Integrated Watershed Management, Autumn, 2026, 6(3), 95-111 **Article Type: Research**

doi: 10.22034/iwm.2026.2077954.1254 **Online ISSN: 2783-4581**

Evaluation and comparison of XBeach, DBN and LightGBM models for predicting flood discharge (Case study: Taleghan Watershed)

Ramtin Tavoosi Rad, Sadaf Piri, Mohammad Ansari ghojghar*

Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran

*** Corresponding author:** ansari.ghojghar@ut.ac.ir

(Received: 15 November 2025 Revised: 24 December 2025 Accepted: 15 February 2026)

Extended Abstract

Introduction: In recent decades, the increased intensity and frequency of flood events due to climate change, urbanization, and land degradation have become a major challenge in water resource management. The occurrence of flash floods in mountainous areas of the country, including the Taleghan watershed, results in consequences such as soil erosion, damage to infrastructure and threats to water resources. Therefore, accurate prediction of flood discharge and hydrological behavior of watersheds is essential for timely decision-making in early warning systems and risk management. The present study aimed to evaluate and compare the performance of three models, XBeach, DBN, and LightGBM, in predicting the maximum monthly flood discharge in the Taleghan watershed.

Materials and methods: The data used included time series of monthly discharge from hydrometric stations in the region over several consecutive years. To evaluate the effect of temporal memory, four different seasonal combinations were designed, including lags of one to four seasons (each season consisting of three months) in the discharge modeling. After preprocessing, standardization and separation into training and test sets, the data were analyzed within the framework of the three models using the R programming software. The physical model XBeach was analyzed as a process-based baseline, while the DBN model was implemented using the structure of dynamic Bayesian networks and probabilistic hidden layers to represent temporal dependencies of the data. The LightGBM model was designed as a gradient boosting tree, with optimization of learning parameters and non-surface growth of trees. The performance of the models was evaluated using the statistical indices NSE, RMSE, MAE and the correlation coefficient (R).

Results and Discussion: The results showed that the LightGBM model had a significantly better performance than the other two models in all stations and in all temporal combinations. With NSE values ranging from 0.908 to 0.931 and correlation coefficient between 0.896 and 0.918, this model showed the highest degree of agreement with the observed data. Also, the RMSE error values for the LightGBM model at the studied stations ranged from 0.079 to 0.131, indicating the high accuracy of the model in predicting the maximum monthly discharge. The DBN model provided good performance with NSE values between 0.864 and 0.896 and correlation coefficient 0.816 to 0.832, while the XBeach numerical model with NSE values of 0.834 to 0.862 and correlation of 0.807 to 0.823 had lower accuracy than the two data-driven models. Despite the relative superiority of the DBN model over XBeach, the performance difference between the two models was not statistically significant in most temporal combinations. Given the complexity of the network structure and the higher computational cost of DBN, the use of the XBeach model is suggested as a more practical option in the second rank. In addition, the ability of the LightGBM model to reproduce seasonal fluctuations and strong flow trends was more significant than other models. The DBN model also performed better compared to XBeach, but the statistical difference resulting from the evaluation criteria between the two models was not significant in most combinations. Considering the complexity of the network structure, high computation time, and cost of adjusting DBN parameters, the use of the XBeach numerical model is recommended as a more economically and practically efficient option. In contrast, the ability of LightGBM to combine nonlinear features of input data and learn complex patterns made this model the most accurate and stable option for flow prediction.

Conclusion: Correlation analyses between observational and predicted data showed that the points resulting from the LightGBM model had the highest density along the one-to-one correlation line and showed the least dispersion, while the XBeach and DBN models had more deviation from the correlation line. These findings are consistent with recent studies that have reported the effectiveness of gradient boosting algorithms in flow and flood prediction. Overall, the findings of this study suggest that the use of lightweight and fast data-driven models such as LightGBM can play an important role in the development of flood forecasting systems in mountainous basins such as Taleghan. High accuracy, fast update capability, low computational requirements, and the possibility of integrating with remote sensing data make this model a suitable option for use in early warning systems and intelligent water resource management. The main innovation of this research is to provide a quantitative and systematic comparison between lightweight data-driven models, deep learning, and physical process models for predicting the maximum monthly discharge, as well as analyzing the sensitivity of their performance to the input temporal memory length, which leads to the presentation of an operational decision-making framework based on accuracy and computational cost.

Keywords: Data Driven Models, Deep Learning, Flood Warning System, Machine Learning.

Citation: TavoosiRad, R., Piri, S. & Ansari ghojghar, M. (2026). Evaluation and comparison of XBeach, DBN and LightGBM models for predicting flood discharge (Case study: Taleghan Watershed). *Integrated Watershed Management*, 6(3), 95-111. https://doi.org/10.22034/iwm.2026.2077954.1254

Copyrights:
Copyright for this article is retained by the author(s), with publication rights granted to Integrated Watershed Management. This is an open-access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/ by/4.0).

مدیریت جامع حوزه‌های آبخیز، سال ششم، شماره سوم، پاییز ۱۴۰۵، صفحات (۱۱۱-۹۵) نوع مقاله: پژوهشی

شاپا الکترونیکی: ۴۵۸۱-۲۷۸۳ doi: 10.22034/iwm.2026.2077954.1254

مقایسه عملکرد مدل‌های XBeach، LightGBM و DBN به‌منظور پیش‌بینی سیلاب (مطالعه موردی: حوزه‌آبخیز طالقان)

رامتین طاوسی‌راد، صدف پیری، محمد انصاری قوجقار*

گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران،

***نویسنده مسئول:** ansari.ghojghar@ut.ac.ir

(تاریخ دریافت: ۱۴۰۴/۰۸/۲۴ تاریخ بازنگری: ۱۴۰۴/۰۹/۰۳ تاریخ پذیرش: ۱۴۰۴/۱۱/۲۶)

چکیده مبسوط

مقدمه: در دهه‌های اخیر، افزایش شدت و فراوانی رخدادهای سیلابی به‌دلیل تغییرات اقلیمی، رشد شهرنشینی و تخریب اراضی به یکی از چالش‌های اصلی در مدیریت جامع حوزه‌های آبخیز و آبخیزداری شهری تبدیل شده است. وقوع سیلاب‌های ناگهانی در حوزه‌های کوهستانی کشور ازجمله حوزه آبخیز طالقان، پیامدهایی نظیر فرسایش خاک، آسیب به زیرساخت‌ها و تهدید منابع آبی را در پی دارد. در این میان، پیش‌بینی دقیق دبی سیلاب و رفتار هیدرولوژیکی حوزه‌های آبخیز، لازمه تصمیم‌گیری به‌موقع در سامانه‌های هشدار سریع و مدیریت ریسک است. در این راستا، پژوهش حاضر با هدف ارزیابی و مقایسه عملکرد سه مدلXBeach، DBN و LightGBM به‌مظور پیش‌بینی دبی بیشینه ماهانه سیلاب در حوزه آبخیز طالقان انجام گرفت.

موادوروش‌ها: داده‌های مورد استفاده شامل سری‌های زمانی دبی ماهانه ایستگاه‌های هیدرومتری منطقه طی دوره ۳۰ ساله (۱۴۰۰–۱۳۷۱) بود. برای ارزیابی اثر حافظه زمانی، چهار ترکیب فصلی مختلف طراحی شد که به‌ترتیب شامل تأخیرهای یک تا چهار فصل (هر فصل سه ماهه) در مدل‌سازی دبی بودند. داده‌ها پس از پیش‌پردازش، استانداردسازی و تفکیک به مجموعه‌های آموزش (۸۰ درصد) و آزمون (۲۰ درصد) در قالب سه مدل در نرم‌افزار برنامه نویسی R مورد بررسی قرار گرفتند. مدل فیزیکی XBeach به‌عنوان پایه فرآیندی تحلیل شد درحالی‌که مدل DBN با استفاده از ساختار شبکه‌های بیزین دینامیکی و لایه‌های پنهان احتمالاتی به‌منظور بازنمایی وابستگی‌های زمانی داده‌ها پیاده‌سازی گردید. مدل LightGBM نیز به‌صورت گرادیان تقویتی درختی و با بهینه‌سازی پارامترهای یادگیری و رشد غیرسطحی درختان طراحی شد. ارزیابی عملکرد مدل‌ها با استفاده از شاخص‌های آماری NSE، RMSE، MAE و ضریب همبستگی (R) انجام پذیرفت.

نتایج و بحث: نتایج به‌دست‌آمده نشان داد که مدل LightGBM در تمامی ایستگاه‌ها و در تمام ترکیب‌های زمانی به‌طور محسوس عملکرد بهتری نسبت به دو مدل دیگر داشته است. این مدل با ثبت مقادیر شاخص نش- ساتکلیف در بازه ۰/۹۰۸ تا ۰/۹۳۱ و ضریب همبستگی بین ۰/۸۹۶ تا ۰/۹۱۸، بالاترین میزان انطباق با داده‌های مشاهده‌شده را نشان داد. همچنین مقادیر خطای RMSE برای مدل LightGBM در ایستگاه‌های مورد مطالعه در بازه ۰/۰۷۹ تا ۰/۱۳۱ قرار داشت که بیان‌گر دقت بالای مدل در پیش‌بینی دبی بیشینه ماهانه است. مدل DBN عملکرد خوبی با مقادیر نش-ساتکلیف بین ۰/۸۶۴ تا ۰/۸۹۶ و ضریب همبستگی ۰/۸۱۶ تا ۰/۸۳۲ ارائه داد در حالی که مدل عددی XBeach با ثبت مقادیر نش- ساتکلیف ۰/۸۳۴ تا ۰/۸۶۲ و همبستگی ۰/۸۰۷ تا ۰/۸۲۳ دقت پایین‌تری نسبت به دو مدل داده‌محور داشت. با وجود برتری نسبی مدل DBN نسبت به XBeach، اختلاف عملکرد این دو مدل در اغلب ترکیب‌های زمانی از نظر آماری معنی‌دار نبود. علاوه بر این، توانایی مدل LightGBMدر بازتولید نوسانات فصلی و روندهای شدید جریان نسبت به سایر مدل‌ها چشم‌گیرتر بود. مدل DBN نیز در مقایسه با XBeach عملکرد بهتری داشت اما اختلاف آماری حاصل از معیارهای ارزیابیِ میان این دو مدل در اکثر ترکیب‌ها قابل‌توجه نبود. با توجه به پیچیدگی ساختار شبکه‌ای، زمان محاسبات بالا و هزینه تنظیم پارامترهای DBN، استفاده از مدل عددی XBeach به‌عنوان گزینه‌ای کارآمدتر از نظر اقتصادی و اجرایی توصیه می‌شود. در مقابل، توانایی LightGBM در ترکیب ویژگی‌های غیرخطی داده‌های ورودی و یادگیری الگوهای پیچیده سبب شد تا این مدل به‌عنوان دقیق‌ترین و پایدارترین گزینه برای پیش‌بینی جریان معرفی گردد.

