

River Flow Modeling with Emphasis on Drought and Flood Periods Using Selected Deep Learning and Machine Learning Models (Case Study: Selected Stations in the Karkheh Basin)

Nasrin Beiranvand¹, Alireza Sepahvand^{2*}, Hamed Naghavi³

Received: 12-02-2026, Revised: 22-03-2026, Accepted: 03-06-2026, Published: 03-08-2026

<https://doi.org/10.22034/20.72.3>

Extended Abstract

Introduction

Population growth and the limited availability of surface and groundwater resources have made the optimal management and utilization of water resources an essential necessity. In this regard, investigating the trends of temperature, precipitation, and streamflow variations can play a significant role in water resources management. Temperature, precipitation, and discharge are among the fundamental elements for understanding the climate and hydrology of a watershed. Predicting hydrological parameters has received considerable attention due to their importance in drought analysis and water supply, the design of hydraulic structures, reservoir operation, erosion and sediment control, and many other water-related applications. Rivers are not only considered direct sources of water supply for consumers, but they also play a vital role in maintaining ecosystem stability, recharging groundwater resources, and supporting biodiversity. However, extensive climate changes in recent decades, including rising temperatures, altered precipitation patterns, recurrent droughts, and sudden intense rainfall events, have directly and indirectly affected river flow regimes. Owing to the importance of this issue, numerous studies have been conducted worldwide. Therefore, the present study focuses on river flow modeling with an emphasis on low-flow and high-flow periods using several deep learning models (LSTM and GRU) and machine learning models (RF and MLR) at selected stations within the Karkheh watershed.

Materials and Methods

From a geomorphological perspective, the study area is located in the central part of the Zagros Mountain range in Lorestan Province, Iran, between the geographical longitudes of 47°12'30" to 48°59'20" E and latitudes of 33°05'45" to 34°03'26" N. This study was conducted to predict river discharge under low-flow and high-flow conditions using RF, MLP, LSTM, and GRU models. In the first stage, the required data were collected. The datasets included monthly river discharge, precipitation, temperature, and evaporation records over a 10-year period (2014–2015 to 2023–2024) obtained from the Dareh Tang Kahman, Afrineh Cholehhol, and Afrineh Kashkan hydrometric stations. These data were categorized into two separate groups representing

1. Ph.D. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran.

2. Associate Professor, Department of Range and Watershed Management Engineering, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran. Tel: 09163679256. Corresponding author: Sepahvand.a@lu.ac.ir

3. Associate professor, Department of Forestry Science, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

wet and dry conditions. Subsequently, the data preprocessing stage was carried out. After normalizing the datasets, the data were divided into training and testing subsets, with 70% allocated for model training and 30% for model testing. Temperature, precipitation, and evaporation were considered as the input variables, while river discharge was defined as the output variable of the models. Two deep learning models with similar architectures, consisting of recurrent layers and an output layer, were designed and trained. Each model was implemented separately for wet and dry periods using the Python programming language. Finally, the performance of the models was evaluated and compared using statistical error criteria, including the correlation coefficient (R), mean absolute error (MAE), and root mean square error (RMSE). In addition, sensitivity analysis of the models with respect to different input variables was performed using the elimination method in order to identify the most influential input parameter affecting the model outputs.

Results and Discussion

The results demonstrated that, based on the evaluation criteria, the GRU model during the high-flow period and the RF model during the low-flow period outperformed the other models. According to the testing results, the GRU model provided the best performance during the high-flow period. The correlation coefficient (R), mean absolute error (MAE), and root mean square error (RMSE) values obtained for the Afrineh Cholehhol station were 0.95, 0.06, and 0.10, respectively. Similarly, for the Afrineh Kashkan station, these values were 0.57, 0.17, and 0.24, respectively, while for the Dareh Tang station, the corresponding values were 0.94, 0.09, and 0.13. In addition, the testing results indicated that the RF model achieved the best performance during the low-flow period. The values of R, MAE, and RMSE for the Afrineh Cholehhol station were 0.72, 0.22, and 0.23, respectively. For the Afrineh Kashkan station, the obtained values were 0.82, 0.17, and 0.20, respectively, and for the Dareh Tang station, they were 0.43, 0.34, and 0.38, respectively. The sensitivity analysis of the best-performing models in both high-flow and low-flow periods revealed that precipitation was the most influential parameter affecting the model outputs. The removal of this parameter resulted in a noticeable decline in model performance, indicating its critical role in accurate river discharge prediction.

Conclusion

Overall, the modeling results demonstrated that both deep learning and machine learning models performed well in simulating river discharge during the studied periods using the selected input data at the investigated stations. The findings also indicate that these models have the capability to be applied to neighboring stations with similar hydrological conditions. Furthermore, the results revealed that the considered input parameters, particularly precipitation, had a significant influence on river discharge, leading to high model accuracy in discharge simulation and prediction. Therefore, based on the findings of this study, these optimized models can be effectively utilized to reduce both time and costs in water and soil conservation studies as well as in estimating watershed outlet discharge. In addition, for improved management of the quantity and quality of surface water resources, these models can be applied to estimate discharge at nearby ungauged stations with similar geological and hydrological conditions within the region, providing reliable results regarding river discharge.

Keywords: Lorestan Province, Deep Learning, Machine Learning, River Discharge, Random Forest

Article Type: Research Article

Acknowledgments

The cooperation and assistance of Lorestan University is appreciated.

Conflicts of Interest

The authors declare that there are no conflicts of interest related to the authorship, research, or publication of this article.

Data Availability Statement:

The data supporting the findings of this study are available from the corresponding author upon reasonable request.

Authors' Contribution

Nasrin Beiranvand: Writing - original draft preparation, Resources, Software, Manuscript editing, Alireza Sepahvand: Conceptualization, Final editing, methodology, Hamed Naghavi: Advisor, review and editing, methodology. All authors have read and agreed to the published version of the manuscript.

Citation: Beiranvand N, Sepahvand A, Naghavi H, River Flow Modeling with Emphasis on Drought and Flood Periods Using Selected Deep Learning and Machine Learning Models (Case Study: Selected Stations in the Karkheh Basin). jwmseir 2026; 20 (72):28-42

Iran-Watershed Management Science & Engineering, Year 2026, Vol 20, No 72, 28-42

Publisher: Watershed Management Society of Iran

© Author(s)



مدل سازی جریان رودخانه با تأکید بر دوران کم آبی و پرآبی با استفاده از برخی مدل های یادگیری عمیق و یادگیری ماشین (مطالعه موردی: برخی ایستگاه های حوضه کرخه)

نسرین بیرانوند^۱، علیرضا سپهوند^۲، حامد نقوی^۳

تاریخ دریافت: ۱۴۰۴/۱۱/۲۳، تاریخ داوری: ۱۴۰۵/۰۱/۰۲، تاریخ پذیرش: ۱۴۰۵/۰۳/۱۳، تاریخ انتشار: ۱۴۰۵/۰۵/۱۲

