

## Evaluation of the intelligent model (Cat-XG)boost for runoff prediction, case study: Karaj Watershed

Ramtin Tavoosi Rad<sup>1</sup>, Mohammad Ansari ghoghhar<sup>2\*</sup> and Arash Malekian<sup>3</sup>

<sup>1</sup> Master Candidate, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran

<sup>2</sup> Corresponding Author, Assistant Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran

<sup>3</sup> Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran

Received: 10 January 2026

Accepted: 09 May 2026

### Extended abstract

#### Introduction

Accurate runoff prediction plays a crucial role in water resource management, flood control and climate change adaptation planning. Given the nonlinear, complex and multifactorial nature of hydrological processes, the use of data-driven methods and machine learning algorithms has become an efficient approach for runoff analysis and modeling in recent years. Two individual models, XGBoost, CatBoost and a hybrid model of this two single models, (Cat-XG)Boost were evaluated to predict runoff in the Karaj watershed. Few studies have compared these two algorithms and presented an intelligent hybrid combination at the monthly level. While filling this research gap the present study can provide practical guidance for water resource planners and resource management warning systems in climate change conditions.

#### Materials and method

In the present study, the efficiency of two widely used individual deep learning models, including CatBoost, XGBoost and a novel hybrid model called (Cat-XG)Boost were evaluated in predicting monthly runoff in the Karaj watershed. For this purpose, monthly average discharge data from five hydrometric stations of Gachsara, Sira-Kaloan, Sira-Karaj, Neshtarud and Pol-e-Khab Dorud with maximum monthly average discharge of 17.22, 16.56, 12.11, 0.36 and 0.28, respectively, in the Karaj watershed during the long-term statistical period of 30 years (1371-1400) were used as model inputs. After performing preprocessing, normalization, outlier removal, stationarity check and input transformation processes, the models were used as inputs. The models were measured with 4 evaluation criteria NS, R, RMSE and MAE. The predictions of the studied models were recorded in 4 states. First, the average discharge of the past 3 months was considered as the model input. In the second scenario, the average discharge of the 6 months before was entered into the model. The third scenario was designed using three consecutive delay seasons (9 months) of monthly average discharge. The fourth scenario included a year of consecutive time lag.

#### Results and discussion

The prediction results showed that the hybrid model (Cat-XG)Boost with a significant difference provides the best performance in predicting monthly runoff of the Karaj watershed compared to the two individual models evaluated. This model recorded NS above 0.957 and correlation above 0.939 in all stations studied. In addition, it recorded significantly fewer errors than the other two models. While the individual models XGBoost and CatBoost, especially in stations with more extensive data, faced increased errors. Analysis of correlation diagrams also showed that the integrated model had the highest agreement with the actual values and identified complex runoff patterns with higher accuracy. The results obtained from the present study were also consistent with international studies. The two individual models studied provided average performance in predicting values related to extreme climate events but by combining the two individual models and introducing the hybrid model Boost(Cat-XG), the defects in the individual models were covered and also by eliminating existing errors, much more accurate predictions were recorded.

\* Corresponding author: ansari.ghoghhar@ut.ac.ir

## Conclusion

The results of the present study indicate that the hybrid model (Cat-XG)Boost can be used as a powerful tool for runoff prediction in mountainous and climate change-sensitive basins and play an effective role in the development of rapid warning systems, reservoir management and strategic water resource planning. The findings of the present study confirm that combined approaches in the face of complex hydrological data have a significant advantage over single models. This model can be used as a useful tool in water resource management studies, prediction of drought and seasonal floods and presentation of decision-making scenarios at the basin level.

**Keywords:** Flood control, Deep learning, Metaheuristic algorithm, Mountainous basins, Water resource management

Cite this article: Tavoosi Rad, R., Ansari ghoghghar, M., Malekian, A., 2026. Evaluation of the intelligent model (Cat-XG)boost for runoff prediction, case study: Karaj Watershed. Water. Eng. Manag.18(3), 420-438.

© 2026, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



## ارزیابی مدل تلفیقی هوشمند Boost (Cat-XG) به منظور پیش‌بینی رواناب مطالعه موردی: حوزه آبخیز کرج

رامتین طاوسی راد<sup>۱</sup>، محمد انصاری قوجقار<sup>۲\*</sup> و آرش ملکیان<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

<sup>۲</sup> استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

<sup>۳</sup> استاد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

تاریخ پذیرش: ۱۴۰۵/۰۲/۱۹

تاریخ دریافت: ۱۴۰۴/۱۰/۲۰

### چکیده مبسوط

#### مقدمه

پیش‌بینی دقیق رواناب نقش اساسی در مدیریت منابع آب، کنترل سیلاب و برنامه‌ریزی سازگاری با تغییر اقلیم دارد. با توجه به ماهیت غیرخطی، پیچیده و چندعاملی فرایندهای هیدرولوژیک، استفاده از روش‌های داده‌محور و الگوریتم‌های یادگیری ماشین در سال‌های اخیر به رویکردی کارآمد برای تحلیل و مدلسازی رواناب تبدیل شده است. دو مدل انفرادی CatBoost، XGBoost و مدل هیبریدی Boost (Cat-XG) به منظور پیش‌بینی رواناب حوزه آبخیز کرج مورد ارزیابی قرار گرفتند. مطالعات اندکی به مقایسه این دو الگوریتم و ارائه یک ترکیب هیبریدی هوشمند در سطح ماهانه پرداخته‌اند. پژوهش حاضر ضمن پر کردن این شکاف پژوهشی می‌تواند راهنمایی عملی برای برنامه‌ریزان منابع آب و سامانه‌های هشدار مدیریت منابع در شرایط تغییر اقلیم فراهم کند.

### مواد و روش‌ها

در پژوهش حاضر، کارایی دو مدل پرکاربرد انفرادی یادگیری عمیق شامل CatBoost، XGBoost و یک مدل هیبریدی نوین تحت عنوان Boost (Cat-XG) در پیش‌بینی رواناب ماهانه حوزه آبخیز کرج ارزیابی شد. برای این منظور، داده‌های دبی متوسط ماهانه پنج ایستگاه هیدرومتری گچسر، سیرا-کلوان، سیرا-کرج، نشتارود و پل خواب در دوره به‌ترتیب میانگین دبی بیشینه ماهانه ۱۷/۲۲، ۱۶/۵۶، ۱۲/۱۱، ۰/۳۶ و ۰/۲۸ در حوزه آبخیز کرج طی دوره آماری بلندمدت ۳۰ ساله (۱۴۰۰-۱۳۷۱) به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفت. را به ثبت رساندند. پس از انجام فرایندهای پیش‌پردازش، نرمال‌سازی، حذف داده‌های پرت، بررسی ایستایی و تبدیل ورودی‌ها به‌عنوان ورودی، مدل‌ها مورد استفاده قرار گرفت. مدل‌ها با ۴ معیار ارزیابی NS، R، RMSE و MAE سنجیده شدند. پیش‌بینی‌های مدل‌های مورد پژوهش در چهار حالت به ثبت رسید. حالت نخست، دبی متوسط سه ماه گذشته به‌عنوان ورودی مدل در نظر گرفته شد. در سناریوی دوم، دبی متوسط شش ماه قبل وارد مدل شد. سناریوی سوم با استفاده از سه فصل تأخیر متوالی (نه ماه) دبی متوسط ماهانه طراحی شد. سناریوی چهارم شامل یک سال وقفه زمانی متوالی بوده است.

\* مسئول مکاتبات: ansari.ghojghar@ut.ac.ir

## نتایج و بحث

نتایج پیش‌بینی‌ها نشان داد که مدل هیبریدی (Cat-XG)Boost با اختلاف قابل توجهی بهترین عملکرد را در پیش‌بینی رواناب ماهانه حوزه آبخیز کرج نسبت به دو مدل انفرادی مورد ارزیابی ارائه می‌دهد. این مدل در تمامی ایستگاه‌های مورد بررسی NS بالای ۰/۹۵۷، همبستگی بالای ۰/۹۳۹ به ثبت رساند. همچنین این مدل با اختلاف بسیار، خطاهای کمتری نسبت به دو مدل دیگر ثبت کرد. مقدار RMSE به ثبت رسیده برای این مدل در ایستگاه‌های با مقدار داده‌های فراوان‌تر نسبت به سایر ایستگاه‌ها، بیشتر بوده و بین اعداد ۱/۰۵۷ و ۱/۵۱۷ قرار دارد. مقدار خطاهای ثبت شده به نسبت دو مدل دیگر که خطاهای بالای پنج را ثبت نمودند، عملکرد مثبت مدل هیبریدی پیشنهادی را نشان می‌دهد. اما در ایستگاه‌های با داده‌های کمتر، مقادیر کمی از خطا و در محدوده‌های ۰/۰۲۷ تا ۰/۰۳۷ برآورد شده است. همچنین مقادیر MAE ثبت شده برای مدل هیبریدی پیشنهادی نشان می‌دهد که مقادیر به دست آمده مشابه مقادیر محاسبه شده برای RMSE، بین محدوده ۰/۰۹ برای ایستگاه‌های با مقدار داده‌های ثبت شده کمتر و ۱/۴۵۴ برای ایستگاه‌های با مقدار داده ثبت شده بیشتر محاسبه شده است. در حالی که مدل‌های انفرادی XGBoost و CatBoost به‌ویژه در ایستگاه‌های با داده‌های گسترده‌تر با افزایش خطا به مقدار بالای هفت مواجه شدند. تحلیل نمودارهای همبستگی نیز نشان داد که مدل تلفیقی بیش‌ترین انطباق را با مقادیر واقعی داشته و الگوهای پیچیده رواناب را با دقت بالاتری مورد شناسایی قرار داده است. نتایج به دست آمده از پژوهش حاضر با مطالعات بین‌المللی نیز همخوانی داشت. دو مدل انفرادی مورد پژوهش عملکرد متوسط در پیش‌بینی مقادیر مرتبط با وقایع حدی اقلیمی ارائه کردند اما با ترکیب دو مدل انفرادی و معرفی مدل هیبریدی (Cat-XG)Boost، عیوب موجود در مدل‌های انفرادی پوشیده شده و همچنین با رفع خطاهای موجود، پیش‌بینی‌های بسیار دقیق‌تری به ثبت رسید.