نتیجه‌گیری: بررسی‌های همبستگی میان داده‌های مشاهداتی و پیش‌بینی‌شده نشان داد که نقاط حاصل از مدل LightGBM بیش‌ترین تراکم را در امتداد خط همبستگی یک‌به‌یک داشته و کم‌ترین پراکندگی را نشان می‌دهند در حالی‌که مدل‌های XBeach و DBN انحراف بیش‌تری از خط همبستگی داشتند. این یافته‌ها با نتایج مطالعات اخیر که کارایی الگوریتم‌های گرادیان تقویتی در پیش‌بینی جریان و سیلاب را گزارش کرده‌اند، مطابقت دارد. در مجموع، یافته‌های پژوهش حاضر بیان‌گر آن است که با بهره‌گیری از مدل‌های داده‌محور سبک و سریع مانند LightGBM می‌توان باعث توسعه سامانه‌هایِ پیش‌بینیِ سیلاب در حوضه‌های کوهستانی نظیر طالقان شد. دقت بالا، قابلیت به‌روزرسانی سریع، نیاز محاسباتی پایین و امکان ادغام با داده‌های سنجش‌ازدور این مدل را به گزینه‌ای مناسب برای کاربرد در سامانه‌هایِ هشدارِ سریع و مدیریتِ هوشمندِ منابع آب تبدیل کرده است. با توجه به پیچیدگی ساختار شبکه‌ای و هزینه محاسباتی بالاتر DBN، استفاده از مدل XBeach به‌عنوان گزینه‌ای اجرایی‌تر در رتبه دوم پیشنهاد می‌شود. نوآوری اصلی این پژوهش در ارائه یک مقایسه کمی و سیستماتیک بین مدل‌های داده‌محور سبک، یادگیری عمیق و مدل فرآیندی فیزیکی برای پیش‌بینی دبی بیشینه ماهانه و همچنین تحلیل حساسیت عملکرد آن‌ها نسبت به طول حافظه زمانی ورودی‌ها است که منجر به ارائه یک چارچوب تصمیم‌گیری عملیاتی مبتنی بر دقت و هزینه محاسباتی می‌شود.

واژه‌های کلیدی: سامانه‌های هشدار سیلاب، مدل‌های داده‌محور، یادگیری ماشین، یادگیری عمیق

استناد: طاوسی راد، ر.، پیری، ص.، و انصاری قوجقار، م. (۱۴۰۵). مقایسه عملکرد مدل‌های XBeach، LightGBM و DBN به‌منظور پیش‌بینی سیلاب (مطالعه موردی: حوزه‌آبخیز طالقان). *مدیریت جامع حوزه های آبخیز*، ۶(۳)، ۱۱۱-۹۵. https://doi.org/10.22034/iwm.2026.2077954.1254

حق چاپ:

حق چاپ برای نویسنده (گان) این مقاله محفوظ است. بر اساس قوانین انتشارات با دسترسی آزاد، تمام مطالعات چاپ شده در این نشریه به‌صورت آزاد در وب‌سایت نشریه برای عموم بدون پرداخت هزینه قابل‌دسترس است.

مقدمه

تغییرات اقلیمی و رشد شهرنشینی ریسک وقوع سیلاب‌های ناگهانی و شدتِ دبی بیشینه را افزایش داده‌اند و بنابراین پیش‌بینی دقیقِ دبی بیشینه ماهانه برای مدیریت ریسک و تصمیم‌گیری سریع عملیاتی ضروری است (Kuhaneswaran *et al.*, 2025). تحقیقات نشان داده‌اند که وقوع دبی‌های شدید می‌تواند تحت تأثیر تغییرات کوچک در الگوی بارش باشد به‌طوری که عدم دقت در پیش‌بینی بارش یا تاخیر زمانی اندک می‌تواند منجر به اشتباهات بزرگ در برآورد دبی سیلاب گردد (Okacha *et al.*, 2024). در بسیاری از مناطق، به‌ویژه در حوضه‌هایی که ایستگاه‌های محدودی در آن وجود دارد، شبکه‌های سنجش هیدرولوژیکی و باران‌سنجی به‌صورت پراکنده یا ناکافی هستند که این وضعیت به کاهش دقت پیش‌بینی دبی بیشینه ماهانه منجر می‌شود (Brunner *et al.*, 2021). علاوه بر کمبود داده، اطلاعات دریافتی اغلب با خطا، افت زمانی، نویز و ناسازگاری مواجه‌اند. این چالش‌های کیفیت داده ازجمله خرابی سنسورها، نبود همزمانی زمانی و داده‌های گمشده موجب می‌شوند تا مدل‌های پیش‌بینی، علی‌رغم طراحی پیچیده و دقیق، عملکرد واقعی دور از واقعیت داشته باشند (Yu *et al.*, 2025). ماهیت غیرخطی و چندعاملی فرآیند تولید سیلاب و انتقال آن در شبکه‌ی هیدرولوژیک از دلایل مهم کارکرد ناموفق مدل‌های پیش‌بینی هستند. پارامترهای تأخیر زمانی، تغییرات فضاییِ ناهمگن در بارش و کارایی زهکشی، نفوذپذیری خاک، پوشش زمین، ساختار شبکه رودخانه‌ای و بازتاب‌های جریان برگشتی در زمان اوج به هم وابسته‌اند. مدل‌های ساده اغلب قادر به لحاظ کردن این تعاملات پیچیده به‌صورت کامل و دقیق نیستند (Mahmood *et al.*, 2025). در نهایت، اکثر مدل‌های موجود فقط بر تخمین نقطه‌ای تمرکز دارند اما در مدیریت احتمال وقوع سیلاب، ارائه بازه اطمینان و بیان ریسک ناشی از خطا برای تصمیم‌گیرندگان بسیار حیاتی است تا بتوانند سناریوهای محتمل را پیش‌بینی کرده و اقدامات لازم را در زمان وقوع هریک از سناریوها در نظر بگیرند (Roohi *et al.*, 2025). در سال‌های اخیر، پژوهش‌هایی به‌منظور به‌کارگیری روش‌های یادگیری ماشین و یادگیری عمیق را برای پیش‌بینی جریان‌های رودخانه‌ای و سری‌های زمانی هیدرولوژیک بررسی کرده‌اند. برای مثال Alizadeh و همکاران (۲۰۱۸) در پژوهشی با هدف پیش‌بینی دبی ماهانه رودخانه، عملکرد چندین الگوریتم یادگیری ماشین ازجمله (ANN)[1] و مدل‌های رگرسیونی را ارزیابی کردند و نشان دادند که مدل‌های داده‌محور قادرند روابط غیرخطی موجود در سری‌های زمانی دبی ماهانه را با دقت بالاتری نسبت به روش‌های کلاسیک بازنمایی کنند. Nakhaei و همکاران (۲۰۲۴) در پژوهشی بر روی حوزه آبخیز رودخانه زرینه در ایران، مدل‌های شبکه‌های بازگشتی[2] و حافظه طولانی-کوتاه‌مدت را برای پیش‌بینیِ دبیِ ماهانه توسعه دادند و نشان دادند که انتخاب ساختار مناسب شبکه و متغیرهای ورودی تأثیر معناداری بر دقت پیش‌بینی دارد؛ به‌طوری‌که برخی ساختارهایِ پیشنهادیِ آن‌ها مقادیر بالای شاخص‌های NSE و R را در دوره‌های اعتبارسنجی مستقل ثبت کردند. مرور مطالعات پیشین نشان می‌دهدکه اگرچه پژوهش‌هایی از مدل‌هایِ یادگیریِ ماشین، یادگیری عمیق و مدل‌های فرآیندی برای پیش‌بینی جریان رودخانه استفاده کرده‌اند اما مقایسه هم‌زمان و کمی سه مدل مورد پژوهش به‌منظور پیش‌بینیِ دبیِ بیشینه ماهانه با در نظر گرفتن اثر حافظه زمانی و کارایی عملیاتی به‌ویژه در حوضه‌های کوهستانی ایران، تاکنون به‌طور جامع بررسی نشده است. شبکه‌های بیزی پویا (DBN)[3] به‌عنوان چارچوبی احتمالاتی شناخته می‌شوند که توانایی مدل‌سازی

1. Artificial Neural Networks
2. Recurrent Neural Network
3. Dynamic Bayesian Networks

وابستگی‌های زمانی و عدم قطعیت‌های سیستم‌های هیدرولوژیک را دارند (Chang *et al.*, 2023). پژوهش‌های قبلی نشان داده‌اند که مدل‌های مبتنی بر شبکه‌های بیزی می‌توانند به‌طور مؤثری اطلاعات پیش‌بینی هواشناسی و هیدرولوژیکی را ترکیب کرده و برآوردهای دبی سیلاب را بهبود بخشند (Goodarzi *et al.*, 2019). شبکه‌های عمیقِ اعتقادی[۴]، انواع دیگر شبکه‌های عمیق (DN)[۵] و دیگر روش‌های یادگیری عمیق[۶] در مطالعات اخیر برای تخمین جریان‌های آتی و استخراج الگوهای پیچیده زمانی از داده‌های هیدرومتریک با نتایج امیدوارکننده به‌کار رفته‌اند (Nayak *et al.*, 2022). شبیه‌سازی‌های فرآیندمحورِ هیدرودینامیکی مانند XBeach قادرند فیزیکِ جریان‌های نزدیک‌ساحل، انتقال رسوب و پاسخ مورفودینامیک را پیش‌بینی کرده و هنگامی که با داده‌های مشاهداتی و پیش‌بینی‌های هیدرولوژیکی ترکیب شوند، پایه‌ی فیزیکی دقیقی برای برآورد دبی فراهم می‌آورند (Roelvink *et al.*, 2009). الگوریتم‌های سبکِ گرادیانت‌بوس مانند LightGBM[۷] به الگوریتم‌های درخت تصمیم تعلق دارد و در حل و رگرسیون مسائل طبقه‌بندی مورد استفاده قرار گرفته است (Gan *et al.*, 2021). این الگوریتم‌ها به‌خاطر سرعت آموزش، کارایی در تجزیه تحلیل داده‌های بزرگ و عملکرد بالای پیش‌بینی، گزینه‌ی مناسبی برای یادگیری رابطه‌ی غیرخطی بین متغیرهای هواشناسی، هیدرولوژیکی و دبیِ خروجی هستند (Ke *et al.*, 2017).