<https://doi.org/10.22034/20.72.3>

چکیده


در این پژوهش به بررسی عملکرد برخی مدل های یادگیری عمیق (LSTM و GRU) و یادگیری ماشین (RF و MLP) برای مدل سازی دبی رودخانه در استان لرستان در ایستگاه های هیدرومتری چولهول افرینه، کشکان افرینه و دره تنگ در دو دوره کم آبی و پرآبی پرداخته شده است. برای انجام این تحقیق از داده های ورودی تبخیر، دما و بارش همچنین داده خروجی دبی رودخانه در بازه زمانی ۱۰ ساله (۱۳۹۳-۱۳۹۴ تا ۱۴۰۲-۱۴۰۳) استفاده شد. با استفاده از داده های دبی برای هر ایستگاه حد تعیین دوره کم آبی و دوره پرآبی مشخص شد، سپس دبی رودخانه به دو دوره کم آبی و پرآبی تقسیم شد. سپس مدل سازی داده ها (۷۰ درصد داده های آموزش و ۳۰ درصد داده های آزمایش) با استفاده از مدل های ذکر شده در محیط Python انجام شد. نتایج نشان داد باتوجه به معیارهای ارزیابی مدل GRU در دوره پرآبی و مدل RF در دوره کم آبی نسبت به سایر مدل ها عملکرد بهتری از خود نشان داده اند. با توجه به نتایج بخش آزمایش مدل GRU در دوره پرآبی بهترین نتیجه را به ما داده است که به ترتیب ضریب همبستگی، میانگین خطای مطلق و ریشه میانگین مربعات خطا در ایستگاه چولهول افرینه ۰/۹۵، ۰/۰۶ و ۰/۱۰، هم چنین ایستگاه کشکان افرینه ۰/۵۷، ۰/۱۷ و ۰/۲۴ و در آخر ایستگاه دره تنگ ۰/۹۴، ۰/۰۹ و ۰/۱۳ به دست آمده است. همچنین نتایج بخش آزمایش مدل RF در دوره کم آبی بهترین نتیجه را به ما داده است که به ترتیب ضریب همبستگی، میانگین خطای مطلق و ریشه میانگین مربعات خطا در ایستگاه چولهول افرینه ۰/۷۲، ۰/۲۲ و ۰/۲۳، هم چنین ایستگاه کشکان افرینه ۰/۸۲، ۰/۱۷ و ۰/۲۰ و در آخر ایستگاه دره تنگ ۰/۴۳، ۰/۳۴ و ۰/۳۸ به دست آمده است. لذا با توجه به نتایج به دست آمده از این پژوهش می توان از این مدل های بهینه برای صرفه جویی در هزینه و زمان برای بحث حفاظت آب و خاک و تخمین دبی خروجی از حوزه های آبخیز استفاده کرد. هم چنین می توان برای اجرای مدیریت بهتر در رابطه با کمیت و کیفیت آب های سطحی، این مدل ها برای تخمین دبی ایستگاه های مجاور فاقد آمار دارای شرایط زمین ساختی و هیدرولوژیکی یکسان در سطح منطقه مورد استفاده قرار گیرند و نتایج قابل اعتمادی در رابطه با دبی رودخانه ارائه دهند.

کلید واژه ها: استان لرستان، یادگیری عمیق، یادگیری ماشین، دبی رودخانه، جنگل تصادفی.

نوع مقاله: پژوهشی

استناد: بیرانوند نسرین، سپهوند علیرضا، نقوی حامد. مدل سازی جریان رودخانه با تأکید بر دوران کم آبی و پرآبی با استفاده از برخی مدل های یادگیری عمیق و یادگیری ماشین (مطالعه موردی: برخی ایستگاه های حوضه کرخه). علوم و مهندسی آبخیزداری ایران. ۱۴۰۵؛ ۲۰ (۷۲): ۲۸-۴۲

علوم و مهندسی آبخیزداری ایران سال ۱۴۰۵، دوره ۲۰، شماره ۷۲، ۲۸-۴۲



ناشر: انجمن آبخیزداری ایران

- ۱- دانشجوی دکتری، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، لرستان، خرم آباد، ایران.
- ۲- *دانشیار، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، خرم آباد، ایران. تلفن: ۰۹۱۶۳۶۷۹۲۵۶، نویسنده مسئول: Sepahvand.a@lu.ac.ir
- ۳- دانشیار، گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه لرستان، خرم آباد، ایران.

منابع آب سطحی، به‌ویژه جریان رودخانه‌ها، از بنیادی‌ترین ارکان توسعه پایدار در جوامع انسانی به شمار می‌روند و نقشی حیاتی در تأمین نیازهای شرب، کشاورزی، صنعتی و حتی تولید انرژی ایفا می‌کنند. رودخانه‌ها نه تنها به‌عنوان منابع مستقیم آب برای مصرف‌کنندگان محسوب می‌شوند، بلکه در پایداری بوم‌سازگان‌ها، تغذیه آب‌های زیرزمینی و حمایت از تنوع زیستی نیز نقش محوری دارند. با این حال، تغییرات گسترده اقلیمی در دهه‌های اخیر، افزایش دما، تغییر الگوهای بارش، وقوع خشکسالی‌های پی‌درپی و بارش‌های ناگهانی و شدید، به‌طور مستقیم و غیرمستقیم بر الگوی جریان رودخانه‌ها تأثیر گذاشته‌اند [۴ و ۹]. پیامد این تغییرات، افزایش شدت نوسانات در جریان رودخانه‌ها، وقوع پدیده‌های حدی مانند سیلاب‌های ناگهانی و کاهش شدید جریان در دوره‌های کم‌آبی است. از همین رو، پیش‌بینی دقیق جریان رودخانه در دوره‌های کم‌آبی و پرآبی به یکی از اولویت‌های اصلی در مدیریت منابع آب تبدیل شده است. اهمیت این موضوع زمانی پررنگ‌تر می‌شود که بدانیم بیش از ۷۰ درصد منابع آب شیرین جهان در بخش کشاورزی مصرف می‌شود و کوچک‌ترین خطا در پیش‌بینی جریان می‌تواند منجر به اختلال در تولید محصولات کشاورزی، خسارات اقتصادی و اجتماعی و تهدید امنیت غذایی شود [۸]. علاوه بر این، در بسیاری از مناطق نیمه‌خشک و خشک مانند ایران، رودخانه‌ها منبع اصلی تأمین آب هستند و وابستگی شدید به این منابع، لزوم پیش‌بینی دقیق جریان را در سناریوهای مختلف اقلیمی دوچندان می‌سازد. به‌طور خاص در حوضه‌های مهمی نظیر حوضه رودخانه کرخه، که نقش مهمی در تأمین آب کشاورزی و شرب جنوب و جنوب غرب ایران دارد، مدیریت دقیق منابع آب بدون پیش‌بینی جریان امکان‌پذیر نیست. مدل‌سازی جریان رودخانه‌ها در دوران کم‌آبی و پرآبی، از جنبه‌های گوناگون اهمیت دارد: نخست، این مدل‌سازی‌ها به مدیران منابع آب کمک می‌کند تا تخصیص بهینه منابع آبی برای مصارف مختلف را انجام دهند؛ دوم، امکان پیش‌بینی و کنترل سیلاب‌های ناگهانی فراهم می‌شود؛ و سوم، می‌توان اثرات تغییرات اقلیمی بر الگوهای جریان را تحلیل کرده و سناریوهای مدیریتی مناسبی تدوین نمود [۱۳]. از همین رو، مدل‌های پیش‌بینی جریان رودخانه یکی از ابزارهای اساسی در مدیریت پایدار منابع آب و برنامه‌ریزی‌های کلان محیط‌زیستی به شمار می‌روند. روش‌های سنتی مدل‌سازی جریان رودخانه شامل مدل‌های فیزیکی و مفهومی هستند که بر اساس معادلات هیدرولوژیکی، هیدرولیکی یا آماری توسعه یافته‌اند. اگرچه این روش‌ها از پایه‌های علمی قدرتمندی برخوردارند و در بسیاری از مطالعات کاربرد داشته‌اند، اما محدودیت‌هایی اساسی دارند. نیاز به داده‌های متعدد و باکیفیت، حساسیت بالا به خطاهای ورودی، پیچیدگی در کالیبراسیون و عدم انعطاف‌پذیری در مواجهه با شرایط غیرخطی و غیرایستا از جمله این محدودیت‌ها است [۱۰]. به‌ویژه در شرایط شدید اقلیمی (مانند خشکسالی‌های طولانی یا بارش‌های


