری کارآمد در مدیریت پایدار منابع آب سنتی مانند قنات در عصر تغییر اقلیم هستند. ادامه این مسیر پژوهشی با تمرکز بر بهبود مدل و تعمیم آن به شرایط متنوع اقلیمی، نه تنها می‌تواند به ارتقای دقت پیش‌بینی‌ها در شرایط عدم قطعیت اقلیمی منجر شود، بلکه راه‌حل‌های علمی و عملی برای مقابله با بحران آب ناشی از تغییر اقلیم در مناطق خشک ارائه خواهد داد. در نهایت، این پژوهش با تلفیق دقت الگوریتم‌های پیشرفته یادگیری ماشین با دانش سنتی مدیریت منابع آب، جایگاه قنات را فراتر از یک سازه مهندسی قدیمی، به عنوان یک «رکن استراتژیک و هوشمند» در سازگاری با تغییر اقلیم تثبیت می‌کند. نتایج به‌دست‌آمده نشان می‌دهد با بهره‌گیری از ابزارهای پیش‌بینی مدرن نظیر XGBoost، می‌توان عدم قطعیت‌های اقلیمی که حیات این سیستم‌های پایدار را تهدید می‌کنند، به طور مؤثری مدیریت کرد. این هم‌افزایی میان سنت و تکنولوژی، نه تنها کارآمدی قنات‌ها را در برابر نوسانات شدید آبی حفظ می‌کند، بلکه این میراث بومی را به بخشی از شبکه تاب‌آوری مدرن در مناطق خشک تبدیل می‌کند؛ به طوری که با پیش‌بینی دقیق‌تر رفتار این سیستم‌ها، می‌توان برنامه‌ریزی‌های کلان برای تضمین امنیت آبی و پایداری زیست‌بوم‌های کویری در عصر تغییر اقلیم را با اطمینان بیشتری پیاده‌سازی کرد.

منابع

1. Samaniego L. Permanent shifts in the global water cycle. *Science*. 2025;387(6741):1348-1350.
2. Ogunrinde AT, Adeyeri OE, Xian X, Yu H, Jing Q, Faloye OT. Long-term spatiotemporal trends in precipitation, temperature, and evapotranspiration across arid Asia and Africa. *Water*. 2024;16(22):3161.
3. Abdelkhalek AM, Awadallah AG, Awadallah NA. Rainfall Extremes Analysis in Arid Regions Under Climate Change: A Structured Review of Methods and Approaches. *Climate*. 2026 May 3;14(5):100.
4. Scanlon BR, Fakhreddine S, Rateb A, de Graaf I, Famiglietti J, Gleeson T, et al. Global water resources and the role of groundwater in a resilient water future. *Nat Rev Earth Environ*. 2023;4(2):87-101.
5. Wang D, Li K, Li H, Zhang Y, Fu T, Sun L, Wang Y, Zhang J. Water resource utilization and future supply-demand scenarios in energy cities of semi-arid regions. *Scientific reports*. 2025 Feb 11;15(1):5005.
6. Granata F, Di Nunno F. Pathways for hydrological resilience: strategies for adaptation in a changing climate. *Earth Systems and Environment*. 2026 Feb;10(1):203-31.
7. Bartlett JA, Dedekorkut-Howes A. Adaptation strategies for climate change impacts on water quality: a systematic review of the literature. *J Water Clim Change*. 2023;14(3):651-675.
8. Hosen N, Nakamura H, Hamzah A. Adaptation to Climate Change: Does Traditional Ecological Knowledge Hold the Key? *Sustainability*. 2020;12(2):676.
9. Akhondi Z, Khayat A, Yaghoobzadeh M. Investigating the Impact of Climate Change on Qanat Discharge: A Case Study of Qanats in Birjand County. *J Aquifer Qanat*. 2026;5(2):1-18. (In Persian with English abstract)
10. Ferdowsi A, Piadeh F, Behzadian K, Mousavi SF, Ehteram M. Urban water infrastructure: A critical review on climate change impacts and adaptation strategies. *Urban Clim*. 2024;58:102132.
11. Agricultural Research, Education, and Extension Organization. Research on groundwater resources management in Iran (Report No. 1401). Tehran, Iran: Agricultural Research, Education and Extension Organization; 2022.
12. Ministry of Energy, Office of Basic Water Studies. Annual report on the status of qanats in Iran (Report No. 1402). Tehran, Iran: Ministry of Energy; 2023.
13. Foruzanmehr M, Khozaymehnezhad H. Investigation of spatial and temporal changes of qualitative parameters of Qaen plain aquifer using interpolation methods. *J Aquifer Qanat*. 2023;4(1):1-15. (In Persian with English abstract)
14. Hosseini Fahraji RS, Sharifzadeh M. Qanat maintenance from key informants' viewpoint: A qualitative research in Taft County. *J Community Dev (Rural-Urban)*. 2016;8(2):295-312. (In Persian with English abstract)
15. Niazkar M, Menapace A, Brentan B, Piraei R, Jimenez D, Dhawan P, Righetti M. Applications of XGBoost in water resources engineering: A systematic literature review (Dec 2018–May 2023). *Environ Model Softw*. 2024;174:105971.
16. Samani S, Vadiati M, Kisi O, Ghasemi L, Farajzadeh R. Qanat discharge prediction using a comparative analysis of machine learning methods. *Earth Sci Inform*. 2024;17(5):4597-4618.
17. Piraei R, Afzali SH, Niazkar M. Assessment of XGBoost to estimate total sediment loads in rivers. *Water Resour Manag*. 2023;37(13):5289-5306.
18. Safira RAD, Anjasmara IM, Awange JL. Predictive Modeling of Terrestrial Water Storage Anomalies in Kalimantan Basins: Bridging the GRACE and GRACE-FO Data Gap with Extreme Gradient Boosting. *GEOID*. 2024;19(3):508-518.
19. Kosravi S, Khozimeh Nejad H, Khayat A, Akhoondi Z. Forecasting the water level of Baldeh Qanat in Ferdows Using Time Series Methods. *J Aquifer Qanat*. 2026;5(2):189-202. (In Persian with English abstract)
20. Jiang X, Fan C, Liu K, Chen T, Cao Z, Song C. Centenary covariations of water salinity and storage of the largest lake of Northwest China reconstructed by machine learning. *J Hydrol*. 2022;612:128095.

