

Research Paper

Evaluation of the Performance of Long Short-Term Memory Neural Network in Flood Forecasting

Somayeh Shahri^{*1}, Amir Safari²,

¹ Yazd University, Faculty of Art and Architecture, Wind Catcher International Research Center (WCRC), Postdoctoral Researcher, National Science Foundation of Iran

^{*}(Corresponding author: Email:shahrister@gmail.com

² Kharazmi University - Faculty of Geographical Sciences - Department of Physical Geography, Email:saffari@khu.ac.ir



10.22125/iwe.2025.554010.1902

Received:
September 17, 2025
Accepted:
December 17, 2025
Available online:
December 25, 2025

Keywords:
Flood, Forecast, Artificial
Intelligence, Deep Learning,
Long-Short-Term Memory
Neural Network

Abstract

Flooding is one of the most dangerous natural disasters that can cause irreparable damage to human societies. Accurate flood prediction is essential for reducing damages and better planning. This study describes the potential application of long short-term memory (LSTM) neural network, an example of deep learning neural network architecture, for explicit spatial prediction and mapping of flash flood probability. These models were trained based on hydrological and meteorological data and their performance was evaluated using various criteria. The performance of this model seemed to provide stronger results than classical statistical models, but due to the shortcomings and large number of inconsistent data in central Iran, which usually refers to the spatial dispersion of stations and measurement errors and the lack of metadata, and their access is also somewhat difficult. On the other hand, the main river of the basin has a seasonal nature and due to the prevailing climatic conditions, the frequent occurrence of zero discharge values causes uncertainty and error in the model training process. Using historical hydrometric station data from 1991 to 2024, in order to estimate the baseline conditions as well as the precipitation data of the corresponding meteorological stations, advanced methods such as extreme gradient boosting (XGBoost), Shapley incremental description analysis (SHAP), and analysis of variance (ANOVA) were used to determine the most important factors affecting the river flow. The findings showed that the most appropriate scenario for parameter selection is the M7 scenario, in which the current day's discharge with a time delay of two days ago and precipitation data from only two stations "Aligoli Bardestan" and "Faizabad" were used instead of using data from 9 basin stations; this scenario provided a favorable performance with a Nash coefficient (NSE) equal to 0.6 in the test phase and 0.5 in the training phase. However, the presented prediction showed that the model faced challenges in estimating peak discharges and tended to greatly underestimate peak discharges due to the large number of zeros. This shows that although neural network models are powerful tools for hydrological modeling, they are suitable for modeling normal time

^{*} **Corresponding Author:** Somayeh Shahri

Address: Yazd University, Faculty of Art and Architecture,
Wind Catcher International Research Center (WCRC),
Postdoctoral Researcher, National Science Foundation of Iran

Email: shahrister@gmail.com
Tel: 989131546576

series of water flow and general trends, and are not sufficient for accurate flood peak prediction alone and only when supplemented with data corrections, error function modification, or combination with other methods (physical models, peak classification, or quantile/ensemble models) become safe for more advanced methods such as flood warning.

1. Introduction

Floods are one of the most devastating hydrological hazards that can cause serious damage to infrastructure, human settlements, and natural resources in the shortest possible time. Estimating the probability and severity of floods requires accurate analysis of historical data including precipitation, temperature, river water level, and soil moisture. In recent years, the application of artificial intelligence and intelligent optimization methods in water engineering has emerged as one of the leading research fields. The increasing need to design efficient systems, reduce operating costs, and increase the safety of water structures has led to data-driven models and predictive approaches finding a special place in the analysis, design, and management of water resources. Especially in areas such as water supply networks, transient flow behavior, determination of material properties, and flood management, the use of artificial intelligence models has been feasible and effective. Since the 2010s, flood forecasting has been mainly based on classical statistical models; however, with the expansion of large and complex hydrological data, machine learning methods have gradually replaced traditional methods. Since 2020, deep learning, with the ability to automatically extract features from data, has become one of the dominant approaches in predicting hydrological time series, and several studies have emphasized the superior performance of these models (Li et al., 2021; Wang et al., 2022; Zhang et al., 2023). As a first step, the use of optimization methods in the design of water supply systems has been considered. The research work of Kianfard and Ahadiyan (2016) showed that optimizing water supply networks under pressure and transient flow not only reduces pressure drop and energy consumption, but can also lead to a more economical design with more reliable performance for the network. This approach demonstrates the effective role of intelligent algorithms and decision-making models in hydraulic analysis and structural design. According to global reports, about 84% of natural disaster losses are related to floods (Jamal et al., 2020). It is also estimated that economic losses due to floods in many countries are about \$60 billion annually (Convertino et al., 2019; Janizadeh et al., 2019). In the last decade, the intensification of the effects of climate change has led to an increase in the frequency and severity of floods; in some areas, more than 25,000 residential units were destroyed and about \$2.5 billion in damage was caused to agricultural infrastructure and water resources in 2022–2023 (Heinz et al., 2024; Spitalar et al., 2024). The first step in flood management is to identify and analyze the risk in flood-prone areas; because this analysis enables preventive planning, damage reduction, and optimal resource allocation. In line with this goal, there is a need for accurate and reliable tools that can estimate the time, location, and extent of flood occurrence (Biotayel, 2019; Choubin et al., 2019). Initially, flood risk modeling was performed with bivariate and multivariate statistical methods such as frequency ratio, weight of evidence, and logistic regression (Khosravi, 2018). However, the simplicity of these models reduced the prediction accuracy and ignored complex hydrological behavior. The importance of optimization in the design of water distribution and transmission systems has also been highlighted in the study of Ahadiyan et al. (2023). In this study, the dimensions of the agricultural water transfer system from Karun 3 Dam were reviewed using analytical and optimization methods, and the results showed that the use of intelligent decision-making models in large water transfer projects can reduce costs, increase efficiency, and reduce water losses. The use of data-driven models in this area of water engineering is an important step towards