سیل‌آسا) این مدل‌ها اغلب از دقت کافی برخوردار نیستند. در میان این مدل‌ها، الگوریتم‌های یادگیری ماشین^۱ و یادگیری عمیق^۲ به دلیل توانایی بالا در کشف روابط غیرخطی و پیچیده بین داده‌ها، جایگزین مناسبی برای روش‌های سنتی محسوب می‌شوند [۲۲]. این مدل‌ها با استفاده از داده‌های تاریخی و ورودی‌های هواشناسی نظیر بارش، دما و تبخیر، قادرند الگوهای پنهان جریان را شناسایی و پیش‌بینی‌های دقیق‌تری ارائه دهند. به‌طور خاص، مدل‌های یادگیری عمیق مانند LSTM و GRU، به دلیل معماری بازگشتی خود توانایی ویژه‌ای در پردازش داده‌های سری زمانی و شناسایی وابستگی‌های بلندمدت دارند. این ویژگی سبب شده است که این مدل‌ها در مدل‌سازی جریان رودخانه، بارش-رواناب، و پیش‌بینی سطح آب دریاچه‌ها و مخازن با موفقیت‌های قابل توجهی همراه باشند [۱ و ۳]. مطالعات متعددی نشان داده‌اند که LSTM و GRU به‌ویژه در شرایط پرآبی ناشی از بارش‌های شدید و کم‌آبی ناشی از خشکسالی، عملکرد بسیار بهتری نسبت به روش‌های سنتی و حتی برخی روش‌های یادگیری ماشین دارند [۲۱]. در کنار مدل‌های یادگیری عمیق، روش‌های سبک‌تر یادگیری ماشین نیز همچنان جایگاه ویژه‌ای دارند. به‌عنوان مثال، RandomTree یکی از روش‌های مبتنی بر درخت تصمیم است که به دلیل سادگی، سرعت بالا و توانایی مدیریت داده‌های پرنویز، در بسیاری از مطالعات هیدرولوژیکی مورد استفاده قرار گرفته است [۷]. همچنین مدل M5P که یک الگوریتم ترکیبی از درخت تصمیم و رگرسیون خطی محسوب می‌شود، توانسته است در شرایطی که داده‌ها محدود هستند یا تغییرات غیرخطی پیچیده وجود دارد، نتایج مطلوبی ارائه دهد [۱۹]. مقایسه این مدل‌ها با شبکه‌های یادگیری عمیق، نه تنها درک بهتری از توانایی‌های هر الگوریتم فراهم می‌کند، بلکه می‌تواند راهنمای مناسبی برای انتخاب مدل در مطالعات مشابه باشد.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه از نظر ژئومورفولوژیکی در بخش مرکزی سلسله جبال زاگرس در استان لرستان قرار دارد که خود بخشی از حوزه آبخیز کرخه است. حوضه کشکان با مساحت ۸۸۴۴/۶ کیلومتر مربع مطابق شکل ۱ بین طول‌های جغرافیایی ۳۰° ۱۲' ۴۷" تا ۲۰° ۵۹' ۴۸" شرقی و عرض‌های ۴۵° ۵' ۳۳" تا ۳۴° ۰۳' ۳۶" شمالی قرار دارد. بلندترین نقطه حوضه در بخش شمال غربی با ارتفاع ۳۶۴۶ متر از سطح دریا و پست‌ترین نقطه حوضه در بخش جنوبی یعنی خروجی حوضه با ارتفاع ۷۶۰ متر از سطح دریا قرار دارد. میانگین بارندگی حوضه ۴۳۷ میلی‌متر (۱۳۹۷-۱۳۷۸) است.

1. Machine Learning
2. Deep Learning



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه بر روی نقشه استان لرستان

Fig 1. Geographical location of the study area

مراحل تحقیق را نشان می‌دهد.

مدل LSTM^۱

LSTM یک نوع شبکه عصبی بازگشتی پیشرفته است که برای یادگیری وابستگی‌های بلندمدت در سری‌های زمانی طراحی شده است. در مطالعه‌های هیدرولوژی با دقت بالا برای پیش‌بینی جریان و مدل‌سازی داده‌های روزانه و ماهانه به کار رفته است. LSTM به‌ویژه برای مدل‌سازی داده‌های آب‌وهوا، جریان رودخانه، پیش‌بینی بارندگی و سایر مسائل اقلیمی عملکرد بسیار خوبی دارد، چرا که قادر به درک وابستگی زمانی و فصلی در داده‌هاست [۹].

مدل GRU^۲

نسخه ساده‌تر LSTM است که در سال ۲۰۱۴ معرفی شد. دارای دو دروازه update و reset است و برخلاف LSTM ساختار حافظه جداگانه‌ای ندارد، که سبب کاهش پارامترها و سرعت آموزش بالاتر می‌شود. در مطالعات اخیر، GRU در مسائل هیدرولوژیکی مانند پیش‌بینی دبی رودخانه و تبخیر-تعرق با حجم داده محدود نیز عملکرد مناسبی از خود نشان داده است [۲۲].


مدل RF^۳

جنگل تصادفی (RF) یکی از انواع روش‌های الگوریتم‌های یادگیری است که از الگوریتم‌های پایه برای پیش‌بینی‌های چندگانه استفاده می‌کند. جنگل تصادفی اولین بار توسط Breiman در سال ۱۹۹۹ معرفی شد که جنگل‌های تصادفی (RF) یک نوع مدرن از درخت پایه هستند که شامل انبوهی از درخت‌های طبقه‌بندی و رگرسیونی می‌باشند [۱۸]. جنگل تصادفی متغیر ورودی زیادی را پذیرا بوده و همچنین می‌تواند اهمیت نسبی هر یک از متغیرها را بررسی کرده و مهمترین متغیر را در پیش‌بینی مدل شناسایی کند. این روش پتانسیل لازم را به‌عنوان یک مدل مکانی برای ارزیابی و پیش‌بینی مسائل زیست محیطی و زمینی را دارد [۱۴].