21. Wu J, Ma D, Wang W. Leakage identification in water distribution networks based on XGBoost algorithm. *J Water Resour Plan Manag.* 2022;148(3):04021107.
22. Zhou S, Liu Z, Wang M, Gan W, Zhao Z, Wu Z. Impacts of building configurations on urban stormwater management at a block scale using XGBoost. *Sustain Cities Soc.* 2022;87:104235.
23. Ali S, Khorrami B, Jehanzaib M, Tariq A, Ajmal M, Arshad A, et al. Spatial downscaling of GRACE data based on XGBoost model for improved understanding of hydrological droughts in the Indus Basin Irrigation System (IBIS). *Remote Sens.* 2023;15(4):873.
24. Zhang T, Wang Z, Huang L, He L, Yao C. A novel XGBoost-based approach for reconstruction terrestrial water storage variations with GNSS in the Northeastern Tibetan Plateau. *J Hydrol.* 2025;659:133255.
25. Dastourani M, Mamirabadizadeh M, Mohammadie K. The Impact Assessment of Changes in Agricultural Cropping Patterns on the Quantitative Status of Groundwater Resources in the Qaen Plain Aquifer Using the MODFLOW Model. *Iran J Irrig Drain.* 2025;e223369. (In Persian with English abstract)
26. Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*; 2016 Aug 13-17; San Francisco, CA. New York: ACM; 2016. p. 785-794.
27. Knoben WJ, Freer JE, Woods RA. Inherent benchmark or not? Comparing Nash–Sutcliffe and Kling–Gupta efficiency scores. *Hydrol Earth Syst Sci.* 2019;23(10):4323-4331.
28. Falah F, Tahmasbipour N. Identification of outliers in flood data analysis using range and statistical methods. In: *Proceedings of the 2nd National Conference on Hydrology of Iran*; 2017; (location unknown). (publisher unknown); 2017.
29. Mohammadi M. Statistics and its applications in experimental sciences. Tehran, Iran: Daneshgah Publishing; 2016. (In Persian with English abstract)
30. Karimi M, Hosseini A. Time series analysis and its applications in engineering. Tehran, Iran: Daneshgah Publishing; 2015. (In Persian with English abstract)
31. Willmott CJ, Matsuura K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Clim Res.* 2005;30(1):79-82.
32. Samantaray S, Sahoo A, Yaseen ZM, Al-Suwaiyan MS. River discharge prediction based multivariate climatological variables using hybridized long short-term memory with nature inspired algorithm. *Journal of Hydrology.* 2025 Mar 1;649:132453
33. Ebrahimzadeh Z, Abdollahi K, Bidaki RZ, Eslamian S. A comparative analysis of machine learning models for predicting groundwater and surface water in a stressed semi-arid watershed: The Khanmirza case study. *Environmental Earth Sciences.* 2026 Mar 17;85(7):159.
34. Gupta HV, Kling H, Yilmaz KK, Martinez GF. Decomposition of the mean squared error and NSE performance metrics: Implications for improving hydrological modelling. *J Hydrol.* 2009;377(1-2):80-91.