## نتیجه‌گیری

نتایج پژوهش حاضر بیان‌گر آن است که مدل هیبریدی (Cat-XG)Boost می‌تواند به‌عنوان ابزاری قدرتمند برای پیش‌بینی رواناب در حوضه‌های کوهستانی و حساس به تغییر اقلیم به کار گرفته شود و به‌منظور توسعه سامانه‌های هشدار سریع، مدیریت مخازن و برنامه‌ریزی راهبردی منابع آب نقش مؤثری ایفاء کند. نتایج به دست آمده نشان داد که مدل هیبریدی پیشنهادی، بهترین خروجی‌ها را به ثبت رساند. در تمامی ایستگاه‌های مورد مطالعه، مقدار NS بالای ۰/۹۵۱ و همبستگی بالای ۰/۹۳۹ ثبت شد. همچنین، این مدل به‌طور محسوسی، مقادیر خطای MAE و RMSE را کاهش داد. در سه ایستگاه گچسر، سیرا-کلون و سیرا کرج که بیشترین مقادیر داده‌ای را دارا بودند، خطای بیشتری به نسبت سه ایستگاه دیگر به ثبت رسید. خطای ثبت شده بالاتر سه ایستگاه ذکر شده به دلیل میزان بالاتر نوسانات دبی بیشینه ماهانه این ایستگاه‌ها بوده که باعث ثبت خطاها در اعداد بزرگ‌تر شده است. یافته‌های پژوهش حاضر تأیید می‌کند که رویکردهای ترکیبی در مواجهه با داده‌های پیچیده هیدرولوژیک، مزیت قابل توجهی نسبت به مدل‌های انفرادی دارند. از این مدل می‌توان به‌عنوان ابزاری سودمند در مطالعات مدیریت منابع آب، پیش‌بینی خشکسالی و سیلاب‌های فصلی و ارائه سناریوهای تصمیم‌گیری در سطوح حوضه‌ای مورد استفاده نمود.

**واژه‌های کلیدی:** الگوریتم فراکاوشی، حوضه‌های کوهستانی، کنترل سیلاب، مدیریت منابع آب، یادگیری عمیق

## مقدمه

باشد، بخشی از آب ناشی از باندگی در سطح حوضه باقی می‌ماند (Panjekoi et al., 2018). بررسی‌های انجام شده نشان می‌دهد، کمترین تغییر در میزان بارش و درجه حرارت می‌تواند باعث کاهش یا افزایش رواناب‌های فصلی، سالیانه، سیلاب‌ها و خشکسالی‌های

رواناب به‌عنوان یکی از مؤلفه‌های بیلان آب حوضه، اهمیت زیادی در آبخیزداری و مدیریت منابع آب دارد. بحث رواناب و رابطه بارندگی-رواناب از مهم‌ترین موضوعات در هیدرولوژی آب‌های سطحی است. هرگاه شدت بارش از ظرفیت نفوذ آب به داخل خاک بی‌تر

زودرس شده و در نتیجه سیستم‌های آبی را دچار چالش می‌کند.

لذا تحقیق در این زمینه ضروری است. با توجه به کاربردهای وسیع مدل‌های شبکه عصبی مصنوعی به‌منظور تخمین پارامترهای گوناگون در زمینه‌های متفاوت و علوم مختلف، در سال‌های اخیر از این ابزار قدرتمند در علم آب و تخمین رواناب سطحی نیز استفاده شده است (Aghajanzadeh Sareskanroud et al., 2019). مدل‌های هوش مصنوعی با توانایی خود در شناسایی الگوهای پیچیده و غیرخطی در داده‌ها به مهندسان این امکان را می‌دهند تا پارامترهای ژئوتکنیکی را با دقت بیشتری نسبت به روش‌های سنتی تخمین بزنند. کاربرد هوش مصنوعی در این حوضه، پروژه‌های مهندسی را به سمت طراحی‌های بهینه، تحلیل ریسک دقیق‌تر و کاهش تأثیرات زیست محیطی هدایت کرده است. این تکنیک‌ها در پیش‌بینی رواناب، مدلسازی سطح آب زیرزمینی، تحلیل پایداری شیب‌ها و طبقه‌بندی توده سنگ با موفقیت به کار رفته‌اند (Mirzahoseini, 2025).

توسعه مدل‌های داده‌محور، دقت پیش‌بینی جریان رودخانه را به میزان قابل‌توجهی افزایش داده است. داده‌های موجود در مجموعه داده‌های جریان رودخانه تاریخی با استفاده از روش‌های محاسباتی مبتنی بر یادگیری ماشین<sup>۱</sup> و هوش مصنوعی<sup>۲</sup> برای تشخیص الگوها و همبستگی‌ها مورد مطالعه قرار می‌گیرند. در نتیجه دقت بالاتر پیش‌بینی جریان ورودی، روش‌های یادگیری ماشین می‌توانند منجر به تصمیم‌گیری آگاهانه‌تر در مدیریت منابع آب شوند (Majdar et al., 2025).

تقویت گرادیان یک تکنیک قدرتمند یادگیری ماشین است که در طیف وسیعی از وظایف عملی به نتایج پیشرفته‌ای دست می‌یابد. این روش به‌منظور یادگیری مسائلی با ویژگی‌های ناهمگن، داده‌های نویزی و وابستگی‌های پیچیده ارائه شده است. تقویت گرادیان اساساً فرایندی برای ساخت یک پیش‌بینی‌کننده گروهی با انجام گرادیان نزولی در یک فضای تابعی است. این روش با نتایج نظری محکمی پشتیبانی می‌شود که

توضیح می‌دهند چگونه می‌توان پیش‌بینی‌کننده‌های قوی را با ترکیب مکرر مدل‌های ضعیف‌تر ساخت (Prokhorenkova et al., 2018). مدل XGBoost<sup>۳</sup> یک الگوریتم تقویت گرادیان قدرتمند است که در مدلسازی روابط غیرخطی عالی عمل می‌کند و به دلیل بهینه‌سازی پیشرفته و توانایی‌اش در مدیریت داده‌های ساختاریافته در پیش‌بینی سری‌های زمانی به‌ویژه با متغیرهای تأخیری، عملکرد فوق‌العاده‌ای دارد (Hameed et al., 2025).

علاوه بر این، سرعت بالا و کارایی محاسباتی این روش را برای کاربردهای بلادرنگ مانند توسعه سیستم‌های هشدار ایده‌آل می‌سازد. در مجموع این مزایا به بهبود مدیریت بحران، کاهش خسارات زیست‌محیطی و اقتصادی و تدوین سیاست‌های مؤثرتر برای مقابله با طوفان‌های گرد و غبار منجر می‌شود (Ansari ghoghghar and Pourmohammad, 2025). پژوهش‌های گذشته از مدل XGBoost به‌منظور برآورد دقت پیش‌بینی رواناب استفاده به‌عمل آمده است. Niazkar et al., (2024) به بررسی تأثیر مدل‌های یادگیری ماشین در بهبود نتایج پیش‌بینی رواناب و جریان رودخانه پرداختند. نتایج این پژوهش نشان داد که استفاده از مدل XGBoost به‌طور چشم‌گیری دقت برآوردها را افزایش می‌دهد.

این رویکردها علاوه بر بهبود دقت، امکان ادغام داده‌های متنوع فضایی-زمانی و بهره‌مندی از روش‌های تبیینی را فراهم می‌آورند که به فهم بهتر عوامل موثر در تولید رواناب کمک می‌کند. مطالعه Ni et al., (2020) نشان داد که XGBoost در مقایسه با روش‌های عصبی مصنوعی و برخی مدل‌های درختی دیگر، عملکرد برتری در پیش‌بینی جریان‌های روزانه تا ماهانه دارد و در شبیه‌سازی نقاط اوج و کف جریان نیز اغلب نتایج قابل‌اطمینانی ارائه می‌کند. علاوه بر این، XGBoost به خوبی با داده‌های دارای تأخیر زمانی کار می‌کند که برای مدلسازی سری‌های زمانی هیدرولوژیک حیاتی است.