روش تحقیق

این تحقیق به‌منظور، پیش‌بینی دبی جریان رودخانه در دو وضعیت کم‌آبی و پرآبی با استفاده از مدل‌های RF، LSTM و MLP و GRU انجام گرفته است. در مرحله اول به جمع‌آوری داده‌ها پرداخته شده است. داده‌های مورد استفاده شامل دبی جریان رودخانه، بارش، دما و تبخیر به‌صورت ماهانه و مربوط به یک دوره ۱۰ ساله (۱۳۹۳-۱۳۹۴ تا ۱۴۰۲-۱۴۰۳) مربوط به ایستگاه‌های دره تنگ کهمان، افرینه چولهول و افرینه کشکان هستند که از سازمان هواشناسی و شرکت آب منطقه‌ای لرستان تهیه شدند. این داده‌ها در دو دسته مجزا شامل شرایط پرآبی و کم‌آبی تفکیک شده‌اند. تفکیک داده‌ها به این صورت انجام شد که میانگین دبی جریان برای هر ایستگاه در بازه زمانی مورد نظر به دست آمد و دبی‌های کمتر از آن مقدار بخش کم‌آبی و بیشتر از آن مقدار بخش پرآبی در نظر گرفته شد و در ادامه به پردازش داده‌ها پرداخته شده است. به‌همین منظور پس از نرمال‌سازی داده‌ها، تقسیم داده‌ها (۷۰٪ آموزش مدل و ۳۰٪ آزمایش مدل) انجام گرفت. ورودی‌های مدل پارامترهای دما، بارش و تبخیر بوده و همچنین دبی جریان رودخانه به‌عنوان خروجی مدل معرفی شده است. دو مدل یادگیری عمیق با ساختار مشابه، شامل لایه‌های بازگشتی و لایه خروجی، طراحی و آموزش داده شدند. هر مدل برای شرایط پرآبی و کم‌آبی به‌صورت جداگانه با زبان برنامه‌نویسی Python اجرا شد. در نهایت عملکرد مدل‌ها با استفاده از معیارهای سنجش خطا در هر دو شرایط پرآبی و کم‌آبی ارزیابی و مورد مقایسه قرار گرفتند. همچنین تحلیل حساسیت مدل‌ها نسبت به ورودی‌های مختلف به روش حذفی برای تعیین اثر مهمترین پارامتر ورودی بر روی خروجی مدل‌ها بررسی شد. با اجرای مدل‌های یادگیری عمیق LSTM و GRU و مدل‌های یادگیری ماشین RF و MLP بر داده‌های واقعی، این پژوهش تلاش دارد اثربخشی این رویکردها را در مدل‌سازی دبی جریان در سناریوهای کم‌آبی و پرآبی تحلیل و بررسی نماید. همچنین، به مقایسه دقیق عملکرد این مدل‌ها در شرایط متغیر اقلیمی پرداخته خواهد شد. شکل ۲ نمودار جریانی

1. Long Short-Term Memory
2. Gated Recurrent Unit
3. RandomForest



شکل ۲- نمودار جریانی مراحل تحقیق
Fig 2. Flowchart of research

مدل MLP^1 شبکه عصبی مصنوعی جز سیستم‌های دینامیکی هستند که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین سبب به این سیستم‌ها هوشمند گفته می‌شود زیرا بر اساس محاسبات روی داده‌های مشاهداتی قوانین کلی حاکم بر پدیده‌ها را کشف نموده و بر اساس آن‌ها به پیش‌بینی‌هایی دست می‌زنند. مدل‌های اساساً فیزیکی به علت سادگی اغلب توسط الگوریتم ANNs قابل مدل‌سازی هستند. مدل‌های ANNs توسط توپولوژی شبکه، خواص گره‌ها و قوانین آموزش و یادگیری مشخص می‌شوند. در میان الگوهای متفاوت شبکه‌های پیش‌سو نسبت به سایر الگوها ANNs، از محبوبیت بیشتری برخوردار است. ساختار شبکه شامل لایه‌هایی از المان‌های پردازشی موازی بوده که اصطلاحاً به آن نرون گفته می‌شود که در آن هر لایه توسط اتصال‌های میانی وزن‌دار به لایه پردازشی متصل می‌شود [۱۷].

معیارهای ارزیابی خطا

در ارزیابی عملکرد مدل‌های پیش‌بینی جریان رودخانه، استفاده از معیارهای عددی دقیق، نقش بسیار مهمی در سنجش دقت و کارایی مدل‌ها دارد. معیارهای متداول شامل ریشه میانگین مربعات خطا

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (H - F)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |H - F| \quad (2)$$

$$r = \frac{n \sum HF - (\sum H)(\sum F)}{\sqrt{n(\sum H^2) - (\sum H)^2} \sqrt{n(\sum F^2) - (\sum F)^2}} \quad (3)$$

2. Root Mean Square Error
3. Correlation Coefficient
4. Mean Absolute Error

1. Multi-Layer Perceptron

جدول ۱- خصوصیات آماری داده‌های آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه در دوره پربابی

Table 1. Statistical characteristics of training and testing data of the hydrometric stations during the high-water period

دره تنگ Dareh Tang				کشکان افرینه Kashkan Afrineh				چولهول افرینه Cholhol Afrineh				پارامتر Parameter
انحراف معیار Sd	میانگین Mean	بیشترین Max	کمترین Min	انحراف معیار Sd	میانگین Mean	بیشترین Max	کمترین Min	انحراف معیار Sd	میانگین Mean	بیشترین Max	کمترین Min	
آموزش Train												
136.91	178.49	584.80	26	67.78	118.92	319.80	46.30	47.66	122.10	218.50	59.40	تبخیر Evaporation
5.714	12.70	22.70	3.12	6.06	13.19	26.30	5.70	5.04	13.97	22.10	6.5	دما Trmperatures
118.28	98.02	458.50	0	95.76	116.59	411.50	0	95.22	142	403	9	بارش Rain
4.07	7.66	15.86	3.22	125.20	111.96	650.21	40.25	15.35	12.36	70.01	3.18	دبی Discharge
آزمایش Test												
105.95	65.40	347.10	0	137.16	116.13	387.20	0	100.03	100.04	336.10	0	تبخیر Evaporation
6.81	9.48	22.60	2.10	8.38	14.90	31.40	6.60	6.25	13.39	28.80	8	دما Trmperatures
74.10	77.95	255.50	0	86.38	96	254.50	0	77.29	135.38	258	0	بارش Rain
2.90	5.46	5.46	3.20	45.93	65.26	190.79	37.10	4.07	5.65	16.29	3.26	دبی Discharge

افرینه میزان دبی مرحله آموزش برابر ۶۵۰/۲۱ و ۴۰/۲۵ و در مرحله آزمایش به ترتیب برابر ۱۹۰/۷۹ و ۳۷/۱۰ و ایستگاه دره تنگ نیز مرحله آموزش برابر ۱۵۰/۸۶ و ۳/۲۲ و در مرحله آزمایش به ترتیب برابر ۵/۴۶ و ۳/۲۰ بوده است.