اگرچه تاکنون مدل‌های گوناگونی برای پیش‌بینی دبی بیشینه ماهانه و برآورد سیلاب در حوزه‌های آبخیز ایران و سایر مناطق جهان به‌کار گرفته شده‌اند اما اغلب این مدل‌ها فیزیکی بوده و یا نیاز بالا به داده‌های دقیق تمرکز داشته‌اند و مدل‌های یادگیری ماشین بدون در نظر گرفتن ساختارهای زمانی و فصلی به کار گرفته شده‌اند. ازاین‌رو در بسیاری از موارد، پویایی زمانی سیستم‌های هیدرولوژیک و اثر تأخیر فصلی بر رفتار دبی به‌صورت جامع بررسی نشده است. از سوی دیگر، کاربرد هم‌زمان مدل‌های داده‌محور پیشرفته مانند LightGBM و DBN در کنار مدل فیزیکی XBeach به‌منظور تحلیل و پیش‌بینی دبی بیشینه ماهانه در حوزه‌های کوهستانی کشور به‌ویژه در حوزه آبخیز طالقان تاکنون گزارش نشده است. هدف از انجام این پژوهش، پیش‌بینی دبی بیشینه ماهانه به‌عنوان یک شاخص نماینده از رفتار سیلابی رودخانه در مقیاس زمانی ماهانه است. دبی بیشینه ماهانه به‌طور گسترده در مطالعات هیدرولوژیکی، مدیریت منابع آب و تحلیل ریسک سیلاب در مقیاس‌های میان‌مدت مورد استفاده قرار می‌گیرد و قادر است نوسانات سیلابی حوضه را در بازه‌های زمانی بزرگ‌تر منعکس نماید. اکنون نیاز روزافزون به مدل‌هایی است که ضمن برخورداری از دقت بالا، قابلیت اجرا و بروزرسانی سریع در سامانه‌های هشدار سیلاب داشته باشند. رویکرد ارائه‌شده در این تحقیق، ضمن پاسخ‌گویی به این نیاز می‌تواند به عنوان الگویی برای توسعه مدل‌های هوشمند و کارآمد در مدیریت منابع آب کشور مورد استفاده قرار گیرد.

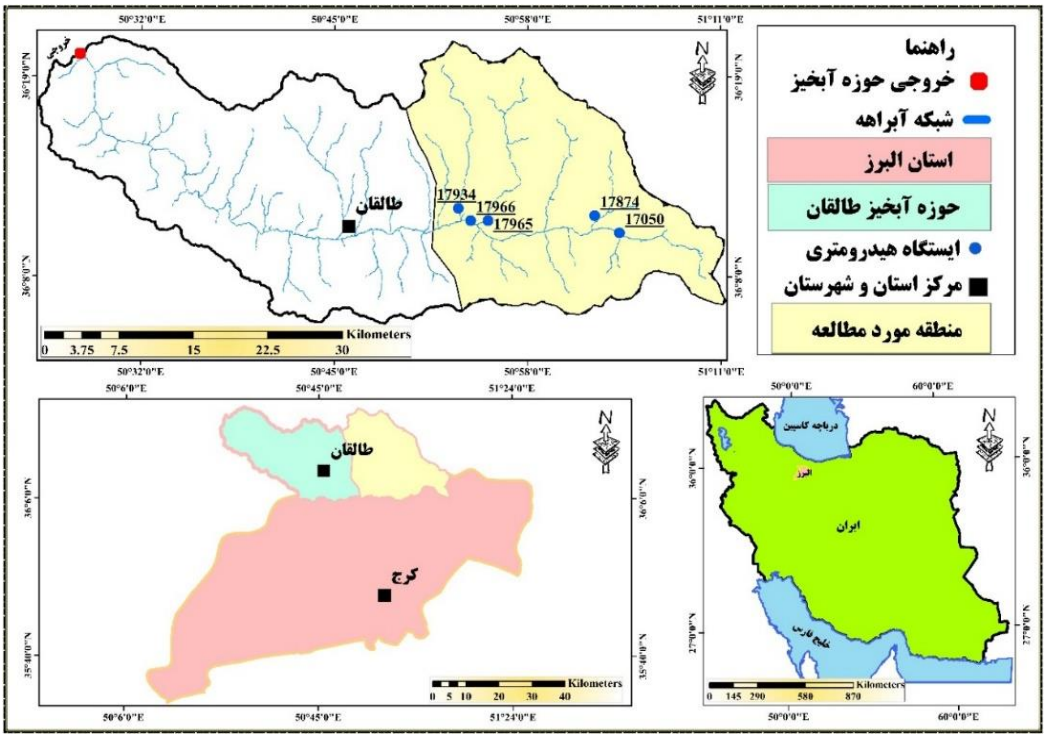
مواد و روش‌ها

منطقه مورد مطالعه و منابع داده‌ای

حوزه آبخیز طالقان در دامنه‌های جنوبی رشته‌کوه البرز و در شمال‌غرب شهرستان کرج واقع شده و یکی از زیرحوضه‌های کلیدی و بالادستی حوزه آبخیز سفیدرود به‌شمار می‌آید. این حوزه بین عرض‌های جغرافیایی ′۰۵ °۳۶ تا ′۲۰ °۳۶ شمالی و طول‌های ′۳۹ °۵۰ تا ′۱۱ °۵۱ شرقی قرار دارد (شکل ۱) و مساحت آن حدود ۱۲۴۳ کیلومترمربع برآورد می‌شود. فاصله این حوضه تا مرکز استان البرز (شهر کرج) حدود ۱۰۵ کیلومتر و تا شمال‌غرب تهران نزدیک به ۱۲۰ کیلومتر است. موقعیت کوهستانی، اختلاف ارتفاع زیاد و الگوی بارش

4. Deep Belief Networks
5. Deep Networks
6. Deep Learning
7. Light Gradient-Boosting Machine

نامنظم از عوامل اصلی در ناپایداری‌های هیدرولوژیکی و بروز سیلاب‌های فصلی در این حوزه محسوب می‌شوند (Ebrahimi *et al.*, 2020). در پژوهش حاضر از داده‌های دبی بیشینه روزانه پنج ایستگاه هیدرومتری فعال در محدوده حوضه طالقان طی دوره ۳۰ ساله (۱۴۰۰–۱۳۷۱) استفاده گردید که جدول ۱، مشخصات این ایستگاه‌ها را نشان می‌دهد.



شکل ۱ - منطقه حوزه آبخیز طالقان و ایستگاه‌های هیدرومتری موردمطالعه

Figure 1- Taleghan watershed area and hydrometric stations studied

جدول ۱ – مشخصات ایستگاه‌های هیدرومتری موردمطالعه حوزه‌آبخیز طالقان

Table 1 - Characteristics of the hydrometric stations studied in the Taleghan watershed

شماره ردیف	کد ایستگاه	نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی (درجه دقیقه)	عرض جغرافیایی (درجه دقیقه)	نام رودخانه
1	17050	گته ده	2353	51°-03′	36°-10′	شاهرود
2	17874	دهدر	2268	50°-12′	36°-10′	دهدر
3	17965	مهران جوستان	2049	50°-54′	36°-10′	شاهرود
4	17966	جوستان	1979	50°-54′	36°-10′	شاهرود
5	17934	علیزان جوستان	1953	50°-53′	36°-11′	شاهرود

مدل عددیِ شبیه‌ساز فرایندهای ساحلی (Xbeach)

XBeach یک مدل فرآیندی کد باز است که برای مدل‌سازی پاسخ سواحل و نواحی نزدیک به ساحل در شرایط طوفانی طراحی شده و قادر است مکانیک موج‌شکنی، جریان‌های سطحی و تغییرات مورفودینامیکی را شبیه‌سازی کند (Roelvink *et al.*, 2009). گروه‌های موج را با استفاده از میانگین‌گیری موج کوتاه شبیه‌سازی می‌کند و به کاربران گزینه‌هایی برای انتخاب از حالت موج ثابت، حالت موج‌ضربه‌ای و حالت غیر هیدرواستاتیک را می‌دهد. معادلات آب کم‌عمق از فرمول میانگین لاگرانژی تعمیم‌یافته برای

تبدیل جریان‌های ناشی از موج و جریان‌های زیرسطحی استفاده می‌کنند. روابط بین سرعت لاگرانژی u^L، سرعت اویلری u^E و سرعت استوکس u^S در معادله مومنتوم و معادله پیوستگی به صورت رابطه (۱) و (۲) نشان داده شده است (Roelvink *et al.*, 2010):

$$u^L = u^E + u^S \quad (۱)$$

$$v^L = v^E + v^S \quad (۲)$$

که در آن u^S و v^S به ترتیب مؤلفه‌های رانش در جهت‌های x و y هستند.

مدل انتقال رسوب از معادله همرفت پخش میانگین عمقی استفاده می‌کند و در رابطه (۳) مشخص شده است:

$$\frac{\partial hC}{\partial t}+\frac{\partial hCu^E}{\partial x}+\frac{\partial hCv^E}{\partial y}+\frac{\partial}{\partial x}\left(D_h h\frac{\partial C}{\partial x}\right)+\frac{\partial}{\partial y}\left(D_h h\frac{\partial C}{\partial y}\right)=\frac{hCeq-hC}{T_s} \quad (۳)$$

که در آن C نشان دهنده غلظت رسوب میانگین عمقی است. Ceq به غلظت رسوب تعادلی (بار معلق یا بار بستر) اشاره دارد. D_h ضریب انتشار رسوب، T_s زمان انطباق مورد استفاده برای نشان دادن میزان جذب رسوب است و می‌توان آن را با عمق h و سرعت ته‌نشینی رسوب تقریب زد. همچنین h نشان دهنده عمق آب و ω_s نشان دهنده سرعت ته نشینی رسوب است (Gai *et al.*, 2025) که در رابطه (۴) قابل مشاهده است:

$$T_s = max\left(0.05\frac{h}{\omega_s}, 0.2\right)s \quad (۴)$$

اگرچه مدل XBeach در اصل برای شبیه‌سازی فرآیندهای ساحلی توسعه یافته است اما در پژوهش حاضر از این مدل به‌عنوان یک ابزار عددی هیدرودینامیکی برای شبیه‌سازی پاسخ جریان در شرایط سیلابی استفاده شده است. در این راستا، پارامترهای مرتبط با موج و مورفودینامیک غیرفعال شده و تمرکز مدل بر حل معادلات جریان کم‌عمق در بستر رودخانه‌ای قرار گرفته است. بدین ترتیب، خروجی XBeach به‌عنوان یک مدل فیزیکی مرجع برای مقایسه عملکرد با مدل‌های داده‌محور مورد استفاده قرار گرفت. در این پژوهش، داده‌های هیدرولوژیکی حوضه کوهستانی طالقان شامل دبی بیشینه ماهانه به‌عنوان شرایط مرزی ورودی مدل XBeach مورد استفاده قرار گرفتند. بدین منظور، مدل در حالت هیدرودینامیکی ساده‌شده اجرا شد و مؤلفه‌های مرتبط با موج‌سازی، مورفودینامیک و فرآیندهای ساحلی غیرفعال گردیدند. شبکه محاسباتی مدل بر اساس هندسه ساده‌شده بستر رودخانه‌ای تعریف و دبی‌های مشاهده‌ای به‌صورت هیدروگراف جریان در مرز بالادست اعمال شدند. خروجی مدل، شامل تغییرات تراز آب و سرعت جریان به‌عنوان پاسخ عددی سیستم برای مقایسه با مدل‌های داده‌محور مورد استفاده قرار گرفت.