مدل CatBoost<sup>۴</sup> مبتنی بر درخت‌های تصمیم افزایشی گرادیان است که در آن مجموعه‌ای از

<sup>3</sup> Extreme Gradient Boosting

<sup>4</sup> Categorical Boosting

<sup>1</sup> Machine Learning (ML)

<sup>2</sup> Artificial Intelligence (AI)

واقع شده و بین طول‌های جغرافیایی حدود  $51^{\circ} 00'$  تا  $51^{\circ} 25'$  شرقی و عرض‌های جغرافیایی  $35^{\circ} 48'$  تا  $36^{\circ} 12'$  شمالی گسترده شده است. این حوضه با وسعت تقریبی ۷۰۰ تا ۸۰۰ کیلومترمربع، یکی از حوضه‌های حیاتی تأمین‌کننده آب شرب، کشاورزی و نیازهای صنعتی استان‌های تهران و البرز به‌شمار می‌رود. حوزه آبخیز کرج تأمین‌کننده بخش مهمی از آب شرب و مصرف شهری صنعتی برای مناطق کرج و تهران است. همین امر اهمیت این حوضه را برای مطالعات هیدرولوژیک، برنامه‌ریزی منابع آب و مدیریت بحران آب دوچندان می‌کند (Alipour and Hosseini, 2018). در پژوهش حاضر به‌منظور ارزیابی عملکرد مدل‌های یادگیری ماشین در پیش‌بینی رواناب از مدل‌های انفرادی XGBoost، CatBoost و مدل هیبریدی Boost (Cat-XG) استفاده شد. داده‌های دبی متوسط ماهانه مربوط به پنج ایستگاه هیدرومتری فعال در محدوده حوزه آبخیز کرج طی دوره ۳۰ ساله (۱۴۰۰-۱۳۷۱) جمع‌آوری شد. پنج ایستگاه هیدرومتری گچسر، سیرا-کلون، سیرا-کرج، نشتارود و پل خواب-دورود به‌ترتیب میانگین دبی بیشینه ماهانه ۱۷/۲۲، ۱۶/۵۶، ۱۲/۱۱، ۰/۳۶ و ۰/۲۸ را به ثبت رساندند و در شکل ۲ مشخص شده‌اند. شکل ۱ موقعیت جغرافیایی ایستگاه‌های مورد مطالعه را نشان می‌دهد. پس از انجام فرایندهای پیش‌پردازش، نرمال‌سازی، حذف داده‌های پرت، بررسی ایستایی و تبدیل ورودی‌ها به‌عنوان ورودی، مدل‌ها مورد استفاده قرار گرفت. سپس بخشی از مجموعه داده برای آموزش مدل و قسمت باقیمانده برای ارزیابی عملکرد آن استفاده شد. داده‌های آموزشی ۸۰ درصد از مجموعه داده را تشکیل می‌دهند. در حالی که داده‌های آزمایشی شامل ۲۰ درصد از کل نمونه‌ها هستند. الگوریتم‌های CatBoost و XGBoost به‌عنوان مدل‌های مستقل در طول فاز اولیه توسعه مدل مورد بررسی قرار گرفتند. در نهایت، معیارهای ارزیابی استاندارد مانند RMSE، MAE و R برای اندازه‌گیری قابلیت پیش‌بینی مدل به‌کار گرفته شدند. ساختار کلی مدل استفاده شده و روش‌شناسی مطالعه در شکل ۵ به‌صورت یک نمودار جریان به تصویر کشیده شده است. تمامی مراحل مدل‌سازی، آموزش، تنظیم پارامترها و ارزیابی با استفاده

درخت‌های تصمیم به‌صورت متوالی در طول آموزش ساخته می‌شوند. هر درخت متوالی با کاهش تلفات در مقایسه با درخت‌های قبلی ساخته می‌شود (Shaw, 2023). الگوریتم CatBoost همچنین دارای طرحی است که در برابر مدل‌سازی متغیرهای دسته‌بندی شده مقاوم است. استفاده از داده‌های عددی خارجی منطبق با متغیر دسته‌بندی شده Residence\_PUMA به‌عنوان استراتژی دیگری برای مدل‌سازی متغیرهای دسته‌بندی شده است (Guerrera and Rieksts, 2022). پژوهش Kumar et al., (2023) نشان داد که CatBoost در برخی حوضه‌ها با توجه به نحوه مدیریت متغیرهای زمانی و ویژگی‌سازی فصلی از نظر معیارهایی مانند RMSE و همبستگی از XGBoost و سایر الگوریتم‌ها بهتر عمل کرده است. رویکردهای هیبریدی و تلفیق الگوریتم‌ها برای افزایش پایداری و انتقال‌پذیری پیش‌بینی‌ها رو به افزایش است. مطالعات مختلف نشان داده‌اند که با استفاده از چارچوب‌های هیبریدی می‌توان دقت پیش‌بینی را افزایش داد. این نتایج نشان می‌دهد که ترکیب دو الگوریتم قدرتمند تقویتی می‌تواند مزیت‌های هر مدل را هم‌زمان ارائه داده و نقص آنها را پوشش دهد (Wang and Peng, 2024).


با وجود رشد سریع کاربرد مدل‌های XGBoost و CatBoost در هیدرولوژی، تعداد مطالعاتی که مستقیماً به مقایسه این دو الگوریتم و ارائه یک ترکیب هیبریدی هوشمند در سطح ماهانه پرداخته باشند، خصوصاً برای حوضه‌های با ویژگی‌های اقلیمی و مدیریتی همانند حوضه کرج، محدود است. مطالعات قبلی صرفاً به مقایسه مدل‌های منفرد پرداخته و یا مدل‌های هیبریدی به‌کار گرفته‌اند که یکی از آنها فیزیکی است؛ اما ترکیب مستقیم دو الگوریتم کمتر مطالعه شده است. مقایسه مدل‌های CatBoost، XGBoost و ارائه یک مدل هیبریدی تحت عنوان Boost (Cat-XG) ضمن پر کردن این شکاف پژوهشی می‌تواند راهنمایی عملی برای برنامه‌ریزان منابع آب و سامانه‌های هشدار مدیریت منابع در شرایط تغییر اقلیم فراهم کند.

## مواد و روش‌ها


**منطقه مورد مطالعه:** حوزه آبخیز کرج در بخش جنوب‌غربی رشته‌کوه البرز و شمال‌غرب استان تهران

حوضه و شناسایی مناسب‌ترین مدل برای پیش‌بینی  
آبدهی جریان را فراهم ساخت.

از محیط‌های نرم‌افزاری R انجام شد. این رویکرد امکان  
مقایسه دقیق عملکرد مدل‌ها در شبیه‌سازی رواناب



شکل ۱- موقعیت منطقه مورد مطالعه  
Fig. 1. Geographical location of the studied stations



شکل ۲- ایستگاه‌های مورد مطالعه  
Fig. 2. distribution of the studied stations

این مدل با بهینه‌سازی‌های خاص مانند یادگیری  
موازی، الگوریتمی مقاوم به داده‌های پراکنده و استفاده  
از تکنیک‌هایی برای کاهش مصرف حافظه و سرعت بالا  
طراحی شده است. به همین منظور برای داده‌های  
طبقه‌بندی شده با تعداد نمونه یا متغیر زیاد بسیار  
مناسب است (Chen and Guestrin, 2016). همچنین  
به دلیل سرعت، قابلیت مقیاس‌پذیری و دقت بالا، مدل

**مدل XGBoost:** مدل XGBoost یک نسخه پیچیده از  
تکنیک‌های تقویت گرادیان است که برای کارایی  
محاسباتی و اثربخشی مدل بهبود یافته است. این روش  
از یک چارچوب تقویت گرادیان استفاده می‌کند که  
مدل‌های افزایشی را به صورت متوالی می‌سازد و  
بهینه‌سازی هرگونه تابع مشتق‌پذیر را تسهیل می‌کند  
(Levent et al., 2025).


$$obj = \sum_{i=1}^n l(y_i, \hat{y}_i^{(s)}) + \sum_{i=1}^s \omega(f_i) \quad (2)$$

که در آن،  $\hat{y}_i^{(s)}$  مقدار پیش‌بینی در مرحله  $s$  و  $\omega(f_i)$  پیچیدگی درخت است. این تابع هدف از دو بخش تشکیل شده است. بخش اول، تابع زیان است که توصیف می‌کند، مدل چقدر خوب با داده‌ها مطابقت دارد و بخش دوم مربوط به پیچیدگی مدل است که جریمه‌ای برای بیش‌برازش در نظر می‌گیرد (Sadeghramoghaddam, 2022).

XGBoost در مسائل رگرسیونی، طبقه‌بندی و پیش‌بینی سری‌زمانی به‌طور گسترده استفاده می‌شود (Szczeplonek, 2022). فرم ساده‌شده از مدل XGBoost به‌صورت رابطه (۱) بیان شده است.

$$\hat{y}_i = \sum_{k=1}^K f_k(X_i) \quad f_k \in F \quad (1)$$

که در آن،  $K$  تعداد درختان،  $f_k$  یک تابع در فضای گسترده  $F$  و  $F$  مجموعه تمام درختان ممکن است. تابع هدف که XGBoost سعی در مینیمم کردن آن دارد، در رابطه (۲) نشان داده شده است.



شکل ۳- مدل XGBoost (Sadeghramoghaddam, 2022)

Fig. 3. XGboost model (Sadeghramoghaddam, 2022)

$$t_k = \operatorname{argmin}_{EL}(y, F_{k-1}(x) + t(x)) \quad (3)$$

که در آن،  $(x, y)$  نمونه‌های آزمایشی مستقل از مجموعه آموزش هستند. GBDT از گرادین منفی تابع زیان برای برازش درخت تصمیم CART آموزش داده شده  $t_k$  استفاده می‌کند و مدل نهایی  $M$  که در رابطه (۴) نشان داده شده است از یادگیرنده ضعیف اولیه  $M_0$  و مرحله آموزش  $n$  ام با اندازه گام  $a_n$  پس از  $N$  تکرار به‌دست می‌آید.

$$M = M_0 + \sum_{k=1}^N a_n t_k \quad (4)$$

این الگوریتم با معرفی بوستینگ ترتیبی<sup>۷</sup>، اثر نویز داده‌ها و مشکل جابه‌جایی پیش‌بینی را کاهش داده و پایداری مدل را به‌طور چشم‌گیری افزایش می‌دهد. همچنین بهره‌گیری از درخت‌های کاملاً متقارن به‌عنوان مدل پایه، علاوه بر پایداری ساختاری موجب سرعت بالاتر در مرحله پیش‌بینی شده و اجرای مدل را

**مدل CatBoost:** مدل CatBoost یک چارچوب

تقویت‌گرادیان بر پایه درخت تصمیم (GBDT)<sup>۸</sup> مبتنی بر مدل درخت تصمیم متقارن است که مزایای پشتیبانی از متغیرهای دسته‌ای، وابستگی کم به ابرپارامتر و دقت بالا را داراست (Liu et al., 2024). تفاوت مدل CatBoost نسبت به XGBoost در بومی‌سازی متغیرهای دسته‌ای<sup>۹</sup> است. به این معنی که قبل از انجام مدل‌سازی، تبدیل ویژگی‌های دسته‌ای به عدد نیاز نیست. این موضوع پیش‌پردازش را دقیق‌تر می‌کند (Prokhorenkova et al., 2018).