جدول ۲ خصوصیات آماری داده‌های ورودی و خروجی دوره کم‌ابی مربوط به مرحله آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد. مطابق نتایج جدول ۳ مشخص شد که به ترتیب بیش‌ترین و کم‌ترین دبی ایستگاه چولهول افرینه در مرحله آموزش برابر ۳/۰۵ و ۰/۲۶ و در مرحله آزمایش به ترتیب برابر ۳/۸۰ و ۰/۱۱ بوده است، در ایستگاه کشکان افرینه مرحله آموزش برابر ۳۴/۹۵ و ۰/۶۶ و در مرحله آزمایش به ترتیب برابر ۳۲ و ۰/۵۵ به دست آمده است و ایستگاه دره تنگ نیز مرحله آموزش برابر ۳/۰۸ و ۰/۸۴ و در مرحله آزمایش به ترتیب برابر ۵ و ۰/۴۲ بوده است.

مدل‌سازی دبی در دوره پربابی

یکی از معیارهای ارزیابی عملکرد مدل‌های داده‌محور، پارامترهای آماری هستند. نتایج این پارامترهای آماری برای مدل‌های مختلف در جدول ۳ برای داده‌های آموزش و آزمایش در ایستگاه‌های هیدرومتری مورد مطالعه در دوره‌ی پربابی ارائه شده است. براساس جدول ۴، مدل GRU نسبت به سایر مدل‌ها در پیش‌بینی دبی جریان

در روابط فوق، F مقدار برآورد شده، H مقدار مشاهده شده، $\bar{H}$ میانگین مقادیر مشاهده شده و n تعداد داده‌های اندازه‌گیری است.

تحلیل حساسیت مدل^۱

تحلیل حساسیت یکی از مراحل مهم در ارزیابی مدل‌های پیش‌بینی به‌ویژه در حوضه هیدرولوژی و پیش‌بینی جریان رودخانه است. هدف اصلی این تحلیل، شناسایی میزان تأثیر هر یک از ورودی‌های مدل (مانند دما، بارش، تبخیر) بر خروجی مدل (مثلاً دبی جریان) است. به بیان ساده، تحلیل حساسیت کمک می‌کند مشخص شود کدام متغیرهای ورودی بیشترین نقش را در عملکرد مدل دارند و حذف یا تغییر کدام متغیر می‌تواند باعث افت یا بهبود پیش‌بینی شود [۲].

نتایج

جدول ۱ خصوصیات آماری داده‌های ورودی و خروجی دوره پربابی مربوط به مرحله آموزش و آزمایش را در ایستگاه‌های هیدرومتری مورد مطالعه نشان می‌دهد. مطابق نتایج به دست آمده از این جدول تعیین شد که در ایستگاه چولهول افرینه، بیش‌ترین و کم‌ترین دبی در مرحله آموزش به ترتیب برابر ۷۰/۰۱ و ۳/۱۸ و در مرحله آزمایش نیز برابر ۱۶/۲۹ و ۳/۲۶ است، در ایستگاه کشکان

1. Sensitivity Analysis

جدول ۲- خصوصیات آماری داده‌های آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه در دوره کم‌آبی

Table 2. Statistical characteristics of training and testing data of hydrometric stations during the low-water period


دره تنگ Dareh Tang				کشکان افرینه Kashkan Afrineh				چول‌هول افرینه Cholhol Afrineh				پارامتر Parameter
انحراف Sd	میانگین Mean	بیشترین Max	کمترین Min	انحراف Sd	میانگین Mean	بیشترین Max	کمترین Min	انحراف Sd	میانگین Mean	بیشترین Max	کمترین Min	
آموزش Train												
127.45	135.54	431.10	0	130.35	229.64	439.10	0	136.66	213.73	439.10	0	تبخیر Evaporation
6.86	12.40	23.40	0.60	8.69	21.68	33.30	6.60	9.36	20.61	33.30	5.70	دما Trmperatures
52.31	44.16	181	0	28.59	18.74	124.50	0	36.19	26.67	161	0	بارش Rain
0.59	2	3.08	0.84	9.25	14.26	34.95	0.66	0.76	1.40	3.05	0.26	دبی Discharge
آزمایش Test												
166.71	178.84	564.10	0	136.28	193.20	410.20	0	137.35	6056.4	417.20	0	تبخیر Evaporation
7.82	15.96	26.90	2.50	8.75	19.77	33	6.30	8.52	592.9	33	6.30	دما Trmperatures
59.07	51.46	180.50	0	52.92	45.67	147	0	43.41	987.5	142	0	بارش Rain
1.08	1.43	5	0.42	9.53	13.03	32	0.55	0.80	28.3	3.80	0.11	دبی Discharge

جدول ۳- پارامترهای ارزیابی مدل‌ها در ایستگاه‌های هیدرومتری مورد مطالعه در دوره پربابی

Table 3. Parameters for evaluating models at the hydrometric stations during the high-water period

Test آزمایش			Train آموزش			Model مدل
R ²	MAE	RMSE	R ²	MAE	RMSE	
Cholhol Afrineh چولهول افرینه						
0.71	0.14	0.30	0.95	0.05	0.06	LSTM
0.95	0.06	0.10	0.99	0.01	0.02	GRU
0.70	0.15	0.22	0.99	0.03	0.06	RF
0.85	0.13	0.18	0.97	0.04	0.05	MLP
Kashkan Afrineh کشکان افرینه						
0.54	0.18	0.33	0.94	0.05	0.06	LSTM
0.57	0.17	0.24	0.99	0.003	0.007	GRU
0.10	0.18	0.31	0.98	0.02	0.06	RF
0.55	0.20	0.26	0.95	0.07	0.09	MLP
Dareh Tang دره تنگ						
0.48	0.26	0.32	0.68	0.17	0.23	LSTM
0.94	0.09	0.13	0.96	0.05	0.08	GRU
0.56	0.24	0.32	0.94	0.10	0.14	RF
0.92	0.10	0.14	0.69	0.18	0.23	MLP


برای هر دو دسته آموزش و آزمایش عملکرد بهتری دارد. بر این اساس در ایستگاه چول‌هول افرینه نتایج مرحله آزمایش نشان داد که مدل GRU با ضریب همبستگی ۰/۹۵، ریشه میانگین مربعات خطا ۰/۱۰ و میانگین خطای مطلق ۰/۰۶ دارای بهترین عملکرد است. همچنین در ایستگاه کشکان افرینه با توجه به نتایج بخش آزمایش، مدل GRU با ضریب همبستگی ۰/۵۷، ریشه میانگین مربعات خطا ۰/۲۴ و میانگین خطای مطلق ۰/۱۷ به‌عنوان بهترین مدل انتخاب شد. و همچنین برای ایستگاه دره تنگ مدل GRU با ضریب همبستگی ۰/۹۴، ریشه میانگین مربعات خطا ۰/۱۳ و میانگین خطای مطلق ۰/۰۹ در مرحله آزمایش دارای بهترین کارایی است. از نظر دقت، مدل GRU در رتبه نخست قرار دارد و پس از آن MLP قرار می‌گیرد. به‌منظور ارزیابی توان مدل برتر نمودارهای تغییرات و خطا ارائه شده است. شکل‌های ۳ و ۴ نمودارهای داده‌های مشاهداتی و پیش‌بینی بخش آموزش و آزمایش و همچنین نمودارهای داده‌های خطا در بخش آموزش و آزمایش ایستگاه‌های چول‌هول افرینه، کشکان افرینه و دره تنگ را در دوره پربابی نشان می‌دهد. براساس نتایج ارائه شده در این شکل‌ها داده‌های دبی مشاهداتی و پیش‌بینی انطباق بالایی دارند.