مدل یادگیری ماشین تقویت گرادیانی سبک (LightGBM)

این الگوریتم مبتنی بر بافت‌نگار[8]، سرعت آموزش را افزایش داده و مصرف حافظه را توسط استراتژی رشد برگ به برگ درختان با حداکثر محدودیت عمق کاهش می‌دهد. طبق استراتژی رشد سطح به سطح، برگ‌های روی یک لایه به طور همزمان تقسیم می‌شوند. برگ‌های روی یک لایه به طور نامتمایز رفتار می‌شوند در حالی که بهره اطلاعات متفاوتی دارند. بهره اطلاعات نشان‌دهنده کاهش مورد انتظار در آنتروپی ناشی از تقسیم گره‌ها بر اساس ویژگی‌ها است که در رابطه ۵ و ۶ نمایش داده شده است:

$$lg(B,V) = En(B) - \sum_{v\epsilon(V)}\frac{|B_V|}{B}En(B_V) \quad (۵)$$

$$En(B) = \sum_{d=1}^{D} -p_{d\log 2}\, p_{d'} \quad (۶)$$

که در آن $En(B)$ آنتروپی اطلاعات مجموعه B است. p_d آنتروپی اطلاعات مجموعه B است. D تعداد دسته‌ها است. v مقدار ویژگی V است و B_V زیرمجموعه‌ای از

8. Histogram

B است که برای آن ویژگی مقدار V دارد (Szczepanek, 2022).

مدل LightGBM در پژوهش حاضر با استفاده از پیاده‌سازی استاندارد و با هدف یادگیری روابط غیرخطی بین داده‌های دبی ماهانه آموزش داده شد. برای بهبود عملکرد مدل، تنظیم پارامترهای اصلی شامل تعداد درخت‌ها، عمق بیشینه درخت و نرخ یادگیری به‌صورت آزمون و خطا و بر اساس کمینه‌سازی خطای پیش‌بینی در دوره آموزش انجام شد. داده‌ها به‌صورت زمانی به دو بخش آموزش (۸۰ درصد) و آزمون (۲۰ درصد) تقسیم شدند تا ترتیب زمانی سری حفظ شود. به‌منظور جلوگیری از بیش‌برازش، عملکرد مدل در مرحله آزمون مستقل ارزیابی و شاخص‌های آماری بر اساس داده‌های آزمون گزارش گردیدند.

مدل یادگیری عمیق شبکه باور عمیق (DBN)

مدل یادگیریِ عمیقِ شبکه باور عمیق، ساختاری گرافیکی برای مدل‌سازی وابستگی‌های زمانیِ متغیرهای تصادفی است؛ این مدل قادر است وابستگی‌های درون برش و بین برش را مدل‌سازی کند و به‌راحتی مشاهدات چندمنبعی را با توزیع‌های احتمالاتی تلفیق نماید (Murphy & Weiss, 2013). مدل یادگیریِ عمیقِ شبکه باور عمیق به عنوان بسطی از شبکه باور، مدل‌سازی محیطی را قادر می‌سازند تا بر این ضعف غلبه کرده و فرآیندهای پویا را مدل‌سازی کند و بنابراین تکامل یک فرآیند محیطی را در طول زمان مشخص کند. روابط زمانی و کشف الگو را از طریق برش زمانی در ثبت پیچیدگی و ماهیت متغیر یک مسئله نشان می‌دهند. برنامه‌های مدل‌سازی اکولوژیکی و محیطی با استفاده از این مدل کمیاب هستند. به این دلیل است که الگوریتم‌های مدل یادگیریِ عمیقِ شبکه باور عمیق در بسته‌های نرم‌افزاری تجاری محبوب کمتر در دسترس هستند و کم‌تر پشتیبانی می‌شوند (Chang *et al.*, 2023).

ویژگی تعریف‌کننده‌ی شبکه‌های باور عمیق، مدل‌سازی وابستگی Xi(t)، برای هر i، به سایر کمیت‌ها است یعنی تعریف تکامل فرآیند تصادفی X(t) → X(t + 1). به طور رسمی برای هسته‌ی احتمال که تکرارهای فرآیند تصادفی را تعریف می‌کند، وابستگی باید مارکوفی باشد با اثرات خودرگرسیونی با تأخیر زمانی اضافی که در رابطه (۷) نمایش داده شده است:

$$p(X_i(t+1) \in A) = f_i\big(X(t), X_{j\neq i}(t+1), \{X_i(t-\tau)\}\tau = 1, \dots, p, Z\big) \quad (۷)$$

که در آن A مجموعه‌ای در جبر σ بورل X است. یعنی، هسته گذار می‌تواند به وضعیت فعلی سایر متغیرهای تصادفی، مقادیر متغیرهای تصادفی در زمان قبل، متغیرهای مستقل از زمان Z و همچنین احتمالاً یک اثر خودرگرسیونی از طریق وابستگی به وابسته باشد (Kungurtsev *et al.*, 2024).

یک مدل شبکه باور عمیق در قالب دو متغیر تعریف می‌شود که در آن یک شبکه باور است که احتمال پیشین را تعریف می‌کند و شبکه بیزینِ زمانیِ دوبخشی (TBN2) که با استفاده از یک گراف نظارت‌شده بدون حلقه (Graph Acyclic Directed) به شکل رابطه ۸ تعریف می‌شود:

$$P(Z_t|Z_{t-1}) = \prod_{i=1}^{N} P\left(Z_t^i | P_a\left(Z_t^i\right)\right) \quad (۸)$$

که در آن Z_t^i، i مین گره در زمان t است و $P_a\left(Z_t^i\right)$ والدین Z_t^i در گراف هستند. گره‌ها در بخش اول از یک شبکه بیزینِ زمانیِ دوبخشی، هیچ پارامتر مرتبطی با آن‌ها ندارند اما هر گره در بخش دوم یک ارتباط توزیع احتمال شرطی دارند که را برای همه t>1 تعریف می‌کند (Ebrahimi *et al.*, 2018).

در این پژوهش، مدل شبکه باور عمیق به‌صورت یک ساختار چندلایه شامل یک لایه ورودی، دو لایه پنهان و یک لایه خروجی پیاده‌سازی شد. تعداد نورون‌های لایه‌های پنهان به‌صورت آزمون و خطا و با هدف کمینه‌سازی خطای پیش‌بینی تعیین گردید. فرآیند آموزش شبکه شامل دو مرحله پیش‌آموزش بدون نظارت با استفاده از ماشین بولتزمن محدود (RBM) و تنظیم نهایی وزن‌ها به‌صورت نظارت‌شده با الگوریتم

پس‌انتشار خطا بود. تابع فعال‌سازی سیگموئید برای لایه‌های پنهان و تابع خطی برای لایه خروجی مورد استفاده قرار گرفت. پیاده‌سازی مدل DBN در محیط نرم‌افزاری R انجام شد.

مدل‌های پیش‌بینی

به‌منظور پیش‌بینی سیلاب، سه مدل عددی، یادگیری ماشین و یادگیریِ عمیقِ LightGBM، Xbeach و DBN مورد مطالعه و آزمایش قرار گرفتند. سپس با استفاده از شاخص‌های ارزیابی دقت، مناسب‌ترین مدل برای هر پیش‌بینی انتخاب شد. در این فرآیند، تعداد فصل‌های گذشته به عنوان عامل اصلی برای پیش‌بینی ماه آتی در نظر گرفته شد که شامل یک، دو، سه یا چهار فصل قبل از داده‌های دبی بیشینه متوسط ماهانه بود. در ترکیب اول، پیش‌بینی دبی بیشینه ماهانه برای ماه بعدی با تکیه بر سری زمانی دبی با یک فصل تأخیر انجام شد. به این صورت که برای برآورد در زمان $(t+1)$، از مقدار دبی در زمان (t) استفاده گردید. در ترکیب دوم، پیش‌بینی ماه آتی بر اساس داده‌های دبی تا دو فصل پیشین صورت گرفت، در ترکیب سوم، پیش‌بینی ماه آتی بر اساس داده‌های دبی تا سه فصل پیشین صورت گرفت و در ترکیب چهارم، پیش‌بینی ماه آتی بر اساس داده‌های دبی تا ۴ فصل یا یک‌سال پیشین صورت گرفت. مدل‌های پیش‌بینی به‌صورت ترکیب‌های ۱ تا ۴ نشان داده شده است:

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

معیارهای ارزیابی مدل

در پژوهش حاضر برای مقایسه نتایج و ارزیابی مدل‌ها از چهار معیار اصلی استفاده گردید. ریشه میانگین مربعات خطا (RMSE): میزان پراکندگی خطا بین مقادیر واقعی و پیش‌بینی‌شده را بیان می‌کند.. مقدار کمتر به معنی دقت بالاتر مدل است و این معیار با رابطه ۹ محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(o_i - f_i)^2} \quad (۹)$$

در روابط 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 می‌باشد.

میانگین قدر مطلق خطا (MAE): این معیار متوسط مقدار مطلق اختلاف بین داده‌های مشاهده‌ای و پیش‌بینی‌شده را نشان می‌دهد و با رابطه ۱۰ محاسبه می‌شود

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|o_i - f_i| \quad (۱۰)$$

شاخص کارایی نش- ساتکلیف (NS): نشان‌دهنده میزان انطباق مقادیر پیش‌بینی‌شده با مقادیر مشاهده‌شده است و مقدار آن بین منفی بی‌نهایت تا ۱ متغیر است. مقدار نزدیک به ۱ بیان‌گر عملکرد بسیار خوب مدل است و با رابطه ۷ محاسبه می‌شود.

$$NS = 1 - \frac{\sum_{i=1}^{n}(o_i - f_i)^2}{\sum_{i=1}^{n}(\bar{o} - o_i)^2} \quad (۱۱)$$

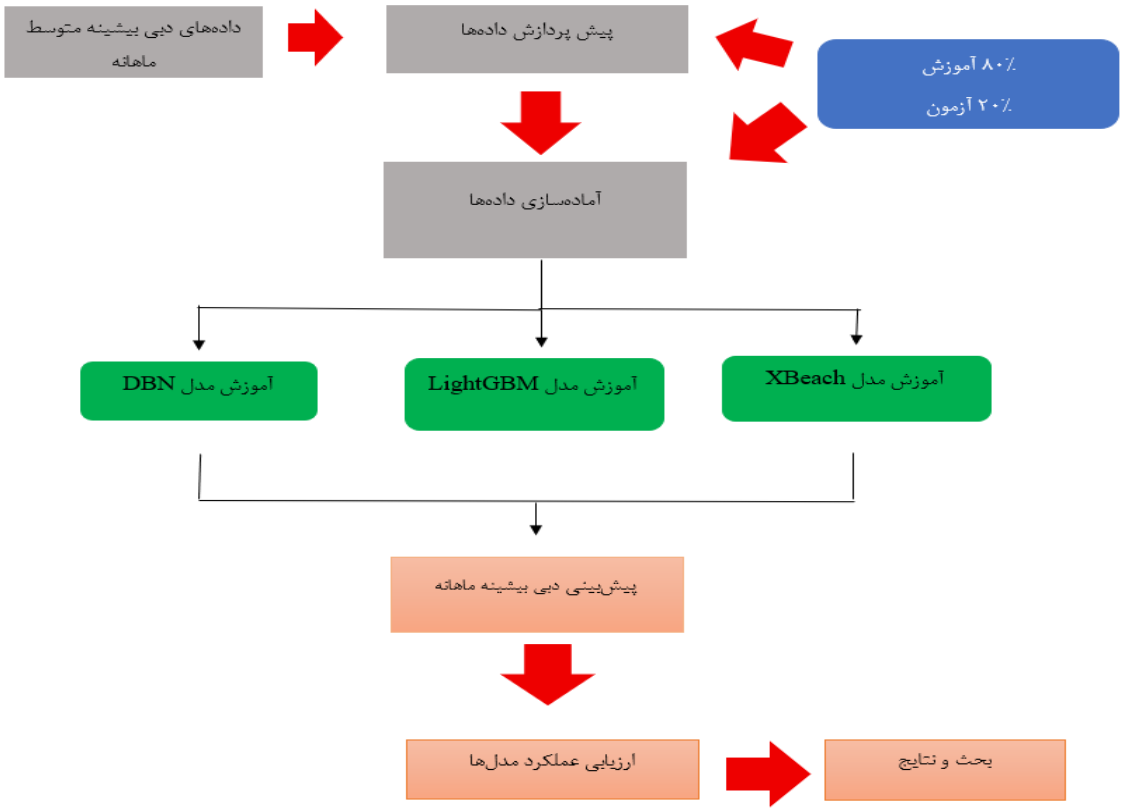
ضریب همبستگی (R): این شاخص میزان رابطه خطی بین داده‌های مشاهده‌ای و پیش‌بینی‌شده را مشخص می‌کند. مقدار آن در بازه {۱- تا ۱} قرار دارد و مقدار نزدیک به ۱ بیان‌گر همبستگی مثبت قوی است. با کمک رابطه ۱۲ ضریب همبستگی محاسبه می‌شود.