یادگیرنده قوی تولید شده پس از آموزش  $F_{k-1}$  است و هدف آموزشی در دور بعدی به‌دست آوردن یک درخت  $t_k$  از مجموعه درخت تصمیم CARAT، برای کمینه کردن امید ریاضی  $E()$  تابع زیان  $L()$  است. پارامتر  $t_k$  به‌صورت رابطه (۳) محاسبه می‌شود.

<sup>7</sup> Ordered Boosting

<sup>5</sup> Gradient-boosted decision trees

<sup>6</sup> Categorical features

بوستینگ ارائه دهد (Wang and Qian, 2023). در جدول ۲، مقادیر ابرپارامترهای مورد استفاده در مدل‌های حاضر به‌منظور پیش‌بینی سیلاب مشخص شده است.

در کاربردهای عملی بهینه می‌سازد. مجموعه این نوآوری‌ها باعث شده است که مدل CatBoost در بسیاری از مسائل پیش‌بینی به‌ویژه در داده‌های غیریکنواخت و پیچیده، عملکردی دقیق‌تر و قابل‌اعتمادتر نسبت به بسیاری از الگوریتم‌های

جدول ۱- مقادیر ابرپارامترهای مورد استفاده در مدل‌ها

Table 1. Hyperparameter values used in models

| Station             | Model  | $\phi_1$ | $\phi_2$ | $\theta_1$ | $\theta_2$ | $Q_0$ | $\lambda^2$ | Epochs | LR     |
|---------------------|--------|----------|----------|------------|------------|-------|-------------|--------|--------|
| Gachsar             | XG     | 0.5163   | 0.3341   | 0.3761     | 0.3952     | 2.57  | 17          | 56     | 0.0431 |
|                     | CAT    | 0.5194   | 0.3145   | 0.3952     | 0.3881     | 2.12  | 21          | 61     | 0.0651 |
|                     | CAT-XG | 0.5671   | 0.3453   | 0.2831     | 0.4113     | 2.03  | 24          | 93     | 0.0631 |
|                     | XG     | 0.5241   | 0.3641   | 0.2742     | 0.4011     | 2.93  | 13          | 121    | 0.0328 |
| Sira-Kalvan         | CAT    | 0.5306   | 0.3448   | 0.3456     | 0.4116     | 2.81  | 18          | 128    | 0.0617 |
|                     | CAT-XG | 0.5021   | 0.3652   | 0.2776     | 0.4017     | 2.03  | 31          | 133    | 0.0713 |
|                     | XG     | 0.5312   | 0.3021   | 0.2331     | 0.4112     | 2.42  | 32          | 132    | 0.0610 |
| Sira-Karaj          | CAT    | 0.5149   | 0.3112   | 0.2456     | 0.3983     | 3.51  | 17          | 143    | 0.0614 |
|                     | CAT-XG | 0.5223   | 0.3342   | 0.3652     | 0.4323     | 3.66  | 16          | 157    | 0.0713 |
|                     | XG     | 0.5661   | 0.3341   | 0.3841     | 0.4467     | 3.03  | 14          | 181    | 0.0619 |
| Pol khab-Nashtaroud | CAT    | 0.5248   | 0.3563   | 0.3452     | 0.3839     | 2.94  | 35          | 202    | 0.0513 |
|                     | CAT-XG | 0.5436   | 0.3228   | 0.3113     | 0.4112     | 2.83  | 41          | 205    | 0.0711 |
|                     | XG     | 0.5118   | 0.3316   | 0.2328     | 0.4661     | 3.06  | 36          | 133    | 0.6611 |
| Pol khab-Moroud     | CAT    | 0.5234   | 0.3417   | 0.2667     | 0.3956     | 2.54  | 61          | 146    | 0.6441 |
|                     | CAT-XG | 0.5776   | 0.3811   | 0.3643     | 0.4773     | 2.33  | 53          | 151    | 0.6652 |

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - f_i)^2} \quad (5)$$

در رابطه‌های (۵) تا (۸)،  $f_i$  مقادیر پیش‌بینی شده در گام زمانی  $i$ ام،  $o_i$  مقادیر مشاهداتی در گام زمانی  $i$ ام،  $\bar{f}$  میانگین مقادیر پیش‌بینی شده،  $n$  تعداد داده‌ها و  $\bar{o}$  میانگین مقادیر مشاهداتی است.

میانگین قدر مطلق خطا (MAE): به‌عنوان شاخصی مکمل، میانگین فاصله مطلق بین مقادیر پیش‌بینی شده و مشاهده‌ای را بدون در نظر گرفتن علامت خطا محاسبه می‌کند. برخلاف RMSE، این معیار حساسیت کمتری نسبت به خطاهای حدی دارد و تصویری واقع‌بینانه از عملکرد کلی مدل در طول دوره مطالعه ارائه می‌دهد. رابطه ریاضی MAE مطابق رابطه (۶) بیان می‌شود (Francisco et al., 2025).

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{o}_i - f_i| \quad (6)$$

شاخص کارایی نش ساتکلیف (NSE): میزان بهبود پیش‌بینی مدل نسبت به استفاده از میانگین مشاهدات

#### مدل هیبریدی (Cat-XG)Boost: مدل هیبریدی

پیشنهادی در پژوهش حاضر از ترکیب متوالی دو الگوریتم انفرادی CatBoost و XGBoost تشکیل شده است. ابتدا CatBoost بر روی داده‌های پیش‌پردازش شده آموزش داده می‌شود تا الگوهای پیچیده و غیرخطی سیر زمانی را استخراج کند. سپس خروجی‌های CatBoost همراه با داده‌های اصلی به‌عنوان ورودی مدل XGBoost مورد استفاده قرار می‌گیرند. شکل ۴ اجزای مدل هیبریدی (Cat-XG)Boost را نشان می‌دهد.

#### معیارهای ارزیابی مدل: ریشه میانگین مربعات خطا

(RMSE): معیاری است که میزان پراکندگی مقادیر پیش‌بینی شده نسبت به داده‌های مشاهده‌ای را با تأکید ویژه بر خطاهای بزرگ نشان می‌دهد. مقادیر کمتر RMSE بیان‌گر انطباق بالاتر نتایج شبیه‌سازی با مشاهدات داده‌ها است. این شاخص بر اساس رابطه (۵) محاسبه می‌شود (Ji et al., 2023).

مقادیر نزدیک به ۱+ بیانگر همبستگی قوی و عملکرد مطلوب مدل هستند و با رابطه (۸) ضریب همبستگی محاسبه می‌شود.


$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (8)$$

به‌طور کلی باید توجه داشت که مقادیر مطلق RMSE و MAE در ایستگاه‌های با دبی‌های بزرگ‌تر به‌دلیل مقیاس خود متغیر به‌صورت عددی بزرگ‌تر ظاهر می‌شوند در حالی که عملکرد نسبی مدل در این ایستگاه‌ها نیز در محدوده قابل قبول باقی می‌ماند.

را اندازه‌گیری می‌کند. مقدار یک برای این شاخص نشان‌دهنده انطباق کامل شبیه‌سازی با داده‌های واقعی بوده در حالی که مقدار صفر بیانگر عملکردی هم‌سطح با میانگین داده‌های مشاهده‌ای است. مقادیر منفی نیز حاکی از ناتوانی مدل در بازتولید الگوی جریان هستند و با رابطه (۷) نشان داده شده است (Nash and Sutcliffe, 1970).

$$NS = 1 - \frac{\sum_{i=1}^n (o_i - \bar{o})^2}{\sum_{i=1}^n (\hat{o}_i - \bar{o})^2} \quad (7)$$

ضریب همبستگی (R): شدت و جهت رابطه خطی بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد.



شکل ۴- فلوچارت مدل هیبریدی (Cat-XG)Boost

Fig. 4. Flowchart of (Cat-XG)Boost hybrid model

مختلف تأخیری طراحی شد. در هر سناریو، هدف مدل‌ها برآورد مقدار دبی متوسط ماه آینده  $(Q_{t+1})$  بر اساس مقادیر دبی مشاهده‌شده در ماه‌های پیشین است. در سناریوی نخست، دبی متوسط سه ماه گذشته به‌عنوان ورودی مدل در نظر گرفته شد. در سناریوی دوم، دبی متوسط شش ماه قبل وارد مدل شد تا تأثیر حافظه کوتاه‌مدت سیستم بررسی شود. سناریوی سوم با استفاده از سه فصل تأخیر متوالی دبی متوسط ماهانه طراحی شد.

**مدل‌های پیش‌بینی:** در پژوهش حاضر به‌منظور پیش‌بینی رواناب ماهانه در حوزه آبخیز کرج، سه مدل CatBoost، XGBoost و (CAT-XG)Boost ارزیابی شدند. ورودی مدل‌ها مبتنی بر سری زمانی دبی متوسط ماهانه استخراج‌شده از ایستگاه‌های هیدرومتری بوده و پس از استخراج مقادیر متوسط ماهانه، برای پیش‌بینی ماه آینده از مقادیر رواناب گذشته به‌عنوان متغیرهای تأخیری استفاده شد.

به‌منظور بررسی تأثیر طول حافظه زمانی و میزان اطلاعات گذشته بر دقت پیش‌بینی، چهار سناریوی

به صورت ترتیبی و مبتنی بر توالی زمانی انجام گرفت و نمونه برداری ها به صورت تصادفی صورت نگرفت. بدین ترتیب، حدود ۸۰ درصد ابتدایی داده های ماهانه دوره آماری برای آموزش مدل ها و ۲۰ درصد پایانی داده ها به عنوان دوره آزمون در نظر گرفته شد.