شکل ۳- نمودار کارایی مدل برتر در دوره‌ی پرآبی ایستگاه‌ها (الف: چولهول افرینه، ب: کشکان افرینه، ج: دره تنگ)

Fig 3. Performance diagram of the best model during the high-water period

(A: Cholhol Afrineh, B: Kahkan Afrineh, C: Dareh Tang)



شکل ۴- داده‌های خطا در دوره‌ی پرآبی ایستگاه‌ها (الف: چولهول افرینه، ب: کشکان افرینه، ج: دره تنگ)

Fig 4. Error data diagram during the high-water period (A: Cholhol Afrineh, B: Kahkan Afrineh, C: Dareh Tang)

آنالیز حساسیت مدل به معنی اجرای مجدد مدل با حذف پارامترهای ورودی برای تعیین پارامتر موثر بر نتیجه است. برای این اساس جدول ۴ تحلیل حساسیت بهترین مدل برای هر ایستگاه را در دبی دوره پرابی ارائه می‌دهد. نتایج حاصل از این جدول مشخص شد در ایستگاه‌های چولهول افرینه، کشکانه افرینه و دره تنگ همگی با حذف بارش مدل، عملکرد ضعیف‌تری نسبت به حذف سایر پارامترها داشته است و نشان می‌دهد پارامتر بارش بیش‌ترین تاثیر را در مدل‌سازی دارا بوده است.

جدول ۴- تحلیل حساسیت مدل برتر در دوره پرابی ایستگاه‌های هیدرومتری مورد مطالعه

Table 4. Sensitivity analysis of the superior model during the high-water period of the hydrometric stations

پارامتر حذفی	RMSE	MAE	R ²
چولهول افرینه Chohol Afrineh			
تبخیر Evaporation	0.10	0.06	0.95
دما Trmperatures	0.10	0.06	0.95
بارش Rain	0.31	0.16	0
کشکان افرینه Kashkan Afrineh			
تبخیر Evaporation	0.27	0.20	0.53
دما Trmperatures	0.26	0.18	0.53
بارش Rain	0.31	0.16	0.15
دره تنگ Dareh Tang			
تبخیر Evaporation	0.15	0.09	0.93
دما Trmperatures	0.16	0.12	0.90
بارش Rain	0.32	0.17	0.60

مدل‌سازی دبی در دوره کم‌آبی

مقایسه‌ی ضریب همبستگی، میانگین خطای مطلق و ریشه میانگین مربعات خطا برای مدل‌های استفاده شده در جدول ۵ برای دوره کم‌آبی ایستگاه‌های هیدرومتری مورد مطالعه ارائه شده است. نتایج جدول ۶ نشان می‌دهد که در تمام ایستگاه‌ها، مدل‌ها در بخش آموزش دارای نتایج مطلوبی بودند، اما در بخش آزمایش نتایج تغییرات زیادی داشتند و مدل RF بهتر از سایر مدل‌ها عمل کرده است. بر این اساس در ایستگاه چولهول افرینه نتایج مرحله آزمایش نشان داد که مدل RF با ضریب همبستگی ۰/۷۲، ریشه میانگین مربعات خطا ۰/۲۳ و میانگین خطای مطلق ۰/۲۲ دارای بهترین عملکرد است. هم‌چنین در ایستگاه کشکان افرینه با توجه به نتایج بخش آزمایش، مدل RF با ضریب همبستگی ۰/۸۲، ریشه میانگین مربعات خطا ۰/۲۰ و میانگین خطای مطلق ۰/۱۷ به‌عنوان بهترین مدل انتخاب شد. هم‌چنین برای ایستگاه دره تنگ مدل RF با

ضریب همبستگی ۰/۴۳، ریشه میانگین مربعات خطا ۰/۳۸ و میانگین خطای مطلق ۰/۳۴ در مرحله آزمایش دارای بهترین کارایی است.


جدول ۵- پارامترهای ارزیابی مدل‌ها در ایستگاه‌های هیدرومتری مورد مطالعه در دوره کم‌آبی

Table 5. Parameters for evaluating models at the hydrometric stations during the low water period

آزمایش Test			آموزش Train			مدل Model
R ²	MAE	RMSE	R ²	MAE	RMSE	
چولهول افرینه Chohol Afrineh						
0.74	0.20	0.23	0.67	0.16	0.20	LSTM
0.54	0.22	0.25	0.54	0.19	0.22	GRU
0.72	0.22	0.23	0.95	0.08	0.10	RF
-0.75	0.39	0.56	0.60	0.18	0.22	MLP
کشکان افرینه Kashkan Afrineh						
0.74	0.18	0.21	0.64	0.17	0.20	LSTM
0.64	0.19	0.23	0.65	0.16	0.20	GRU
0.82	0.17	0.20	0.94	0.08	0.09	RF
0.67	0.18	0.23	0.61	0.16	0.21	MLP
دره تنگ Dareh Tang						
-0.14	0.33	0.37	0.54	0.19	0.23	LSTM
0.16	0.32	0.36	0.57	0.18	0.22	GRU
0.43	0.34	0.38	0.96	0.08	0.10	RF
0.04	0.33	0.37	0.47	0.20	0.24	MLP

برای ارزیابی بهتر مدل برتر نمودارهای تغییرات دبی در داده‌های مشاهداتی و پیش‌بینی هم‌چنین نمودار داده‌های خطا در شکل‌های ۵ و ۶ برای بخش آموزش و آزمایش ایستگاه‌های چولهول افرینه، کشکان افرینه و دره تنگ را در دوره کم‌آبی نشان می‌دهد.


تحلیل حساسیت به‌منظور شناسایی مهم‌ترین متغیر ورودی در پیش‌بینی دبی جریان ایستگاه‌های مطالعاتی در جدول ۶ تحلیل برای دبی دوره کم‌آبی ارائه شده است. برای این منظور، بهترین مدل یعنی جنگل تصادفی با مجموعه داده موجود مورد استفاده قرار گرفت. مجموعه‌های مختلفی از داده‌های آموزش از طریق حذف تک‌به‌تک هر پارامتر ورودی ایجاد شد و نتایج در قالب ضریب همبستگی، میانگین خطای مطلق و ریشه میانگین مربعات خطا با استفاده از داده‌های آزمایش گزارش شده است. نتایج ارائه شده در جدول ۷ نشان می‌دهد که عامل بارش در مقایسه با سایر ورودی‌ها بیشترین نقش را در پیش‌بینی دبی جریان دارد.