$$R = \frac{\frac{1}{n}\sum_{i=1}^{n}(o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n}\sum_{i=1}^{n}(o_i - \bar{o})^2}\sqrt{\sum_{i=1}^{n}(f_i - \bar{f})^2}} \quad (۱۲)$$

به‌منظور ارزیابی پایداری و قابلیت تعمیم مدل‌ها از روش صحت‌سنجی متقاطع زمانی استفاده شد. در این روش، داده‌های دبی بیشینه ماهانه با حفظ ترتیب زمانی به چندین بازه آموزش و آزمون تقسیم شدند. شاخص‌های ارزیابی مورد استفاده برای هر تکرار محاسبه شده و میانگین عملکرد مدل‌ها به‌عنوان معیار نهایی گزارش شد.

مراحل انجام پژوهش

پژوهش حاضر به‌منظور مقایسه سه مدل عددی، یادگیری ماشین و یادگیری عمیقِ Xbeach، LightGBM و DBN در پیش‌بینی احتمال وقوع سیلاب در منطقه طالقان صورت گرفت. در ابتدا داده‌های موردنیاز دبی بیشینه متوسط ماهانه برای پنج ایستگاه هیدرومتری منطقه طالقان تهیه گردید و سپس با استفاده از نرم‌افزار برنامه‌نویسی R، دبی بیشینه ماهانه سیلاب استخراج و به‌عنوان خروجی مدل‌ها مورد استفاده قرار گرفت. به‌منظور پیاده‌سازی و ارزیابی مدل‌ها، داده‌های دبی بیشینه ماهانه به دو بخش آموزش و آزمون تقسیم شدند. به‌گونه‌ای که ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمون مورد استفاده قرار گرفت. فرآیند آموزش مدل‌های داده‌محور شامل تنظیم پارامترهای داخلی به‌منظور کمینه‌سازی خطای پیش‌بینی در دوره آموزش بود. برای جلوگیری از بیش‌برازش، عملکرد مدل‌ها در مرحله اعتبارسنجی مستقل ارزیابی شد و شاخص‌های آماری صرفاً بر اساس داده‌های آزمون گزارش گردیدند. در مورد مدل عددی XBeach، پارامترهای هیدرودینامیکی مدل به‌صورت دستی و بر اساس تطابق خروجی با مقادیر مشاهده‌ای دبی تنظیم شدند. نمودار جریانی پژوهش حاضر در شکل ۲ نمایش داده شده است.



شکل۲- نمودار جریانی مراحل انجام پژوهش

Figure 2- Flowchart of the research process

نتایج و بحث

نتایج ارائه‌شده در این بخش مربوط به پیش‌بینی دبی بیشینه ماهانه سیلاب در ایستگاه‌های مورد مطالعه است. تحلیل نتایج ارائه‌شده در جداول ۲ تا ۴ نشان می‌دهد که مدل یادگیری ماشین LightGBM در تمامی سناریوها به‌صورت مداوم عملکرد بهتری نسبت به دو مدل دیگر داشته است. این برتری در شاخص‌های معیارِ عملکرد به‌صورت کاهش خطا در RMSE، MAE و افزایش توانایی بازتولید نوسان‌های زمانی مقادیر بالاتر در NS و R مشهود است. به‌طوری‌که این مدل

شاخص نش- ساتکلیف ۰/۹۰۸ تا ۰/۹۳۱ را به ثبت رساند که این امر بیان‌گر عملکرد کاملاً موفق این مدل در پیش‌بینی دبی بیشینه ماهانه داشته است. همچنین مقدار همبستگی ۰/۸۹۶ تا ۰/۹۱۸ به‌ثبت رسیده در این مدل نشان می‌دهد که مدل LightGBM به‌خوبی الگوهای موجود در داده‌ها و تاخیرهای زمانی را آموخته و مورد پیش‌بینی قرار داده است. از طرفی ثبتِ مقادیر خطای RMSE بین ۰/۰۷۹ تا ۰/۱۳۱ در ۴ ایستگاه مهران جوستان، علیزان جوستان، گته ده و دهدر نشان از دقت بالای این مدل در روندیابیِ الگوهای موجود دارد. لازم به ذکر است که در تمامی مدل‌ها، ایستگاه جوستان که بیش‌ترین حجم و دامنه تغییرات دبی را در میان ایستگاه‌های مورد مطالعه دارد، مقادیر بالاتری از خطای RMSE و MAE را نسبت به سایر ایستگاه‌ها ثبت کرده است. این موضوع را می‌توان به نوسانات شدیدتر، وقوع مقادیر حدی و پیچیدگیِ هیدرولوژیکیِ بالاتر این ایستگاه نسبت داد که پیش‌بینیِ دقیقِ دبی بیشینه ماهانه را چالش‌برانگیزتر می‌سازد. با این حال حتی در این ایستگاه نیز الگوی برتری نسبی مدل‌ها حفظ شده و مدل LightGBM در مقایسه با مدل‌های DBN و XBeach خطای کم‌تری از خود نشان داده است که بیان‌گر پایداری عملکرد این مدل در شرایط داده‌ای پیچیده‌تر می‌باشد. به بیان کلّی، LightGBM در مجموعه‌های آموزش و همچنین در مجموعه‌های آزمون پایداری و دقت بهتری نشان داد؛ این الگوی برتری در تمام ترکیب‌های زمانی از یک فصل تا چهار فصل گذشته مشاهده می‌شود. این نتیجه هم‌راستا با مطالعه Zhao و همکاران (۲۰۲۵) است که نشان داده‌اند الگوریتم‌های نظیر LightGBM به‌خصوص در مسائل هیدرولوژیک و نقشه‌برداری ریسک پیش‌بینی نقطه‌ای سیلاب، عملکرد برتر و پایدارتری نسبت به سایر الگوریتم‌های مرسوم ارائه می‌دهند.

جدول ۲ - نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل LightGBM

Table 2- Statistical results of input data for modeling and forecasting floods with the LightGBM model

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوستان	4	0.974	0.345	0.331	0.924	0.931	0.352	0.338	0.918
	3	0.969	0.348	0.334	0.919	0.928	0.355	0.342	0.912
	2	0.963	0.351	0.335	0.914	0.923	0.358	0.343	0.907
	1	0.957	0.354	0.337	0.911	0.917	0.359	0.348	0.902
مهران جوستان	4	0.974	0.113	0.093	0.923	0.929	0.121	0.097	0.917
	3	0.968	0.114	0.095	0.918	0.927	0.123	0.101	0.911
	2	0.961	0.117	0.095	0.913	0.922	0.125	0.101	0.906
	1	0.956	0.119	0.098	0.907	0.916	0.125	0.103	0.901
علیزان جوستان	4	0.972	0.087	0.071	0.921	0.928	0.091	0.077	0.916
	3	0.966	0.088	0.072	0.916	0.925	0.091	0.079	0.909
	2	0.959	0.089	0.072	0.912	0.921	0.092	0.081	0.905
	1	0.954	0.091	0.074	0.906	0.914	0.094	0.082	0.899
گته ده	4	0.973	0.092	0.075	0.919	0.927	0.094	0.083	0.915
	3	0.965	0.093	0.075	0.915	0.924	0.096	0.085	0.908
	2	0.957	0.093	0.076	0.912	0.919	0.097	0.087	0.904
	1	0.953	0.095	0.077	0.904	0.911	0.099	0.089	0.896
دهدر	4	0.971	0.066	0.047	0.917	0.925	0.071	0.051	0.914
	3	0.964	0.068	0.048	0.914	0.923	0.073	0.052	0.907
	2	0.956	0.069	0.049	0.909	0.917	0.075	0.054	0.903
	1	0.954	0.071	0.051	0.903	0.908	0.079	0.056	0.896

نتایج نشان می‌دهد که DBN نسبت به مدل عددی فیزیکی XBeach در معیارهای دقت اغلب اندکی بهتر عمل کرده است؛ اما این تفاوت در اغلب ایستگاه‌ها و ترکیب‌ها معنادار نبود و فاصله عملکردها ناچیز است.

به‌طوری‌که مدل DBN شاخص نش- ساتکلیف ۰/۸۶۴ تا ۰/۸۸۸ را ثبت کرده است اما این مقدار در مدل XBeach بین ۰/۸۳۴ تا ۰/۸۶۲ به ثبت رسیده است. همچنین مقایسه مقادیر همبستگی ثبت شده به‌وسیله این دو مدل نشان می‌دهد که مدل DBN مقادیر ۰/۸۱۶ تا ۰/۸۳۲ را بدست آورده. مدل XBeach مقادیر ۰/۸۰۷ تا ۰/۸۲۳ را ثبت کرده که نشان از روندیابیِ صحیح و درک الگوهای موجود شده و مقادیر آزمون را نسبتاً مطابق با مقادیر آموزش ثبت کرده است. از سوی دیگر، DBN قابلیت ذاتی و مشخصی در بیان عدم‌قطعیت و ارائه توزیع احتمالی خروجی‌ها دارد؛ این امر به پیش‌بینی دبی کمک می‌کند اما با هزینه‌های زیادی همراه است. نیاز به برآورد پارامترها و ساختار، سنگینی محاسباتیِ استنتاج خصوصاً برای مدل‌های مرتبه بالاتر یا حالت‌های غیرگوسی و پیچیدگی پیاده‌سازی و نگهداری مدل در محیط عملیاتی ازجمله هزینه‌هاست. این نکته در مطالعات مشابه که کاربرد DBN را برای مسائل زمان متغیر هیدرولوژیک یا کنترل لحظه‌ای بررسی کرده‌اند نیز تکرار شده است. DBN ابزار قدرتمندی برای مدل‌سازی دینامیک سیستم و عدم‌قطعیت است اما هزینه‌های محاسباتی و نیاز به داده تخصص را افزایش می‌دهد. با توجه به این نکات به‌دلیل معنادار نبودن تفاوت عملکرد دو مدل DBN و XBeach، پیشنهاد پژوهش حاضر این است که LightGBM به‌عنوان نخستین گزینه عملیاتی و پژوهشی انتخاب شود و XBeach به‌عنوان گزینه دوم جایگزین اقتصادی‌ترِ DBN لحاظ گردد؛ زیرا XBeach علی‌رغم این‌که یک مدل فرایندی فیزیکی است و قابلیت فیزیکی بالایی دارد در عمل پیاده‌سازی و اجرای برخط کمتر هزینه‌بر و پیچیده از DBN است و در بسیاری از سناریوها عملکرد نزدیک به DBN ارائه می‌دهد.