به منظور بررسی تفاوت عملکردی مدل ها از آزمون t-student در سطح اطمینان ۹۵ درصد استفاده شد. در این آزمون میانگین خطاهای مدل ها در دوره آزمون با سایر مدل ها مقایسه شد تا برتری مدل هیبریدی نسبت به آنها از نظر آماری نیز بررسی شود. نتایج نشان داد که اختلاف میانگین خطاها در اغلب ایستگاه ها معنی دار بوده و عملکرد بهتر مدل هیبریدی ناشی از نوسانات تصادفی نیست. نمودار جریانی پژوهش حاضر در شکل ۴ نمایش داده شده است.

در نهایت، سناریوی چهارم شامل چهار فصل وقفه زمانی متوالی بوده و با هدف ارزیابی نقش حافظه بلند مدت تر حوضه در پیش بینی رواناب ماهانه مورد استفاده قرار گرفت. ساختار کلی سناریوهای ورودی خروجی مدل ها به صورت ترکیب ۱ تا ۴ تعریف می شود.

ترکیب (۱)

$$Q_{(t+1)} = f(Q_{(t)})$$

ترکیب (۲)

$$Q_{(t+1)} = f(Q_{(t)}, Q_{(t-1)})$$


ترکیب (۳)

$$Q_{(t+1)} = f(Q_{(t)}, Q_{(t-1)}, Q_{(t-2)})$$

ترکیب (۴)

$$Q_{(t+1)} = f(Q_{(t)}, Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)})$$

در این پژوهش با توجه به ماهیت پیش بینی زمانی رواناب، تفکیک داده ها به مجموعه های آموزش و آزمون



شکل ۵- فلوچارت مراحل انجام پژوهش

Fig. 5. Flowchart of modeling steps

۲ تا ۴ نشان داد که مدل هیبریدی به طور قابل توجهی دقت بالاتری را به ثبت رساند و قادر است الگوهای پیچیده و غیرخطی جریان را با دقتی بسیار بالاتر نسبت به مدل های منفرد بازسازی کند.

## نتایج و بحث

نتایج حاصل از تحلیل عملکرد سه مدل CatBoost، XGBoost و مدل هیبریدی (Cat-XG)Boost به منظور پیش بینی رواناب ماهانه حوزه آبخیز کرج در جدول های

۰/۱۲۱ تا ۰/۱۴۱ و مقدار RMSE به حدود ۰/۱۶۳ تا ۰/۱۸۵ کاهش پیدا کرده و عملکرد مدل قابل قبول بوده است. مدل CatBoost نیز با وجود مزایایی مانند ساختار درخت‌های متقارن و توانایی ویژه در پردازش ویژگی‌های پیچیده در این مطالعه ضعیف‌ترین عملکرد را در میان سه مدل مورد مطالعه داشته است.

مقدار NS بین ۰/۵۹۴ تا ۰/۶۱۳ و همبستگی ۰/۵۶۶ تا ۰/۵۸۴ نشان می‌دهد که این مدل به‌منظور شناسایی پویایی‌های سری زمانی رواناب در ایستگاه‌های مورد بررسی ناموفق عمل کرده است. مقادیر MAE بین ۵/۱۵۷ تا ۷/۳۱۸ در سه ایستگاه گچسر، سیرا-کلوان و سیرا-کرج نیز بیانگر چالش این مدل در مواجهه با نوسانات شدید، رخداد‌های حدی و رفتارهای نوسانی است. با این حال در دو ایستگاه دیگر مقادیر خطا به محدوده ۰/۱۳۷ تا ۰/۱۶۴ کاهش یافته که نشان می‌دهد CatBoost در شرایطی که داده‌ها نظم بیشتری دارند یا رفتار جریان فاقد نوسان‌های حدی است، قادر به ارائه برآوردهای دقیق‌تری است.

بررسی الگوی خطا در سه ایستگاهی که بالاترین RMSE ثبت شده نشان می‌دهد که این ایستگاه‌ها دارای بیشترین حجم داده و متنوع‌ترین رفتار هیدرولوژیک بوده‌اند. در سری‌های زمانی بلندمدت، فراوانی رخداد‌های سیلابی، دوره‌های خشکسالی، تغییرات کاربری اراضی و مداخلات انسانی باعث ایجاد نوسانات شدید در رواناب می‌شود؛ امری که موجب افزایش حساسیت مدل‌ها نسبت به داده‌های پرت و تغییرات ناگهانی می‌شود. در چنین شرایطی، مدل‌های کلاسیک تقویت‌گرادیان مانند CatBoost و XGBoost انعطاف کافی برای استخراج تمامی این الگوهای پیچیده را ندارند.

برتری مدل هیبریدی (Cat-XG)Boost در این ایستگاه‌ها به‌خوبی نشان می‌دهد که ترکیب دو مدل، توانایی مدل در هم‌زمان‌سازی الگوهای کوتاه‌مدت و بلندمدت را افزایش داده و شناسایی تغییرات غیرخطی را بهبود بخشیده است. در مجموع، نتایج پژوهش حاضر تأکید می‌کند که مدل هیبریدی (Cat-XG)Boost به‌دلیل ماهیت ترکیبی و ساختار بهینه‌شده، مناسب‌ترین گزینه برای مدلسازی رواناب در حوزه آبخیز کرج است. دو مدل انفرادی در پیش‌بینی رواناب

در پژوهش حاضر، مدل (Cat-XG)Boost با دستیابی به مقادیر نش ساتکلیف (NS) بین ۰/۹۵۸ تا ۰/۹۷۴ و ضریب همبستگی ۰/۹۳۹ تا ۰/۹۵۷، نزدیک‌ترین برآورد را به مقادیر مشاهداتی فراهم کرد که نشان‌دهنده توانایی بالای مدل در استخراج هم‌زمان روابط خطی و غیرخطی در داده‌های هیدرولوژیک است. همچنین مقادیر RMSE و MAE در دو ایستگاه پل خواب-نشتارود و پل خواب-دورود کمتر از ۰/۰۳ مترمکعب بر ثانیه بوده است که با توجه به این که دبی بیشینه ماهانه این ایستگاه‌ها به ترتیب حدود ۰/۳۶ و ۰/۲۸ مترمکعب بر ثانیه ثبت شده است، این خطا کمتر از حدود هشت تا ۱۰ درصد دبی بیشینه ماهانه ثبت شده را شامل می‌شود که در مدلسازی رواناب، نشان‌دهنده انحراف بسیار ناچیز و بازسازی تقریباً کامل رفتار سری زمانی است. هرچند در سه ایستگاه دیگر که میانگین دبی بیشتری موجود داشتند، میزان RMSE بیش از ۱/۴ گزارش شد.

این افزایش بیشتر ناشی از ویژگی‌های ساختاری داده‌ها و نوسانات هیدرولوژیکی ایستگاه‌ها بوده تا ضعف مدل زیرا در ایستگاه‌هایی با دبی‌های کوچک‌تر، مقادیر عددی خطا نیز به‌طور طبیعی کوچک‌تر دیده می‌شود هرچند عملکرد نسبی مدل در هردو گروه ایستگاه‌ها قابل قبول است. مدل XGBoost که یکی از قوی‌ترین الگوریتم‌های تقویت‌گرادیان محسوب می‌شود، عملکردی متوسط و قابل قبول ارائه داد. مقدار NS بین ۰/۶۴۱ تا ۰/۶۵۷ و همبستگی ۰/۶۱۲ تا ۰/۶۲۹ نشان داد که این مدل توانسته بخشی از ساختار سری زمانی را بازسازی کند اما در برخی ایستگاه‌ها به‌ویژه ایستگاه‌هایی که دارای جهش‌های ناگهانی در رواناب، رخداد سیلاب‌های مقطعی و دامنه نوسان بالاتر دبی بوده‌اند، مقادیر خطای بالاتری ثبت شده است.

این موضوع بیش از آن که ناشی از ضعف مدل باشد، مربوط به پویایی سری‌زمانی جریان در ایستگاه‌های مورد مطالعه است. در همین راستا، مقادیر RMSE و MAE در سه ایستگاه گچسر، سیرا-کلوان و سیرا-کرج بین ۴/۳۵۱ تا ۶/۴۰۲ مشاهده شد که نشان‌دهنده حساسیت این مدل به داده‌های پرت و رفتارهای ناپایدار سری زمانی است. با این وجود در دو ایستگاه دیگر که داده‌ها نوسان کمتری داشته‌اند، مقادیر MAE به حدود

وجود، نتایج حاصل از این پژوهش نیز تأکید می‌کند که بهترین الگوریتم وابسته به ساختار داده، جنس داده‌ها و پیش‌پردازش است. همچنین با مقایسه مدل هیبریدی مورد بحث و مدل‌های مرجع ساده مانند ARIMA که معمولاً NS در محدوده ۰/۷۵ تا ۰/۵ و خطای بین ۰/۶ تا ۳ مترمکعب بر ثانیه ثبت می‌کنند، مشخص می‌شود که بهبود معیارهای استاندارد ارزیابی و برتری مدل هیبریدی معرفی شده صرفاً حافظه تأخیری داده‌های ورودی نبوده بلکه ناشی از شناسایی الگوهای غیرخطی پیچیده است.

برای مثال در پژوهش Nazari Cheragh Tape et al., (2026) به مقایسه مدل‌های باکس جنکینز ARIMA، SARIMA و مدل‌های یادگیری ماشین ELM و XGBoost پرداختند. نتایج این پژوهش ثابت کرد که مدل XGBoost با اختلاف چشم‌گیری عملکرد بهتری را از نظر دقت و خطای کمتر به ثبت رساند. این نتایج در حالی است که در مطالعه حاضر، مدل هیبریدی (Cat-XG)Boost با اختلاف زیادی عملکرد بهتری را از مدل XGBoost ثبت کرده است. در حوزه آبخیز کرج با توجه به شرایط هیدروکلیماتولوژی سرد، کوهستانی، شیب زیاد و رژیم جریان متغیر، نتایج این پژوهش نشان داد که مدل هیبریدی پیشنهادی با ثبت مقادیر بالا در زمینه دقت و خطای کم، توان بالایی در بازسازی الگوی رواناب ماهانه دارد.