شکل ۵- کارایی مدل برتر در دوره کم آبی ایستگاه‌ها (الف: چولهول افرینه، ب: کشکان افرینه، ج: دره تنگ)

Fig 5. Performance chart of the superior model during the low water period

(A: Chollhol Afrineh, B: Kahkan Afrineh, C: Dareh Tang)



شکل ۶- داده‌های خطا در دوره کم آبی ایستگاه‌ها (الف: چولهول افرینه، ب: کشکان افرینه، ج: دره تنگ)

Fig 6. Error data diagram during the low water period (A: Chollhol Afrineh, B: Kahkan Afrineh, C: Dareh Tang)

جدول ۶- تحلیل حساسیت مدل برتر در دوره کم‌آبی ایستگاه‌های
هیدرومتری مورد مطالعه

Table 6. Sensitivity analysis of the superior model during
the low water period of the hydrometric stations

پارامتر حذفی	RMSE	MAE	R ²
چولهول افرینه Chohol Afrineh			
تبخیر Evaporation	0.23	0.20	0.66
دما Trmperatures	0.22	0.20	0.70
بارش Rain	0.25	0.23	0.50
کشکان افرینه Kashkan Afrineh			
تبخیر Evaporation	0.20	0.17	0.76
دما Trmperatures	0.23	0.19	0.79
بارش Rain	0.22	0.18	0.76
دره تنگ Dareh Tang			
تبخیر Evaporation	0.36	0.32	0.40
دما Trmperatures	0.33	0.34	0.38
بارش Rain	0.29	0.26	-0.11

بحث و نتیجه‌گیری

بارندگی، دما و سیلاب از پارامترهای مهم در بین پارامترهای اقلیمی و هیدرولوژی هستند که پیش‌بینی و شناسایی رفتار آن‌ها برای مدیریت منابع آب از اهمیت ویژه‌ای برخوردار است. شبیه‌سازی جریان رودخانه در ایستگاه‌های هیدرومتری به‌منظور آگاهی از دبی رودخانه اهمیت بالایی دارد. در این تحقیق به مدل‌سازی دبی جریان رودخانه در ایستگاه‌های هیدرومتری چولهول افرینه، کشکان افرینه و دره تنگ حوزه آبخیز کرخه در استان لرستان با استفاده از مدل‌های یادگیری عمیق شامل LSTM و GRU همچنین مدل‌های یادگیری ماشین شامل RF و MLP در بازه زمانی ۱۰ ساله از ۱۳۹۳-۱۳۹۴ تا ۱۴۰۲-۱۴۰۳ در دوران پرآبی و کم‌آبی پرداخته شده است. به‌منظور ارزیابی کارایی این مدل‌ها از ضریب همبستگی (r)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شده است. نتایج حاصل از مدل‌سازی با استفاده از مدل‌های LSTM، GRU و RF برای داده‌های ورودی (تبخیر، دما و بارش) و خروجی (دبی جریان) در دوره کم‌آبی و پرآبی در ایستگاه‌های مختلف (چولهول افرینه، کشکان افرینه و دره تنگ) نشان می‌دهد در بخش پرآبی دبی جریان در قسمت آموزش، بیش‌تر مدل‌ها نتایج خوبی داشته است در حالی‌که در بخش آموزش نتایج همه مدل‌ها دلخواه نبوده و فقط برخی مدل‌ها نتیجه بهتری داشته‌اند. از بین مدل‌های به‌کار برده شده مدل GRU که جزئی از مدل‌های یادگیری عمیق است عملکرد بهتری نسبت به سایر مدل‌ها داشته و در مدل‌سازی دبی جریان نتایج مطلوب‌تری داشته است. همچنین در

قسمت کم‌آبی دبی جریان همه ایستگاه‌ها در قسمت آموزش مدل‌ها نتایج خوبی داشته و در بخش آزمایش در حالت کلی مدل‌ها نتایج بهتری داشته‌اند. از بین مدل‌های استفاده شده در این بخش مدل RF که از مدل‌های یادگیری ماشین اسات باتوجه به معیارهای ارزیابی کارایی مدل عملکرد بهتری داشته و به‌عنوان مدل برتر در مدل‌سازی دبی جریان بخش کم‌آبی در نظر گرفته شده است. در مجموع نتایج مدل‌سازی نشان داد هر دو گروه از مدل‌های یادگیری عمیق و یادگیری ماشین در مدل‌سازی دبی جریان در این بازه زمانی و با استفاده از داده‌های ورودی استفاده شده در ایستگاه‌های مورد مطالعه عملکرد خوبی داشته و قابلیت استفاده در ایستگاه‌های مجاور را دارا هستند. در تحلیل حساسیت مدل‌های برتر در هر دو بخش پرآبی و کم‌آبی نتایج نشان داد پارامتر بارش بیش‌ترین تاثیر را در نتایج مدل داشته و با حذف این پارامتر مدل‌ها نتایج ضعیف‌تری از خود نشان دادند. He و همکاران [۹] در تحقیق خود به این نتیجه رسیدند که مدل‌های مبتنی بر Transformer در پیش‌بینی جریان رودخانه عملکرد بهتری نسبت به LSTM دارند، زیرا قابلیت رمزنگاری هم‌زمان کل توالی ورودی را دارا هستند. نتایج به دست آمده در این تحقیق با پژوهش انجام شده همخوانی دارد. Zhang و همکاران [۲۲] در مطالعه خود، شبکه GRU برای پیش‌بینی جریان در شرایط شدید اقلیمی مورد استفاده قرار گرفته و نشان داده که این مدل در مقابل پرآبی‌های شدید، با دقت بالا مقاومت دارد که با نتایج به دست آمده در این پژوهش همخوانی ندارد زیرا در این پژوهش مدل GRU در بخش پرآبی عملکرد بالایی در همه ایستگاه‌های مورد مطالعه داشته است و مدل برتر بخش پرآبی بوده است. بیرانوند و همکاران [۵] در بررسی عملکرد مدل‌های RF، RepTree، GP-PUK، GP- و M5P در مدل‌سازی رسوب معلق دوره پرآبی و کم‌آبی مدل GP عملکرد بهتری داشته که با نتایج این تحقیق همخوانی ندارد. روشنگر و همکاران [۱۵] به بررسی عملکرد یادگیری عمیق و یادگیری ماشین در پیش‌بینی میزان اکسیژن محلول پرداختند. نتایج نشان‌دهنده برتری یادگیری عمیق بر یادگیری ماشین بوده است که با نتایج این تحقیق مطابقت ندارد. Sepahvand و همکاران [۱۶] به بررسی مدل‌های GP-PUK، GP-RBF، SVM-PUK، SVM-RBF و RF برای حساسیت وقوع زمین لغزش پرداختند. نتایج برتری مدل RF را نسبت به سایر مدل‌ها در مدل‌سازی نشان داد که با نتایج این تحقیق در بخش کم‌آبی همخوانی دارد. پاک‌نژاد و همکاران [۱۲] به بررسی عملکرد مدل‌های RF و ANN در پهنه‌بندی مناطق مستعد دارای جریان‌های واریزه‌ای پرداختند. نتایج نشان دهنده عملکرد بهتر مدل RF بوده است که با نتایج تحقیق انجام شده همخوانی دارد. در نهایت نتایج نشان داد که این پارامترها به‌ویژه تاثیر زیاد پارامتر بارش بر دبی جریان، در مدل‌سازی و پیش‌بینی دبی جریان، باعث بالا بودن دقت مدل می‌شوند.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچگونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

نسرین بیرانوند: نوشتن فایل اولیه مقاله، نرم افزار، منابع، ویرایش متن نهایی، علیرضا سپهوند: راهنمای پروژه، روش کار، ویرایش نهایی، حامد نقوی: مشاور، ویرایش، روش کار. تمام نویسندگان موافق انتشار فایل نهایی مقاله هستند.