جدول ۳ – نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل Xbeach

Table 3- Statistical results of input data for modeling and forecasting floods with the Xbeach model

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوستان	4	0.823	1.432	1.321	0.843	0.862	1.458	1.356	0.823
	3	0.868	1.435	1.325	0.835	0.854	1.461	1.359	0.821
	2	0.863	1.439	1.327	0.831	0.847	1.467	1.363	0.817
	1	0.859	1.441	1.331	0.824	0.841	1.471	1.368	0.809
مهران جوستان	4	0.871	0.437	0.423	0.842	0.861	0.451	0.425	0.822
	3	0.867	0.441	0.424	0.834	0.852	0.454	0.428	0.819
	2	0.861	0.443	0.427	0.829	0.844	0.455	0.431	0.816
	1	0.853	0.444	0.431	0.821	0.837	0.457	0.434	0.812
علیزان جوستان	4	0.871	0.371	0.352	0.841	0.859	0.383	0.364	0.822
	3	0.866	0.372	0.355	0.832	0.851	0.388	0.365	0.817
	2	0.859	0.374	0.359	0.826	0.843	0.391	0.368	0.814
	1	0.848	0.377	0.361	0.819	0.836	0.391	0.371	0.811
گته ده	4	0.869	0.379	0.362	0.838	0.858	0.393	0.374	0.821
	3	0.865	0.381	0.362	0.831	0.849	0.394	0.375	0.816
	2	0.858	0.383	0.364	0.825	0.842	0.395	0.378	0.813
	1	0.846	0.385	0.367	0.817	0.835	0.397	0.381	0.809
دهدر	4	0.867	0.303	0.294	0.837	0.857	0.313	0.297	0.821
	3	0.864	0.305	0.295	0.829	0.848	0.315	0.297	0.815
	2	0.855	0.308	0.295	0.824	0.841	0.315	0.299	0.811
	1	0.843	0.312	0.298	0.816	0.834	0.221	0.303	0.807

جدول ۴ – نتایج آماری داده های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل DBN

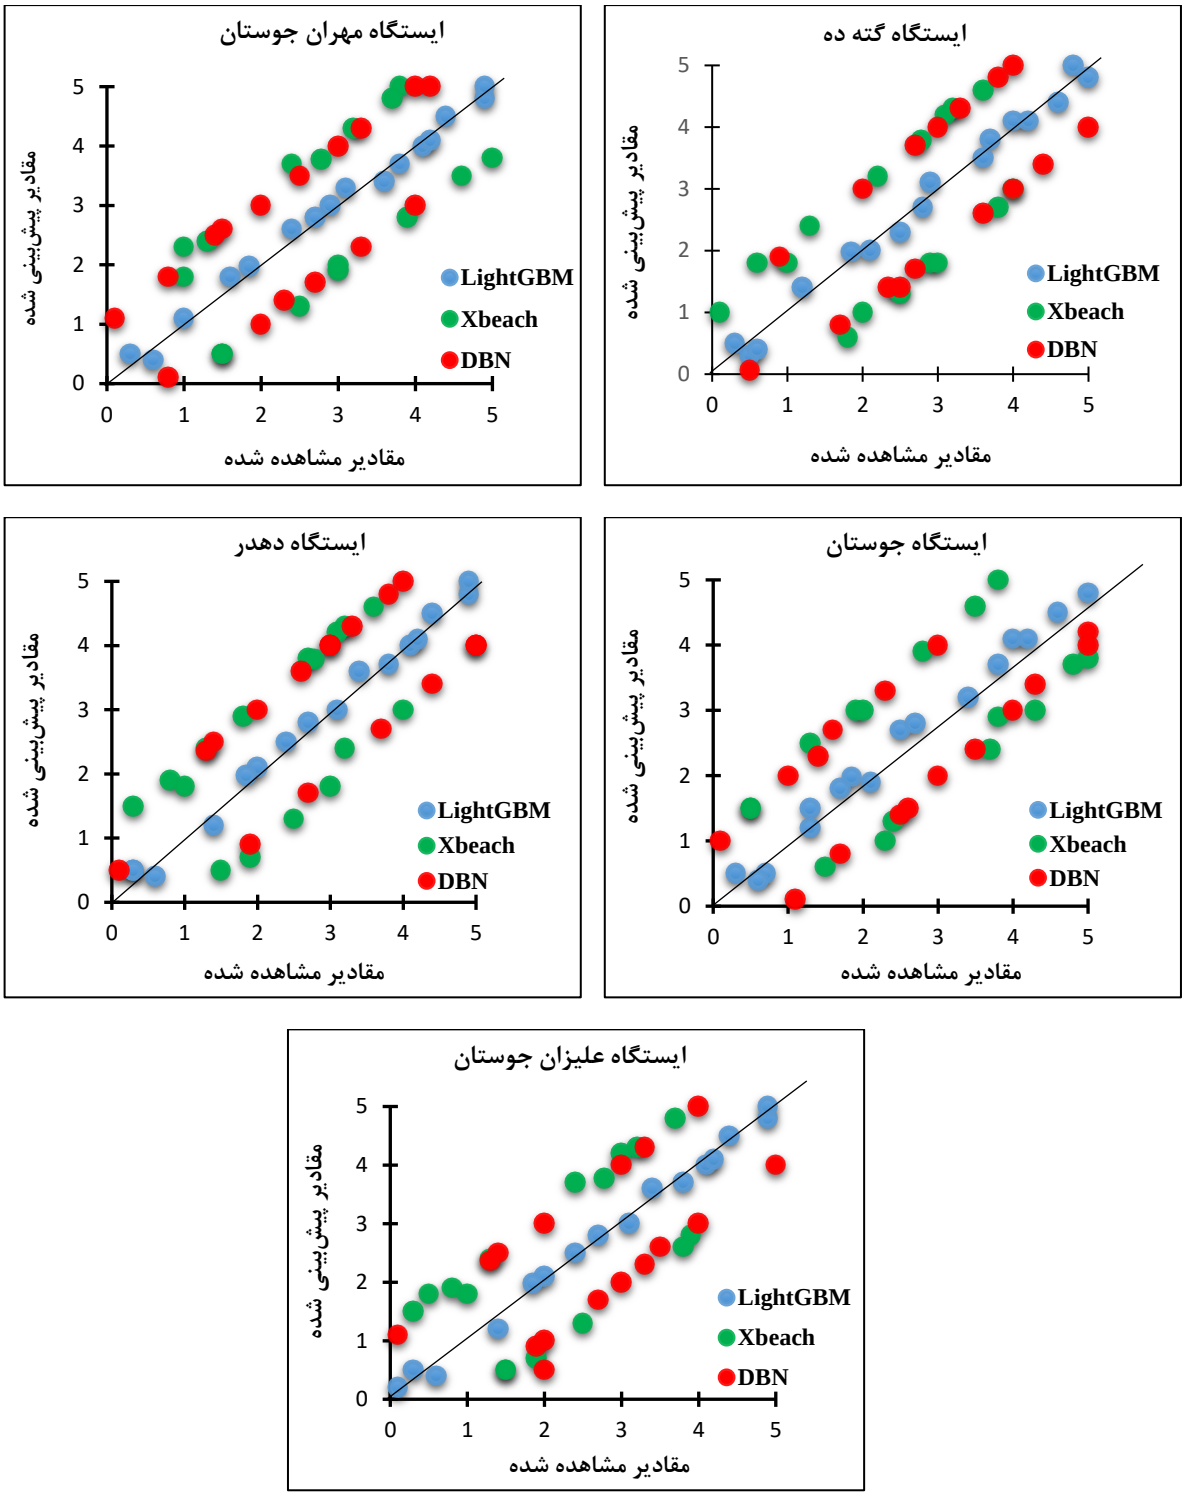
Table 4- Statistical results of input data for modeling and forecasting floods with the DBN model

ایستگاه	شماره ترکیب	مجموعه داده آموزش	مجموعه داده آزمون

R	MAE	RMSE	NS	R	MAE	RMSE	NS		
0.832	1.307	1.409	0.881	0.856	1.302	1.403	0.893	4	جوستان
0.827	1.312	1.413	0.877	0.849	1.304	1.407	0.887	3	
0.823	1.314	1,417	0.873	0.841	1.307	1.411	0.883	2	
0.819	1.418	1.419	0.869	0.835	1.311	1.413	0.877	1	
0.832	0.395	0.419	0.878	0.854	0.392	0.414	0.892	4	مهران جوستان
0.826	0.401	0.422	0.876	0.847	0.398	0.416	0.885	3	
0.822	0.406	0.425	0.872	0.838	0.402	0.419	0.882	2	
0.818	0.408	0.429	0.868	0.831	0.404	0.422	0.875	1	
0.831	0.335	0.363	0.877	0.851	0.331	0.353	0.891	4	علیزان جوستان
0.825	0.338	0.365	0.875	0.846	0.334	0.354	0.884	3	
0.821	0.341	0.367	0.871	0.835	0.338	0.357	0.881	2	
0.817	0.343	0.371	0.866	0.832	0.339	0.357	0.873	1	
0.829	0.344	0.373	0.876	0.849	0.341	0.361	0.889	4	گته ده
0.824	0.347	0.375	0.874	0.844	0.342	0.362	0.881	3	
0.819	0.351	0.378	0.869	0.833	0.344	0.364	0.879	2	
0.816	0.354	0.381	0.865	0.828	0.347	0.367	0.868	1	
0.828	0.261	0.287	0.875	0.847	0.259	0.284	0.888	4	دهدر
0.823	0.265	0.291	0.873	0.843	0.263	0.287	0.881	3	
0.818	0.271	0.293	0.868	0.832	0.264	0.289	0.877	2	
0.816	0.274	0.295	0.864	0.826	0.265	0.291	0.866	1	