با توجه به یافته‌های مطالعه حاضر و گزارش‌های موجود از کارایی مدل‌های تقویت گرادیانی، مشخص شده است که با استفاده از مدل‌های هیبریدی مبتنی بر بوستینگ می‌توان دقت و پایداری زیادی در حوضه‌های مشابه حوزه آبخیز کرج به‌منظور پیش‌بینی رواناب فراهم آورد.

عملکردی متوسط را به ثبت رساندند اما ترکیب این دو مدل انفرادی، باعث رفع خطاهای هردو مدل، برطرف شدن عیوب و افزایش دقت پیش‌بینی‌ها شد. عملکرد ممتاز مدل هیبریدی به‌ویژه در ایستگاه‌هایی با رفتار پیچیده و متلاطم، نشان‌دهنده آن است که بهره‌گیری از مدل‌های ترکیبی در مطالعات هیدرولوژیک می‌تواند رویکردی پیشرو در افزایش دقت و پایداری پیش‌بینی به شمار رود.

این یافته‌ها می‌تواند مبنای مناسبی برای توسعه سیستم‌های هشدار سیلاب، مدیریت ریسک و برنامه‌ریزی علمی منابع آب در حوضه‌های مشابه باشد. مطالعات مختلف نشان داده‌اند که با ادغام چارچوب‌های داده‌محور همراه قطعات مدل‌سازی مکمل مثل ترکیب چند الگوریتم تقویتی، می‌توان دقت و پایداری پیش‌بینی را به‌طور چشم‌گیری بهبود بخشید. برای مثال، Ni et al., (2020) نشان دادند که ترکیب XGBoost با یک مدل خوشه‌ای (GMM-XGBoost) برای پیش‌بینی ماهانه جریان موجب بهبود قابل توجهی در دقت پیش‌بینی نسبت به XGBoost به‌صورت انفرادی شد. نتیجه‌ای که با برتری واضح (Cat-XG)Boost در پژوهش حاضر سازگار است زیرا ترکیب روش‌ها معمولاً موجب کاهش خطاهای منظم و افزایش قابلیت تعمیم می‌شود.

از سوی دیگر، مقالات مقایسه‌ای نشان می‌دهند که کدام الگوریتم با چه نوع داده و در چه اقلیمی بهتر عمل می‌کند. مطالعه مقایسه‌ای جامع Kumar et al., (2023) که به‌طور مستقیم CatBoost، XGBoost و چند الگوریتم دیگر را به‌منظور پیش‌بینی ورودی رودخانه بررسی کرده بود، نشان داد CatBoost در بسیاری از حالت‌ها عملکرد بسیار خوبی نشان می‌دهد. با این

جدول ۲- نتایج آماری داده‌های ورودی جهت مدل‌سازی و پیش‌بینی رواناب با مدل CatBoost

Table 2. Statistical results of input data to the CatBoost model for predicting the runoff

| Station          | Composition number | Trainig Dataset |       |       |       | Test Dataset |       |       |       |
|------------------|--------------------|-----------------|-------|-------|-------|--------------|-------|-------|-------|
|                  |                    | NS              | RMSE  | MAE   | R     | NS           | RMSE  | MAE   | R     |
| Gachsar<br>41253 | 4                  | 0.624           | 7.403 | 7.287 | 0.597 | 0.613        | 7.424 | 7.318 | 0.584 |
|                  | 3                  | 0.621           | 7.409 | 7.289 | 0.594 | 0.608        | 7.425 | 7.321 | 0.579 |
|                  | 2                  | 0.617           | 7.411 | 7.292 | 0.588 | 0.603        | 7.431 | 7.325 | 0.573 |
|                  | 1                  | 0.613           | 7.413 | 7.301 | 0.583 | 0.598        | 7.432 | 7.328 | 0.569 |

| Station                          | Composition number | Trainig Dataset |       |       |       | Test Dataset |       |       |       |
|----------------------------------|--------------------|-----------------|-------|-------|-------|--------------|-------|-------|-------|
|                                  |                    | NS              | RMSE  | MAE   | R     | NS           | RMSE  | MAE   | R     |
| Sira-Kalvan<br>41936             | 4                  | 0.623           | 7.417 | 7.304 | 0.596 | 0.612        | 7.434 | 7.334 | 0.583 |
|                                  | 3                  | 0.619           | 7.421 | 7.307 | 0.594 | 0.607        | 7.437 | 7.336 | 0.587 |
|                                  | 2                  | 0.616           | 7.422 | 7.309 | 0.586 | 0.602        | 7.439 | 7.341 | 0.573 |
|                                  | 1                  | 0.612           | 7.424 | 7.312 | 0.581 | 0.597        | 7.441 | 7.344 | 0.566 |
| Sira-Karaj<br>41101              | 4                  | 0.622           | 5.203 | 5.131 | 0.595 | 0.611        | 5.241 | 5.147 | 0.582 |
|                                  | 3                  | 0.618           | 5.207 | 5.134 | 0.593 | 0.606        | 5.244 | 5.149 | 0.578 |
|                                  | 2                  | 0.615           | 5.212 | 5.137 | 0.585 | 0.601        | 5.253 | 5.156 | 0.572 |
|                                  | 1                  | 0.611           | 5.217 | 5.141 | 0.579 | 0.596        | 5.254 | 5.157 | 0.568 |
| Pol Khab-<br>Nashtaroud<br>41987 | 4                  | 0.621           | 0.183 | 0.124 | 0.594 | 0.609        | 0.197 | 0.137 | 0.581 |
|                                  | 3                  | 0.617           | 0.187 | 0.127 | 0.592 | 0.605        | 0.202 | 0.141 | 0.577 |
|                                  | 2                  | 0.614           | 0.193 | 0.133 | 0.584 | 0.599        | 0.203 | 0.144 | 0.571 |
|                                  | 1                  | 0.609           | 0.201 | 0.141 | 0.578 | 0.595        | 0.206 | 0.151 | 0.567 |
| Pol Khab-<br>Moroud<br>41935     | 4                  | 0.619           | 0.204 | 0.142 | 0.593 | 0.608        | 0.213 | 0.154 | 0.579 |
|                                  | 3                  | 0.616           | 0.207 | 0.144 | 0.591 | 0.604        | 0.214 | 0.157 | 0.576 |
|                                  | 2                  | 0.612           | 0.213 | 0.147 | 0.583 | 0.598        | 0.217 | 0.161 | 0.569 |
|                                  | 1                  | 0.608           | 0.216 | 0.151 | 0.577 | 0.594        | 0.221 | 0.164 | 0.566 |

جدول ۳- نتایج آماری داده‌های ورودی جهت مدلسازی و پیش بینی رواناب با مدل XGBoost

Table 3. Statistical results of input data to the XGBoost model for predicting the runoff

| Station                          | Composition number | Trainig Dataset |       |       |       | Test Dataset |       |       |       |
|----------------------------------|--------------------|-----------------|-------|-------|-------|--------------|-------|-------|-------|
|                                  |                    | NS              | RMSE  | MAE   | R     | NS           | RMSE  | MAE   | R     |
| Gachsar<br>41253                 | 4                  | 0.673           | 6.357 | 6.294 | 0.644 | 0.657        | 6.402 | 6.309 | 0.629 |
|                                  | 3                  | 0.669           | 6.361 | 6.296 | 0.641 | 0.654        | 6.406 | 6.312 | 0.624 |
|                                  | 2                  | 0.664           | 6.364 | 6.298 | 0.637 | 0.651        | 6.409 | 6.317 | 0.621 |
|                                  | 1                  | 0.661           | 6.366 | 6.301 | 0.633 | 0.647        | 6.413 | 6.321 | 0.617 |
| Sira-<br>Kalvan<br>41936         | 4                  | 0.672           | 6.371 | 6.304 | 0.643 | 0.656        | 6.417 | 6.327 | 0.628 |
|                                  | 3                  | 0.668           | 6.373 | 6.309 | 0.641 | 0.654        | 6.421 | 6.331 | 0.623 |
|                                  | 2                  | 0.663           | 6.374 | 6.313 | 0.636 | 0.651        | 6.423 | 6.339 | 0.619 |
|                                  | 1                  | 0.659           | 6.377 | 6.318 | 0.632 | 0.644        | 6.427 | 6.343 | 0.616 |
| Sira-Karaj<br>41101              | 4                  | 0.671           | 4.483 | 4.306 | 0.642 | 0.655        | 4.503 | 4.328 | 0.627 |
|                                  | 3                  | 0.667           | 4.489 | 4.309 | 0.639 | 0.653        | 4.507 | 4.336 | 0.622 |
|                                  | 2                  | 0.662           | 4.493 | 4.317 | 0.635 | 0.649        | 4.512 | 4.344 | 0.618 |
|                                  | 1                  | 0.658           | 4.496 | 4.321 | 0.631 | 0.643        | 4.517 | 4.351 | 0.614 |
| Pol Khab-<br>Nashtaroud<br>41987 | 4                  | 0.669           | 0.146 | 0.103 | 0.641 | 0.654        | 0.163 | 0.121 | 0.625 |
|                                  | 3                  | 0.666           | 0.149 | 0.107 | 0.638 | 0.652        | 0.164 | 0.122 | 0.621 |
|                                  | 2                  | 0.661           | 0.151 | 0.109 | 0.634 | 0.648        | 0.171 | 0.125 | 0.617 |

| Station               | Composition number | Trainig Dataset |       |       |       | Test Dataset |       |       |       |
|-----------------------|--------------------|-----------------|-------|-------|-------|--------------|-------|-------|-------|
|                       |                    | NS              | RMSE  | MAE   | R     | NS           | RMSE  | MAE   | R     |
| Pol Khab-Moroud 41935 | 1                  | 0.657           | 0.154 | 0.112 | 0.629 | 0.642        | 0.174 | 0.131 | 0.613 |
|                       | 4                  | 0.668           | 0.167 | 0.114 | 0.639 | 0.653        | 0.179 | 0.134 | 0.624 |
|                       | 3                  | 0.665           | 0.169 | 0.117 | 0.637 | 0.651        | 0.181 | 0.137 | 0.619 |
|                       | 2                  | 0.659           | 0.174 | 0.121 | 0.633 | 0.647        | 0.183 | 0.139 | 0.616 |
|                       | 1                  | 0.657           | 0.177 | 0.124 | 0.628 | 0.641        | 0.185 | 0.141 | 0.612 |