منابع مورد استفاده

1. Anwar, H. Khan, A.U. Ullah, B. Taha, A.T.B. Najeh, T. Badshah, M.U. Ghanim, A.A.J. and Irfan, M. 2024. Intercomparison of deep learning models in predicting streamflow patterns: insight from CMIP6. Sci Rep, 14(1):17468. DOI: 10.1038/s41598-024-63989-7.
2. Assad, A. and Bouferguene, A. 2022. Resilience Assessment of Water Distribution Networks – Bibliometric Analysis and Systematic Review. Journal of Hydrology, 607(12), 127522. <https://doi.org/10.1016/j.jhydrol.2022.127522>.
3. Balthazar, L.D. Miranda, F. Cândido, V.B. Capriles, P.V. Moraes, M. Ribeiro, C.B. Fayer, G. and Goliatt, L. 2024. Long-term natural streamflow forecasting under drought scenarios using data-intelligence modeling. Water Cycle, 5(1). DOI: 10.1016/j.watcyc.2024.07.001.
4. Bayatvarkshi, M. Taherinia, B. Hosseinianzade, K. and Fasihi, R. 2024. Forecasting river flow using neural intelligence models and LARS-WG models (Case study: Kashkan Watershed). Water and Soil Management and Modelling, 4(3), 225-238. doi: 10.22098/mmws.2023.12827.1281. (In Persian).
5. Beiranvand, N. Sepahvand, A. and Haghizadeh, A. 2023. Suspended sediment load modeling by machine learning algorithms in low and high discharge periods (Case study: Kashkan watershed). Water and Soil

Management and Modelling, 3(2), 50-65. doi: 10.22098/mmws.2022.11262.1115. (In Persian).

6. Benesty, J. Chen, J. Huang, Y. and Cohen, I. 2009. Pearson correlation coefficient. In Noise Reduction in Speech Processing (pp. 1–4). Springer. https://doi.org/10.1007/978-3-642-00296-0_5.

7. Breiman, L. 2001. Random forests. Machine Learning, 45(1), 5–32. DOI: 10.1023/A:1010950718922.

8. Food and Agriculture Organization of the United Nations (FAO). 2023. The state of food and agriculture 2023: Water, agriculture and food security. FAO. <https://doi.org/10.4060/cc7724en>.

9. He, X. Zhang, L. Wang, Y. Liu, Z. and Chen, M. 2025. Multi-step ahead forecasting of daily streamflow based on Transformer architecture. Scientific Reports, 15(1), Article 89837. <https://doi.org/10.1038/s41598-025-89837-w>.

10. Kundzewicz, Z.W. Kanae, S. Seneviratne, S.I. Handmer, J. Nicholls, N. Peduzzi, P. Mechler, R. Bouwer, L.M. Arnell, N. Mach, K. Muir-Wood, R. Brakenridge, G.R. Kron, W. Benito, G. Honda, Y. Takahashi, K. and Sherstyukov, B. 2014. Flood Risk and Climate Change: Global and Regional Perspectives. Hydrological Sciences Journal, 59(1), 1-28. <https://doi.org/10.1080/02626667.2013.857411>.

11. Moriasi, D.N. Arnold, J.G. Van Liew, M.W. Bingner, R.L. Harmel, R.D. and Veith, T.L. 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. Transactions of the ASABE, 50(3), 885–900. <https://doi.org/10.13031/2013.23153>.

12. Paknejad, F. Ahmadabadi, A. Qanavati, E. and zahmatkesh, H. 2023. Zoning of Susceptible Areas with Debris Flows Using Machine Learning Algorithms (Case study of Tangarah Basin -Golestan Province). E.E.R, 13 (1) :1-28. URL: <http://magazine.hormozgan.ac.ir/article-1-702-fa.html>. (In Persian).

13. Poormohammadi, S. and Goodarzi, M. 2024. Prediction of river flow using SMA continuous model in HEC-HMS under climate change conditions. 7th National Conference on Soil Conservation and Watershed Management, Impacts of Climate Change on Agriculture and Natural Resources. 1271-SCWMCCAN (R1). (In Persian).

14. Rodriguez, V. Ghimire, B. Rogan, J. Chica-Olmo, M. and Rigol-Sánchez, J.P. 2012. An assessment of the

19. Wang, Y. and Witten, I.H. 1997. Inducing model trees for continuous classes. Proceedings of the Ninth European Conference on Machine Learning. Prague, Czech Republic: Springer.
20. Willmott, C.J. and Matsuura, K. 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>.
21. Workneh, H. and Jha, M. 2025. Utilizing Hybrid Deep Learning Models for Streamflow Prediction. *Water*, 17(13), 1913. <https://doi.org/10.3390/w17131913>.
22. Zhang, Y. Zhou, Z. Deng, Y. Pan, D. Van Griensven Thé, J. Yang, S.X. and Gharabaghi, B. 2024. Daily Streamflow Forecasting Using Networks of Real-Time Monitoring Stations and Hybrid Machine Learning Methods. *Water*, 16(9), 1284. <https://doi.org/10.3390/w16091284>.
- effectiveness of a Random Forest classifier for land-cover classification. *ISPRS Journal of Photogram Remote Sens*, 67, 93 -104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>.
15. Roushangar, K. and Davoudi, S. 2022. Comparing the Performance of Deep Learning and Machine Learning Methods in Predicting Dissolved Oxygen Content. *Iranian Journal of Soil and Water Research*, 53(8), 1885-1900. doi: 10.22059/ijswr.2022.344088.669288. (In Persian).
16. Sepahvand, A. Sihag, P. and Moradi, S. 2022. Application of the various soft computing techniques for Landslide susceptibility mapping (Case study: A part of Haraz Watershed). *Research Square*, DOI: 10.21203/rs.3.rs-1926899/v1.
17. Sharif Zak, M. and Barani, A.G. 2018. Forecasting the flow rate in mixed channels using neural network algorithms, the first national conference on civil engineering and development, Zibakanar, Rasht, Gilan. (In Persian).
18. Sihag, P. Singh, B. Sepahvand, A. and Mehdipour, V. 2020. Modeling the infiltration process with soft computing techniques, *ISH Journal of Hydraulic Engineering*, 26(2): 138-152. DOI: 10.1080/09715010.2018.1464408.