در بررسی چهار ترکیب زمانی مشاهده شد که افزایش طول حافظه زمانی تا یک میزان مشخص می‌تواند دقت مدل را بهبود دهد. بررسی اثر دوره‌تناوب زمانی بر عملکرد مدل‌ها نشان داد که انتخاب پنجره زمانی ورودی نقش تعیین‌کننده‌ای در دقت پیش‌بینیِ دبیِ بیشینه ماهانه سیلاب دارد. نتایج حاکی از آن است که افزودن اطلاعات تأخیری تا مقیاس فصلی موجب بهبود شاخص‌های عملکرد به‌ویژه در مدل LightGBM شده است؛ با این حال، افزایش بیش‌ازحد عمق حافظه زمانی در برخی ایستگاه‌ها ممکن است منجر به کاهش دقت مدل شود. این رفتار نشان‌دهنده وجود یک دوره‌تناوب بهینه در داده‌هایِ دبیِ ماهانه است که مدل‌هایِ یادگیریِ ماشین نسبت به آن حساس هستند. این یافته‌ها با نتایج مطالعه Kisi و همکاران (۲۰۱۹) هم‌راستا است که نشان دادند با لحاظ‌کردن سیگنال‌های اقلیمی و هیدرولوژیکی با مقیاس زمانی مناسب می‌توان عملکرد مدل‌هایِ یادگیریِ ماشین را بهبود دهد در حالی که استفاده از تأخیرهای زمانی نامتناسب یا بیش‌ازحد ممکن است موجب افزایش نویز و کاهش کارایی مدل شود. مدل‌هایِ یادگیریِ ماشین در مسائل هیدرولوژیکی معمولاً از تعداد محدودی تاخیر مرتبط سود می‌برند و انتخاب پنجره زمانی بهینه باید بر مبنای آزمون و اعتبارسنجی زمانی صورت گیرد. نتیجه پژوهش حاضر که چهار سناریو را مورد بررسی قرار داد این امکان را داد کهLightGBM در همه سطوح حافظه عملکرد قوی و پایدار دارد در حالی که DBNو XBeach حساسیتِ بیشتری به ترکیبِ زمانی از خود نشان داده‌اند. برتری مدل LightGBM نسبت به مدل‌های DBN و XBeach را می‌توان به توانایی بالای این الگوریتم در یادگیری روابط غیرخطی و پیچیده از داده‌های سری زمانی نسبتاً محدود دبی ماهانه نسبت داد. ساختار مبتنی‌بر درخت‌های تصمیم در LightGBM امکان شناسایی الگوهای آستانه‌ای و تعامل بین مقادیر تأخیری دبی را فراهم می‌کند در حالی که این نوع روابط در مدل‌های عمیق مانند DBN نیازمند حجم داده بیشتر برای آموزش پایدار هستند. عملکرد مناسب DBN در مقایسه با مدل عددی XBeach نشان می‌دهد که مدل‌هایِ یادگیریِ عمیق قادرند بخشی از رفتار غیرخطی سیستم هیدرولوژیکی را استخراج کنند اما حساسیت این مدل‌ها به تنظیم ساختار شبکه، تعداد لایه‌ها و پارامترهای آموزشی در کنار هزینه محاسباتی بالاتر می‌تواند موجب کاهش کارایی آن‌ها در داده‌های ماهانه با طول محدود شود. از سوی دیگر، مدل XBeach که یک مدل عددی است

در شبیه‌سازی فرآیندهای هیدرودینامیکی طراحی شده و عدم برتری آن در پیش‌بینی دبی بیشینه ماهانه می‌تواند ناشی از ساده‌سازی‌های اعمال‌شده و عدم استفاده مستقیم از متغیرهای مؤثر هیدرولوژیکی باشد. با این حال، عملکرد قابل قبول این مدل نشان می‌دهد که استفاده از مدل‌های عددی می‌تواند به‌عنوان مرجع مقایسه در کنار مدل‌های داده‌محور مفید باشد. در مجموع، نتایج این پژوهش نشان می‌دهد که در شرایط محدودیت داده و تمرکز بر پیش‌بینی دبی بیشینه ماهانه، مدل LightGBM می‌تواند توازن مناسبی بین دقت پیش‌بینی، پایداری مدل و هزینه محاسباتی ایجاد کند. نتایج حاصل از پژوهش حاضر نشان داد که مدل LightGBM با فاصله معنادار در تمامیِ پارامترهایِ ارزیابی نسبت به دو مدل XBeach و DBN عملکرد بهتری داشت؛ این یافته با مطالعه Szczepanek (۲۰۲۲) در مورد بهبود عملکرد مدل LightGBM پس از بهینه‌سازی پارامترها همخوانی دارد. در این پژوهش با استفاده از داده‌های دبی روزانه در یک حوضه کوهستانی، عملکرد الگوریتم‌های XGBoost، LightGBM و CatBoost مورد مقایسه قرار گرفت. در مطالعه مذکور، با انجام فرآیند تنظیم پارامترهای کلیدی مدل‌ها و ارزیابی آن‌ها بر اساس شاخص‌های آماری مختلف، مشخص شد که LightGBM به دلیل ساختار مبتنی‌بر رشد برگ‌محور درخت‌ها و کارایی بالاتر در یادگیری روابط غیرخطی قادر است الگوهای پیچیده جریان را با دقت بیشتری بازتولید کند. علاوه بر این، مطالعه Gan و همکاران (۲۰۲۱) ضمن گزارش مجموعه‌ای از نتایج بسیار خوب برای LightGBM بیان می‌کند که این مدل حتی نسبت به مدل‌های مبتنی‌بر فرآیند فیزیکی در آن مطالعه برتری داشته است. از سوی دیگر، در مقایسه بین DBN و XBeach، نتایج نشان داد که DBN عملکردی بهتر از XBeach دارد اما این برتری در شاخص‌هایِ مورد ارزیابیِ پژوهش حاضر از لحاظ آماری به حدی نبود که بتوان آن را معنادار قلمداد کرد. این موضوع نیز با پژوهش Chen و همکاران (۲۰۱۹) مطابقت دارد که در آن DBN برای تحلیل ریسک سیلاب استفاده شده است اما تأکید شده که کاربرد عملی آن با پیچیدگی محاسباتی همراه است. مطالعه Goodarzi و همکاران (۲۰۱۹) نیز نشان می‌دهد که مدل‌های بیزی برای پیش‌بینی اوج سیلاب مناسب هستند اما نیاز به داده‌های کمّی دقیق، ساختار پیچیده احتمالاتی و استنتاج دارد. علاوه بر آن، مقالات مرتبط با کاربرد روش‌های یادگیری ماشین و مدل‌های شبکه‌های بیزی در پیش‌بینی سیلاب نیز نشان داده است که گرایش به استفاده از مدل‌های سریع، ساده و با هزینه کم‌تر رو به افزایش است. به عنوان مثال مطالعه Al-Rawas و همکاران (۲۰۲۴) گزارش می‌دهد که مطالعات بین ۲۰۱۰ تا ۲۰۲۳ به کاربرد روش‌های یادگیریِ ماشین پرداخته‌اند و سرعت، هزینه، پیچیدگی و عملیاتی بودن، عوامل تعیین‌کننده در انتخاب مدل بوده است. بنابراین انتخاب عملی برای LightGBM به عنوان گزینه اول و XBeach به عنوان گزینه دوم از منظر کاربردی نیز توجیه‌پذیر است. در بخش حافظه زمانی نیز نتایج به‌دست آمده از جداول ۲ تا ۴ نشان داد که با افزایش تعداد فصول گذشته، دقت مدل‌ها تا حدی بهبود یافت ولی افزایش بیش از حد تأخیر زمانی ممکن بود منجر به پیچیدگی بیش‌تر، بیش‌برازش یا کاهش بازده شود. مطالعات فعلی نشان می‌دهد که در بسیاری از مطالعات هیدرولوژیک، انتخاب بهینه پنجره زمانی برای مدل‌های یادگیری ماشین یکی از عوامل کلیدی است. به عنوان مثال در مطالعه Pala و همکاران (۲۰۲۵) مطرح شده است که مدل LightGBM با مجموعه داده‌های طولانی‌تر یا پنجره زمانی مناسب‌تر عملکرد بهتری ارائه می‌دهد. شکل ۳ میزان انطباق بین مقادیر پیش‌بینی‌شده و مشاهداتی دبی سیلاب را برای هر یک از مدل‌های مورد استفاده نشان می‌دهد.



شکل ۳ – نمودار مقایسه همبستگی مدل‌ها

Figure 3- Model correlation comparison chart

بر اساس نمودارهای همبستگی، مدل LightGBM بیش‌ترین تراکم نقاط را در اطراف خط همبستگی به خود اختصاص داده است که بیان‌گر انطباق بالا و خطای کم‌تر بین مقادیر واقعی و پیش‌بینی‌شده می‌باشد. مقادیر ضریب همبستگی این مدل در ایستگاه‌های مختلف در بازه ۰/۸۹۶ تا ۰/۹۱۸ قرار گرفته است که توانایی بالای مدل LightGBM را در بازنمایی الگوی تغییرات زمانی و شدت دبی سیلاب تأیید می‌کند. این نتایج نشان می‌دهد که ساختار مبتنی‌بر درخت‌های تصمیم تقویت‌شده در

LightGBM قادر است روابط غیرخطی پیچیده موجود در داده‌های هیدرولوژیکی را به‌خوبی استخراج نماید. مدل DBN نیز روند کلی تغییرات را به‌خوبی دنبال کرده اما پراکندگی بیشتری در نقاط نسبت به LightGBM مشاهده می‌شود. مقادیر ضریب همبستگی DBN در محدوده ۰/۸۱۶ تا ۰/۸۳۲ قرار داشته و نشان‌دهنده عملکرد قابل‌قبول اما ضعیف‌تر نسبت به مدل LightGBM است. به‌ویژه در دبی‌های اوج، مدل تمایل به بیش‌برآورد جزئی دارد که می‌تواند ناشی از ساختار چندلایه و حساسیت به تنظیم پارامترهای یادگیری باشد. این ویژگی در مطالعات مشابهی که از DBN برای مدل‌سازی هیدرولوژیک استفاده شده نیز گزارش گردیده است (Chang *et al.*, 2023).

مدل XBeach به‌عنوان یک مدل فیزیکی فرآیندی، همبستگی نسبتاً پایینی را در مقایسه با دو مدل داده‌محور نشان داده است. به‌گونه‌ای که مقادیر ضریب همبستگی آن در بازه ۰/۸۰۷ تا ۰/۸۲۳ قرار گرفته است. هرچند XBeach در بازتولید الگوهای کلی دبی موفق عمل کرده است اما در شرایط پیچیده با ورودی‌های متغیر زمانی، دقت آن کاهش می‌یابد. این مسئله در پژوهش Roelvink و همکاران (۲۰۰۹) نیز تأیید شده که عملکرد این مدل در مقیاس‌های زمانی کوتاه‌تر و داده‌های محدود با افت دقت همراه است. بررسی مقادیر همبستگی حاصل از این نمودارها نشان می‌دهد که LightGBM در تمامی ایستگاه‌ها مقدار همبستگی بالا را ثبت کرده است در حالی که مقادیر برای DBN و XBeach به‌ترتیب عملکرد بهتری داشته‌اند. این نتایج نشان‌گر آن است که مدل‌های داده‌محور به‌ویژه الگوریتم‌های LightGBM قادرند روابط غیرخطی پیچیده بین ورودی‌های اقلیمی و پاسخ هیدرولوژیکی را بهتر شناسایی کنند.