**جدول ۴-** نتایج آماری داده‌های ورودی جهت مدلسازی و پیش بینی رواناب با مدل (XG-Cat)Boost  
**Table 4.** Statistical results of input data to the (Cat-XG)Boost hybrid model for predicting the runoff

| Station                   | Composition number | Train Dataset |       |       |       | Test Dataset |       |       |       |
|---------------------------|--------------------|---------------|-------|-------|-------|--------------|-------|-------|-------|
|                           |                    | NS            | RMSE  | MAE   | R     | NS           | RMSE  | MAE   | R     |
| Gachsar 41253             | 4                  | 0.986         | 1.493 | 1.424 | 0.969 | 0.974        | 1.504 | 1.437 | 0.957 |
|                           | 3                  | 0.982         | 1.494 | 1.427 | 0.964 | 0.971        | 1.507 | 1.439 | 0.953 |
|                           | 2                  | 0.976         | 1.496 | 1.429 | 0.961 | 0.967        | 1.511 | 1.441 | 0.949 |
|                           | 1                  | 0.969         | 1.497 | 1.431 | 0.957 | 0.963        | 1.513 | 1.443 | 0.944 |
| Sira-Kalvan 41936         | 4                  | 0.985         | 1.501 | 1.433 | 0.968 | 0.973        | 1.516 | 1.446 | 0.956 |
|                           | 3                  | 0.982         | 1.502 | 1.434 | 0.963 | 0.971        | 1.517 | 1.449 | 0.953 |
|                           | 2                  | 0.975         | 1.504 | 1.437 | 0.959 | 0.966        | 1.523 | 1.452 | 0.948 |
|                           | 1                  | 0.968         | 1.507 | 1.439 | 0.956 | 0.962        | 1.527 | 1.454 | 0.943 |
| Sira-Karaj 41101          | 4                  | 0.984         | 1.046 | 1.017 | 0.967 | 0.972        | 1.057 | 1.031 | 0.955 |
|                           | 3                  | 0.981         | 1.048 | 1.019 | 0.962 | 0.969        | 1.061 | 1.032 | 0.952 |
|                           | 2                  | 0.974         | 1.048 | 1.021 | 0.958 | 0.965        | 1.063 | 1.034 | 0.947 |
|                           | 1                  | 0.966         | 1.051 | 1.024 | 0.955 | 0.961        | 1.064 | 1.039 | 0.942 |
| Pol Khab-Nashtaroud 41987 | 4                  | 0.982         | 0.017 | 0.006 | 0.966 | 0.971        | 0.021 | 0.011 | 0.954 |
|                           | 3                  | 0.979         | 0.018 | 0.009 | 0.961 | 0.968        | 0.024 | 0.012 | 0.951 |
|                           | 2                  | 0.973         | 0.019 | 0.011 | 0.957 | 0.964        | 0.026 | 0.014 | 0.946 |
|                           | 1                  | 0.965         | 0.022 | 0.013 | 0.954 | 0.959        | 0.028 | 0.019 | 0.941 |
| Pol Khab-Moroud 41935     | 4                  | 0.981         | 0.023 | 0.014 | 0.965 | 0.969        | 0.029 | 0.021 | 0.953 |
|                           | 3                  | 0.978         | 0.025 | 0.016 | 0.959 | 0.967        | 0.031 | 0.023 | 0.949 |
|                           | 2                  | 0.972         | 0.027 | 0.019 | 0.956 | 0.963        | 0.034 | 0.024 | 0.945 |
|                           | 1                  | 0.964         | 0.029 | 0.021 | 0.953 | 0.958        | 0.037 | 0.027 | 0.939 |

است. در نمودارهای پراکنش، مدل هیبریدی (Cat-XG)Boost بالاترین تراکم نقاط در امتداد خط نیمساز را نشان داده و این موضوع بیان‌گر توانایی بسیار بالای مدل در درک ساختار غیرخطی و پیچیده سری زمانی رواناب است.

بررسی نمودارهای همبستگی سه مدل (Cat-XG)Boost، XGBoost و CatBoost در شکل ۶ نشان می‌دهد که نحوه بازسازی الگوهای تغییرات رواناب و میزان نزدیکی مقادیر شبیه‌سازی‌شده به مشاهدات واقعی، تفاوت‌های بنیادینی میان مدل‌ها ایجاد کرده

متوسط و بالا با خطاهای بیشتری همراه است. همچنین شکل کلی نمودار حاکی از آن است که اثر نویز داده‌ها و غیرخطی بودن روابط بین بارش و رواناب، چالش بیشتری برای این مدل ایجاد کرده و باعث شده الگوهای پیچیده فصلی به‌طور کامل بازسازی نشوند.


ترکیب قدرت مدل CatBoost در مدیریت داده‌های نامتوازن و ویژگی‌های پیچیده با توانایی مدل XGBoost در یادگیری روابط غیرخطی و تعاملات عمیق، موجب شده است که مدل هیبریدی نمایی بسیار منظم، فشرده و نزدیک به خط نیم‌ساز ارائه دهد. از سوی دیگر، همخوانی میان نمودارهای همبستگی و شاخص‌های عددی مانند NS، RMSE و MAE نشان می‌دهد که تحلیل نمودارها از نظر تفسیر علمی معتبر است. ایستگاه‌هایی که بیش‌ترین دبی بیشینه ماهانه را داشته‌اند به‌دلیل پیچیدگی بیشتر الگوهای فصلی و سالانه معمولاً پراکندگی بیشتری در نتایج مدل‌های پایه نشان داده‌اند اما مدل هیبریدی این الگوهای پیچیده را با دقت بسیار بالاتری فرا گرفته است.

در مقابل، ایستگاه‌هایی با دبی بیشینه ماهانه پایین‌تر به‌دلیل یکنواخت‌تر بودن رفتار سری زمانی برای مدل‌ها چالش کم‌تری ایجاد کرده‌اند و به همین علت مقادیر RMSE در آنها کاهش داشته است. در مجموع، تحلیل نمودارهای همبستگی به‌خوبی نشان می‌دهد که مدل هیبریدی با بهره‌گیری از نقاط قوت دو الگوریتم اصلی، قادر بوده است تا ساختار پیچیده، غیرفصلی و غیرخطی رواناب ماهانه در حوزه آبخیز کرج را با دقتی بسیار بالا بازسازی کند. درحالی‌که مدل‌های انفرادی CatBoost و XGBoost اگرچه عملکرد قابل توجهی داشته‌اند اما در مواجهه با تغییرپذیری جریان رواناب، دقت و کارایی پایین‌تری نسبت به مدل ترکیبی ارائه داده‌اند.


همبستگی بالای ۰/۹۳۹ و قرارگیری بخش عمده داده‌ها در محدوده نوسان اندک حول خط نیم‌ساز، نشان می‌دهد که مدل رفتار ماهانه رواناب را نه‌تنها در دوره‌های پایدار بلکه در دوره‌های تغییرپذیری شدید نیز به‌درستی پیش‌بینی می‌کند. در این حالت، نقاط پرت بسیار محدود بوده و الگوی کلی پراکنش، شکل فشرده، منظم و منطبق بر داده‌های واقعی دارد که نشان‌دهنده همخوانی مناسب ساختار داخلی مدل با ماهیت داده‌های هیدرولوژیک است.

در مقابل، نمودارهای مربوط به مدل XGBoost اگرچه روند کلی را نسبتاً خوب دنبال کرده‌اند اما پراکندگی نقاط در فاصله‌ای دورتر از خط یک به یک قابل مشاهده است. مقدار همبستگی متوسط ثبت شده نشان‌دهنده آن است که این مدل توانسته بخش‌هایی از ساختار داده را بازتولید کند اما حساسیت آن به نوسانات میان‌مدت و رفتارهای غیرخطی محدود بوده است. در نمودار پراکنش، بخشی از نقاط به‌ویژه در محدوده دبی‌های متوسط و بالا گرایش بیشتری به پراکندگی دارند و این موضوع با مقادیر بالاتر RMSE در سه ایستگاه دارای داده‌های فراوان سازگار است. این وضعیت بیان می‌کند که مدل XGBoost در مواجهه با سری‌های زمانی با ساختار پیچیده‌تر، نیازمند تنظیم پارامترهای بیشتر یا ترکیب با سایر روش‌ها است.