improving engineering decision-making and resource management. Since the beginning of the 2020s, machine learning models and then deep learning have been widely used to predict natural hazards such as fire (Jafari et al., 2020), drought (Rahmati et al., 2021), earthquake (Alizadeh et al., 2022), erosion (Azare et al., 2024), subsidence (Bouy et al., 2023), and landslides (Chen et al., 2024). This trend continued in 2024 and 2025, leading to significant improvements in model accuracy. The use of machine learning methods in the analysis of material behavior and hydraulic systems has introduced a new generation of AI capabilities. Sharififard et al. (2024) determined creep coefficients in viscoelastic pipes using a transient flow-driven machine learning model. This intelligence-driven method has enabled more accurate analysis of the dynamic behavior of pipes, prediction of structural performance, and improvement of design capabilities. AI has also been applied in a practical and effective way in the field of flood risk management and safety of hydraulic structures. In the study of Sajjadi et al. (2024), the redesign of emergency spillways, fuse plugs, and flood warning systems was carried out using data analysis algorithms and intelligent methods. The results of this study showed that AI models can predict floods more accurately and provide cheaper and safer solutions to improve dam safety and reduce flood damage. With the development of deep learning, semi-supervised models have been proposed that can use labeled and unlabeled data simultaneously, thus increasing the accuracy of prediction. This approach has also been effective in the field of flood prediction and has been able to reduce the limitations of traditional supervised methods (Daou et al., 2020; Samin et al., 2021; recent works 2024–2025). Among deep learning models, long-short-term memory (LSTM) networks have attracted much attention in recent years due to their special ability to learn temporal patterns and analyze long-term dependencies. Although LSTMs have been used in many time series applications such as hydroclimatology and river flow modeling, the use of these networks for spatial mapping of flood probability is still in the research stage and few studies have been reported in this area (Studies 2023; Studies 2024; Studies 2025). The results of these studies show that artificial intelligence in water engineering is not only an analytical or computational tool, but also a data-driven decision-making approach to improve design accuracy, reduce resource waste, and manage hydrological hazards. From the design of water supply systems to flood forecasting, the introduction of machine learning models and modern optimization has created a new path for the development of water technologies and increased the level of resilience of hydraulic infrastructure. In summary, the need for new studies and a review of past studies show that traditional statistical methods are not able to model the complexity of flood behavior and that machine learning models perform better for complex behaviors, but require appropriate characterization. Deep learning models, especially LSTM, have the ability to extract automatic features and are suitable for time series data. Despite these advantages, the application of semi-supervised deep networks for spatial mapping of flood probability is still emerging and requires more extensive research. Therefore, the development of intelligent models based on semi-supervised deep learning, the design of data-driven frameworks for areas without complete data, and the evaluation of models at a spatial scale are among the necessities of future studies.

2. Materials and Methods

In this study, we used a type of deep learning neural network, namely long short-term memory (LSTM) networks, which are well-suited for time series data and forecasting based on past trends, for spatial prediction and mapping of flood probability. Despite the widespread use of this model, it has rarely been used for mapping flood probability worldwide. The Taft Pishkough watershed, which is geographically located between latitudes 17°49'31" and 11°33'31" North and longitudes 14°51'53" and 22°2'54" East, was selected as the study area. This basin is located in Taft city and 30 kilometers from Yazd province. In the present study, an attempt is made to evaluate the accuracy of data-driven artificial intelligence models for predicting the discharge value at different stations of the Pishkooch basin in order to determine the optimal

model for each station, and to determine the performance of each model in different parts of the basin. For this purpose, only stations were selected to select the stations available at the basin level that were either on the main branch of the basin river or on the branches of the upstream elevations of the basin that ultimately affect the discharge of the basin, which makes it possible to track and examine the changes in flow discharge along the river path. In this case, the performance of the aforementioned artificial intelligence models can be evaluated at different elevations (from upstream to downstream). As a result, 9 stations were selected for daily precipitation data and only 1 hydrometric station in Feyzabad was selected for flow discharge data,