نتیجه‌گیری

در پژوهش حاضر با هدف ارزیابی و مقایسه کارایی سه مدل LightGBM، DBN و XBeach به‌منظور پیش‌بینیِ دبیِ بیشینه ماهانه در حوزه آبخیز طالقان، چهار حالت زمانی مختلف بر اساس تأخیرهای فصلی طراحی و بررسی شد. نتایج حاصل از تحلیل شاخص‌های ارزیابی نشان داد که تفاوت قابل‌توجهی میان عملکرد مدل‌های داده‌محور و مدل فیزیکی وجود دارد. مدل LightGBM با بهره‌گیری از سازوکار یادگیری گرادیان تقویتی و قابلیت بالای خود در استخراج روابط غیرخطی میان داده‌های ورودی در تمامی حالات زمانی برتری معناداری نسبت به دو مدل دیگر داشت. این مدل همبستگی بالاتر و خطای کمتری را در بازتولید رفتار هیدرولوژیک حوضه نشان داد و به‌عنوان دقیق‌ترین مدل پیش‌بینی جریان انتخاب شد. افزون‌بر دقت بالا، سادگی نسبی در آموزش، زمان اجرای پایین و امکان به‌روزرسانی سریع ازجمله مزایایِ کلیدیِ مدل LightGBM در کاربردهای پیش‌بینی سیلاب محسوب می‌شوند. مدل DBN نیز با وجود توانایی در نمایش پویایی‌های زمانی و روابط علی بین متغیرها در مقایسه با LightGBM دقت پایین‌تری ارائه داد. هرچند این مدل در برخی حالات زمانی عملکردی قابل قبول داشت اما اختلاف آن با XBeach از لحاظ آماری معنادار نبود. با در نظر گرفتن هزینه‌های محاسباتی بالا، نیاز به تنظیم ساختار شبکه و دشواری در تفسیر نتایج، استفاده از مدل DBN در کاربردهای عملیاتی کوتاه‌مدت توصیه نمی‌شود مگر در شرایطی که تحلیل عدم‌قطعیت یا ترکیب چند منبع داده مدنظر باشد. مدل XBeach به‌عنوان یک مدل عددی فیزیکی، موفق شد الگوی کلی رفتار دبی را بازسازی کند اما دقت پیش‌بینی آن نسبت به دو مدل داده‌محور پایین‌تر بود. با این حال از آن‌جا که XBeach مبتنی‌بر اصول فیزیکی جریان و فرسایش است می‌تواند در مطالعاتی که هدف، تحلیل فرآیندی و مکانی پدیده‌های هیدرودینامیکی است به‌عنوان مدل پایه و مرجع مورد استفاده قرار گیرد. در پژوهش حاضر با توجه به هزینه پایین‌تر و سهولت اجرا، مدل XBeach در رتبه دوم پس از LightGBM قرار گرفت و مدلDBN در رتبه سوم قرار گرفت.

در مجموع، یافته‌های این تحقیق بیان‌گر آن است که ترکیب داده‌های اقلیمی و هیدرولوژیکی در قالب مدل‌های داده‌محور به‌ویژه LightGBM، ابزار قدرتمندی برای پیش‌بینی دبی‌های ماهانه در حوزه‌های کوهستانی مانند طالقان فراهم می‌آورد. این مدل می‌تواند به عنوان پایه‌ای برای سامانه‌های هشدار سریع سیلاب و مدیریت هوشمند منابع آب در مناطق با رفتار هیدرولوژیکی پیچیده به کار گرفته شود. پیشنهاد می‌شود در پژوهش‌های آتی ترکیب مدل‌های داده‌محور با مدل‌های فیزیکی مورد بررسی قرار گیرد تا ضمن افزایش دقت، قابلیت تفسیر فیزیکی نیز حفظ شود.

References

Alizadeh, Z., Yazdi, J., Kim, J. H., & Al-Shamiri, A. K. (2018). Assessment of Machine Learning Techniques for Monthly Flow Prediction. *Water*, 10(11), 1676. https://doi.org/10.3390/w10111676

Al-Rawas, G., Nikoo, M. R., Al-Wardy, M., & Etri, T. (2024). A Critical Review of Emerging Technologies for Flash Flood Prediction: Examining Artificial Intelligence, Machine Learning, Internet of Things, Cloud Computing, and Robotics Techniques. *Water*, *16*(14), 2069. https://doi.org/10.3390/w16142069

Brunner, M.I., Slater, L., M.Tallaksen, L., & Clark, M. (2021). Challenges in modeling and predicting floods and droughts: A review. *WIREs Water*, 8(3), 2049-1948. https://doi.org/10.1002/wat2.1520

Chang, L., Bai, Y., Xue, J., Gong, L., Zeng, F., Sun, H., Hu, Y., Huang, H., & Ma, Y. (2023). Dynamic Bayesian networks with application in environmental modeling and management: A review. *Environmental Modelling & Software*, 170, 105835, ISSN 1364-8152. https://doi.org/10.1016/j.envsoft.2023.105835.

Chen, J., Zhong, P., An, R., Zhu, F., & Xu, B. (2019). Risk analysis for real-time flood control operation of a multi-reservoir system using a dynamic Bayesian network. *Environmental Modelling & Software*, 111, 409-420, ISSN 1364-8152. https://doi.org/10.1016/j.envsoft.2018.10.007

Ebrahimi, P., Salamti, A., Mohseni Saravi, M., Malekian, A., & Saedodin, A. (2020). Prediction of Environmental Health by Using Gene Expression and Bayesian Network Techniques in Taleghan Watershed. *Pasture and watershed management*.73(1), 1-18. (In Persian) https://doi:10.22059/jrwm.2018.250908.1221

Ebrahimi, A., Roozbahani, A., & BaniHabib, M.A. (2018). Groundwater Level Prediction Using Dynamic Bayesian Networks Based on Sensitivity Analysis (Case Study: Birjand Plain). *Iranian Water*, 12(2), 91-100. (In Persian)

Gan, M., Pan, S., Chen, Y., Cheng, C., Pan, H., & Zhu, X. (2021). Application of the Machine Learning LightGBM Model to the Prediction of the Water Levels of the Lower Columbia River. *Journal of Marine Science and Engineering*, *9*(5), 496. https://doi.org/10.3390/jmse9050496

Gai, Y., Li, L., Li, Z., & Shi, H. (2025). The Optimization of Four Key Parameters in the XBeach Model by GLUE Method: Taking Chudao South Beach as an Example. *Journal of Marine Science and Engineering*, *13*(3), 555. https://doi.org/10.3390/jmse13030555

Goodarzi, L., E.Banihabib, M., Roozbahani, A., & Dietric, J. (2019). Bayesian network model for flood forecasting based on atmospheric ensemble forecasts. *Nat. Hazards Earth Syst. Sci*, 19, 2513-2524. https://doi.org/10.5194/nhess-19-2513-2019

Ke, G., Meng, Q., Finley, Th., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, TY. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA. https://doi.org/10.5555/3294996.3295074

Kuhaneswaran, B., Sorwar, G., Alaei, A. R., & Tong, F. (2025). Evolution of Data-Driven Flood Forecasting: Trends, Technologies, and Gaps—A Systematic Mapping Study. *Water*, *17*(15), 2281. https://doi.org/10.3390/w17152281

Kungurtsev, V., Rysavy, P., Idlahcen, F., Rytir, P., & Wodecki, A. (2024). Learning Dynamic Bayesian Networks from Data: Foundations, First Principles and Numerical Comparisons. https://10.48550/arXiv.2406.17585

Kisi, O., Choubin, B., Deo, R. C., & Yaseen, Z. M. (2019). Incorporating synoptic-scale climate signals for streamflow modelling over the Mediterranean region using machine learning models. *Hydrological Sciences Journal*, 64(10), 1240-1252. https://doi.org/10.1080/02626667.2019.1632460

Mahmood, MQ., Wang, X., Aziz, F., & Dogulu, N. (2025). Urban flood modelling: Challenges and opportunities - A stakeholder-informed analysis. *Environmental Modelling & Software*, 191, 106507, ISSN 1364-8152. https://doi.org/10.1016/j.envsoft.2025.106507

Murphy, K., & Weiss, Y. (2013). The Factored Frontier Algorithm for Approximate Inference in DBNs. Appears in Proceedings of the Seventeenth Conference on Uncertainty in Artificial Intelligence. https://doi.org/10.48550/arXiv.1301.2296

Nayak, M., Das, S., & Senapati, M. R. (2022). Improving Flood Prediction with Deep Learning Methods. *Journal of The Institution of Engineers (India)*, Series B. 103. https://doi.org/10.1007/s40031-022-00720-y

Nakhaei, M., Zanjanian, H., Nakhaei, P., Gheibi, M., Moezzi, R., Behzadian, K., & Campos, L. C. (2024). Comparative Evaluation of Deep Learning Techniques in Streamflow Monthly Prediction of the Zarrine River Basin. *Water*, 16(2), 208. https://doi.org/10.3390/w16020208

Okacha, A., Salhi, A., Bouchouou, M., & Fattasse, M. (2024). Enhancing flood forecasting accuracy in Data-Scarce regions through advanced modeling approaches. *Journal of Hydrology* ,645, Part B ,132283, ISSN 0022-1694. https://doi.org/10.1016/j.jhydrol.2024.132283

Pala, A., Mutlu, S., & Guven, A. (2025). Evaluation of machine learning models for streamflow projections under different greenhouse gas emission scenarios. *Engineering Research*, ISSN 2307-1877. https://doi.org/10.1016/j.jer.2025.06.006

Roohi, M., Ghafouri, H. R., Ashrafi, S. M., Motagh, M., & Haghshenas Haghighi, M. (2025). A hybrid approach for enhanced flood prediction and assessment: Leveraging physical models, deep learning and satellite remote sensing. *Big Earth Data*, *9*(3), 439–472. https://doi.org/10.1080/20964471.2025.2530850

Roelvink, D., Reiners, A., Van Dongeren, a., Thiel de Veris, J., McCall, R., & Lescinski, J. (2009). Modelling storm impacts on beaches, dunes and barrier islands. *Coastal Engineering*, 56, 1133-1152. doi:10.1016/j.coastaleng.2009.08.006

Roelvink, D., Reiners, A.D., Van Dongeren, AP., Van Thiel de Veries, J., Lescinski, J., & McCall, R. (2010). XBeach Model Description and Manual. Unesco-IHE Institute for Water Education, Deltares and Delft University of Technology. Page: 3

Szczepanek, R. (2022). Daily Streamflow Forecasting in Mountainous Catchment Using XGBoost, LightGBM and CatBoost. *Hydrology*, *9*(12), 226. https://doi.org/10.3390/hydrology9120226

Yu, J., Li, Y., Huang, X., & Ye, X. (2025). Data quality and uncertainty issues in flood prediction: a systematic review. *International Journal of Digital Earth*, *18*(1), 1-30. https://doi.org/10.1080/17538947.2025.2495738

Zhao, J., Wang, X., Ke, E., & Zhao, Y. (2025). Enhancing urban flood resilience: a LightGBM-NSGA2 hybrid model for impervious surface optimization. *Habitat International*, 163, 103475, ISSN: 0197-3975. https://doi.org/10.1016/j.habitatint.2025.103475