امری که کارایی بهتر مدل هیبریدی را توجیه می‌کند، نمودارهای مربوط به مدل CatBoost گسترده‌ترین پراکندگی را نشان می‌دهند. همبستگی ۵۷ تا ۵۹ درصدی و فاصله زیاد نقاط از خط ایده‌آل بیان می‌کند که مدل در بازسازی رفتار رواناب ماهانه دقت کمتری داشته است. الگوهای دیده‌شده در پراکنش نشان می‌دهند که CatBoost در تخمین دبی‌های پایین عملکرد قابل‌قبول‌تری دارد اما در مقادیر



شکل ۶- نمودار مقایسه همبستگی مدل‌ها  
Fig. 6. Comparison diagram of model correlations



ادامه شکل ۶  
Fig. 6. Continued

### نتیجه‌گیری

نتایج این پژوهش نشان داد که بهره‌گیری از رویکردهای نوین یادگیری ماشین در پیش‌بینی رواناب ماهانه حوزه آبخیز کرج می‌تواند به‌طور قابل توجهی دقت و کارایی مدل‌سازی هیدرولوژیک را ارتقاء دهد. مقایسه عملکرد سه مدل CatBoost، XGBoost و مدل هیبریدی (Cat-XG)Boost بیان‌گر آن است که هرچند مدل‌های انفرادی توانسته‌اند بخشی از ساختار عمومی داده‌های رواناب را بازسازی کنند اما محدودیت‌هایی در شناسایی الگوهای پیچیده، غیرخطی و چندبعدی جریان وجود داشته است. در مقابل، مدل هیبریدی (Cat-XG)Boost با ترکیب قابلیت‌های اصلی دو الگوریتم از جمله توانایی XGBoost در استخراج روابط غیرخطی و قدرت CatBoost در مدیریت داده‌های نامتوازن و ویژگی‌های پیچیده به عملکردی بسیار برتر دست یافته است. عملکرد بی‌نقص مدل (Cat-XG)Boost در شاخص‌های ارزیابی نشان‌دهنده قدرت این مدل در بازتولید دقیق رفتار واقعی رواناب است.

تحلیل ایستگاه‌های با حجم دبی بیشینه بالا نیز نشان داد که اگرچه ذات پیچیده‌تر سری‌های زمانی باعث افزایش خطای مدل‌های انفرادی می‌شود اما مدل هیبریدی همچنان با دقت مطلوبی قادر به بازسازی

نوسانات و روندهای ماهانه بوده است. این یافته‌ها تأیید می‌کند که رویکردهای ترکیبی در مواجهه با داده‌های پیچیده هیدرولوژیک، مزیت قابل توجهی نسبت به مدل‌های انفرادی دارند.

از مدل هیبریدی پیشنهادی می‌توان به‌عنوان ابزاری سودمند در مطالعات مدیریت منابع آب، پیش‌بینی خشکسالی و سیلاب‌های فصلی و ارائه سناریوهای تصمیم‌گیری در سطوح حوضه‌ای استفاده به‌عمل آورد. پیشنهاد می‌شود در مطالعات آتی از ترکیب این مدل با روش‌های فراابتکاری به‌منظور بهینه‌سازی فراپارامترها و همچنین از داده‌های چندمنبعه نظیر رطوبت خاک، دمای سطح زمین و داده‌های سنجش‌از‌دور استفاده شود تا دقت پیش‌بینی در مقیاس‌های زمانی و مکانی مختلف بیش از پیش افزایش یابد. با بهره‌گیری از مدل‌های ترکیبی پیشرفته‌تر مانند ادغام الگوریتم‌های فراابتکاری در تنظیم فراپارامترهای CatBoost و XGBoost می‌توان دقت مدل هیبریدی را بهبود بخشید و همچنین نوسانات خطا در ایستگاه‌های با داده‌های حجیم را کاهش داد.

در کنار آن، بررسی مدل‌های عمیق‌تر نظیر شبکه‌های عصبی بازگشتی، مدل‌های مبتنی بر حافظه بلندمدت و معماری‌های مبتنی بر ترنسفورمر می‌تواند

زمینه مقایسه‌ای گسترده‌تری ایجاد کرده و امکان  
تحلیل عمیق‌تر ساختار زمانی رواناب را فراهم آورد.  
دادن داده‌ها و امکانات لازم جهت انجام این پژوهش  
تشکر و قدردانی به‌عمل می‌آید.

### تشکر و قدردانی

### تعارض منافع

از سازمان آب منطقه‌ای استان البرز و دانشکده  
منابع طبیعی دانشگاه تهران به‌منظور در اختیار قرار  
در این مقاله تضاد منافی وجود ندارد و این مسأله  
مورد تأیید همه نویسندگان است.

### منابع مورد استفاده

- Aghajanzadeh Saraskanroud, M., Behmanesh, J., Rezaie, H., Azad, N., 2020. Prediction of Zarrinehrud River run-off in the climate change condition using artificial neural networks. *J. Water. Manage. Res.* 11(22), 20-30 (in Persian). doi:10.52547/jwmr.11.22.20
- Alipour, M., Hosseini, M., 2018. Simulation of surface runoff in Karaj dam basin, Iran. *Appl. Water Sci.* 8(147) (in Persian). <https://doi.org/10.1007/s13201-018-0782-y>
- Ansari ghoghghar, M., Pourmohammad, P., 2025. Comparative analysis of dust storm frequency modeling using the XGBoost machine learning model and the element-free galerkin method, case study: Ilam Province. *Iran. J. Soil Water Res.* 56(6), 1421-1436 (in Persian). doi: 10.22059/ijswr.2025.392122.669904
- Francisco, R., Matos, L.P., Marinheiro, R., Lopes, N., Portela, M.M., Barros, P., 2025. Application of temporal fusion transformers to run-of-the-river hydropower scheduling. *Hydrol.* 12(81). <https://doi.org/10.3390/hydrology12040081>
- Guerrera, K., Rieksts, B., 2022. CATBOOST models for the recidivism forecasting challenge. *NCJRS.*
- Hameed, M.M., Masood, A., hamid, A., Elbeltagi, A., Razali, S.F.M., 2025. Forecasting monthly runoff in a glacierized catchment: A comparison of extreme gradient boosting (XGBoost) and deep learning models. *PLOS ONE* 20(5), e0321008. <https://doi.org/10.1371/journal.pone.0321008>
- Ji, W., Cao, Z., Li, X., 2023. Multi-task learning and temporal-fusion-transformer-based forecasting of building power consumption. *Electron.* 12, 4656. <https://doi.org/10.3390/electronics12224656>
- Kumar, V., Kedam, N., Sharma, K.V., Mehta, D.J., Caloiero, T., 2023. Advanced machine learning techniques to improve hydrological prediction: a comparative analysis of streamflow prediction models. *Water* 15(14), 2572. <https://doi.org/10.3390/w15142572>
- Levent, İ., Şahin, G., Işık, G., van Sark, W.G.J.H.M., 2025. Comparative analysis of advanced machine learning regression models with advanced artificial intelligence techniques to predict rooftop PV solar power plant efficiency using indoor solar panel parameters. *Appli. Sci.* 15(6), 3320. <https://doi.org/10.3390/app15063320>
- Ni, L., Wang, D., Wu, J., Wang, Y., Tao, Y., Zhang, J., Liu, J., 2020. Streamflow forecasting using extreme gradient boosting model coupled with Gaussian mixture model. *J. Hydrol.* 586, 124901, ISSN 0022-1694, <https://doi.org/10.1016/j.jhydrol.2020.124901>
- Liu, Y., Yang, T., Tian, L., Huang, B., Yang, J., Zeng, Z., 2024. Ada-XG-CatBoost: A combined forecasting model for Gross Ecosystem Product (GEP) prediction. *Sustain.* 16(16), 7203. <https://doi.org/10.3390/su16167203>
- Niazkar, M., Menapace, A., Brentan, B., Piraei, R., Jimenez, D., Dhawan, P., Righetti, M., 2024. Applications of XGBoost in water resources engineering: A systematic literature review. *Environ. Modell. Soft.* 174, 105971, ISSN 1364-8152, <https://doi.org/10.1016/j.envsoft.2024.105971>
- Mirzahoseini, A., 2025. Using artificial intelligence in predicting the permeability of geotechnical soils for groundwater resource management. 11th International Conference on Civil Engineering, Architecture and Urban Planning (in Persian). <https://civilica.com/doc/2432355>
- Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models part I: A discussion of principles. *J. Hydrol.* 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Nazari Cheragh Tape, S., Ansari ghoghghar, M., Malekian, A., Ghadimi, M., 2026. Comparison of Box-Jenkins models with machine learning algorithms for streamflow yield modeling, case study: Taleghan Watershed. *Iran. J. Soil Water Res.* 56(11), 3009-3026 (in Persian). doi: 10.22059/ijswr.2025.403797.670025
- panjehkoobi, P., Masoudian, A., Qangherme, A., 2019. Calculating basin runoff coefficient using weather radar, case study: Baghu Basin. *Sci.-Res. Quart. Geograph. Data (SEPEHR)*. 28(110), 209-224 (in Persian). doi:10.22131/sepehr.2019.36624

- Prokhorenkova, M., Gusev, G., Vorobev, A., Dorogush, A.V., Gulin, A., 2018. CatBoost: unbiased boosting with categorical features. 32nd Conference on Neural Information Processing Systems, Montréal, Canada.
- Sadeghramoghaddam, H., 2022. shared bike demand prediction by using metro and bike sharing networks' features. In Partial Fulfillment of The Requirements for The Degree of Master of Science in Architecture, Building and Planning, Track Sustainable Urban Mobility Transitions, Eindhoven University of Technology.
- Seifi Majdar, R., Rahnamaei, A., Babazadeh, V., 2025. Hybrid machine learning in hydrological runoff forecasting: An exploration of extreme gradient-boosting and categorical gradient boosting optimization in the Russian River Basin. *Advance. Engin. Intelli. System.* 004(02), 104-120. doi: 10.22034/aeis.2025.509199.1293
- Shaw, R., 2023. All-stage machine learning-driven B2B sales predictor. Master's Thesis, Vrije Universiteit Amsterdam and Universiteit van Amsterdam.
- Szczepanek, R., 2022. Daily streamflow forecasting in mountainous catchment using XGBoost, LightGBM and CatBoost. *Hydrol.* 9(12), 226. <https://doi.org/10.3390/hydrology9120226>
- Wang, D., Qian, H., 2023. CatBoost-Based automatic classification study of river network. *ISPRS Int. J. Geo-Inform.* 12(10), 416. <https://doi.org/10.3390/ijgi12100416>