3. Results

After the most effective scenario was determined using the optimal structure, the flow rate prediction was performed by the LSTM model for the time series data from 1991 to 2024 for one day in the future, and what can be seen from the prediction trend is that the values are very high from the beginning of 1991 (more than 2 cases), but in the final period (2023–2024) they reach almost zero, indicating a gradual decrease in flow over the period. The most striking points in the difference between Predicted and Observed in the entire data are that at high flow values (2 to 2.6) the model has an error of 20 to 40%, but at low values (close to zero) the model is almost accurate and overall the model behaves conservatively compared to the actual value (the predicted flow rate is always estimated to be lower than the observed flow rate). The overall trend of water flow from 1991 to 2024 is decreasing and the actual maximum flow rate is about 30% higher than the prediction.

The results in all scenarios showed that the model struggled to estimate peak discharges and tended to underestimate peak discharges due to the large number of zeros in the data. In other words, the model is less accurate at high values but performs very well near zero. The mean error is small, so the predictions are close to the actual data. The R^2 value of 0.55 indicates that the model is usable but not optimal. This shows that although neural network models are powerful tools for hydrological modeling, they are highly dependent on accurate and regular data and require long-term time series statistics.

From the results of the statistical analysis of the prediction model with respect to the actual data and the evaluation of the model accuracy indices, it can be estimated that there was an average difference of about 0.4 units between the predicted and actual values ($RMSE = 0.418$), which is acceptable considering the overall values (2 to 0). ($MAE = 0.083$), meaning that in the average case there was about 0.08 units of error, which is considered a very low and good value. MAE smaller than $RMSE$ indicates that we have a few outliers. $MSE = 0.175$ is the mean square error and is sensitive to outliers. $R^2 = 0.55$ means that the model explains about 55 percent of the actual changes, and this value indicates a good average performance.

4. Discussion and Conclusion

Based on the presented results (time series data 1991–2024, one-day forecast, $R^2 = 0.55$, 20–40% error in peak values and good accuracy in values close to zero, the tendency of the model to “under-predict” peak discharges and a gradual decrease in discharge trend over the years), it can be concluded that the LSTM model is a promising tool for this area, but it is not sufficient and optimal on its own, especially if the goal is a flood warning mechanism or accurate peak estimation. The model is capable of modeling the overall structure of the time series and low discharges, but it shows a significant weakness in estimating peak events (high-risk from a flood perspective) that should be compensated by data/model corrections and completion. Of course, if the goal is simply to “determine the general trend” or “manage water resources under normal conditions,” LSTM is perfectly suitable and practical, but if the goal is “flood warning” or “accurate prediction of peaks,” the situation is uncertain and requires correction, because underestimating the peaks

is risky. However, suggestions are made to improve the model performance in this regard to reduce the estimation risk, including the following:

- Modifying the cost function to focus on peaks: weighting samples (sample weighting) or using a combined cost function to give more weight to the error in peak values. (For example: weighting samples with discharge > threshold or using Huber/Quantile loss for sensitivity to peaks).
- Increasing peak samples (data augmentation): Oversampling peak events or using SMOTE-like methods for time series data to expose the model to more examples of peak patterns.
- Making the model two-stage (hybrid approach): The first stage is a classification model (binary) to detect the "probability of peak/flood occurrence"; and in the second stage, if the probability is high, a regression model (peak-specific or a physical-mathematical model such as HBV drainage) is used. This prevents systematic underestimation of the peak.
- Adding exogenous inputs: forecasted precipitation, soil moisture, dam status, snowmelt, and multi-day flow history can increase the model's ability to catch the peak.
- Using hybrid physics-informed + data-driven models: Using a physical or quasi-physical model to estimate the maximum capacity and then correcting it with LSTM (physics-informed / hybrid) can significantly improve the peak accuracy.
- Calibration and bias correction: After forecasting, methods such as quantile mapping or multiplicative bias correction can be used to eliminate systematic underestimation bias.
- Uncertainty modeling and quantile outputs: Instead of a single point prediction, a distribution or confidence interval prediction (e.g., 90% quantile) can be provided to better reflect the risk of decision makers.
- Validation of appropriate metrics for hydrology: In addition to R², Probability of Detection (POD), or False Alarm Rate (FAR) can be used to assess peaks.

In the present study, as can be estimated from the results, the optimal structure for the LSTM model to predict streamflow was different for each input scenario, so that according to these results, functions with a limited number of neurons in the hidden layer perform better than other functions, and in this study, the most appropriate structure is M7. Although this structure is not very satisfactory considering the cases mentioned above, in general, considering that our basin, despite classifying the data and resolving the challenge of data imbalance as much as possible, is still considered a dry basin with a seasonal river, the abundance of zero data and also the short time series of 34 years cannot be responsive to deep learning machine models and poses a problem for training the model. In other words, in arid and semi-arid basins, the distribution of precipitation and river discharge (discharge) is such that for a large part of the year, the discharge is very low or close to zero, and only in limited time periods is a significant figure observed. Given this imbalance, simpler empirical methods and the use of hydrological relations and physical models in training machine learning models for flood simulation can help us more. In general, LSTM is a powerful and suitable tool for modeling water flow time series and general trends, but it is not sufficient alone to accurately and safely predict flood peaks and must be supplemented and calibrated by data corrections, error function changes, or combination with other methods (physical models, peak classification, or quantile/ensemble models) to be reliable for flood warning.

5. Six important references

- 1) Ahadiyan J., Kiani S., Asiaban P., Azizi Nadian H., Omidvarinia M. (2023). 'Optimizing the dimensions of the agricultural water transfer system from the Karun 3 dam to the northeastern cities of Khuzestan province', *Journal of New Approaches in Water Engineering and Environment*, 1(2), pp. 112-126. doi: 10.22034/nawee.2023.367835.1030.
- 2) Chen, W., Hong, H., Panahi, M., Shahabi, H., Wang, Y., Shirzadi, A., Pirasteh, S., Alesheikh, A.A., Khosravi, K., Panahi, S., 2019a. Spatial prediction of landslide susceptibility using GIS-based data mining techniques of ANFIS with whale optimization algorithm (WOA) and grey wolf optimizer (GWO). *Appl. Sci.* 9 (18), 3755.
- 3) Ebrahim Sharififard, Mohamad Azizipour, Javad Ahadiyan, Ali Haghghi; Determination of creep function coefficients of viscoelastic pipes using a transient-guided machine learning model. *AQUA - Water Infrastructure, Ecosystems and Society* 1 November 2024; 73 (11): 2132–2149. doi: <https://doi.org/10.2166/aqua.2024.091>
- 4) Kianfard, M., Ahadiyan, J. (2016). 'Optimization of under pressure water supply network with transient flow using linear programming method', *Iranian Water Researches Journal*, 10(2), pp. 37-46. https://iwrij.sku.ac.ir/article_10477.html?lang=en.
- 5) Olah C (2015) Understanding LSTM Networks.
- 6) Sajjadi, S.M.; Barihi, S.; Ahadiyan, J.; Azizi Nadian, H.; Valipour, M.; Bahmanpouri, F.; Khedri, P. Redesigning the Fuse Plug, Emergency Spillway, and Flood Warning System: An Application of Flood Management. *Water* 2024, 16, 3694. <https://doi.org/10.3390/w16243694>.



ارزیابی کارایی شبکه عصبی حافظه طولانی کوتاه‌مدت در پیش‌بینی سیلاب

(مطالعه موردی: حوضه پیشکوه تفت)

سمیه شهری*^۱، امیرصفاری^۲

تاریخ ارسال: ۱۴۰۴/۰۶/۲۶

تاریخ پذیرش: ۱۴۰۴/۰۱/۲۶

چکیده

پدیده سیل یکی از خطرناک‌ترین بلایای طبیعی است که می‌تواند خسارات جبران‌ناپذیری به جوامع انسانی وارد کند. پیش‌بینی دقیق سیل به منظور کاهش خسارت‌ها و برنامه‌ریزی بهتر ضروری است. این مطالعه کاربرد بالقوه شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) از نمونه معماری شبکه‌های عصبی یادگیری عمیق، را برای پیش‌بینی و نقشه‌برداری مکانی صریح از احتمال سیل ناگهانی شرح می‌دهد. این مدل‌ها بر اساس داده‌های هیدرولوژیکی و هواشناسی آموزش داده شده و کارایی آنها با استفاده از معیارهای مختلف ارزیابی شده است. به نظر می‌رسد عملکرد این مدل نتایج قویتری نسبت به مدل‌های آماری کلاسیک ارائه دهد اما با توجه به نقص و تعداد فراوان داده‌های ناسازگار در ایران مرکزی که معمولاً به پراکندگی مکانی ایستگاه‌ها و خطاهای اندازه‌گیری و عدم وجود متادیتا برمی‌گردد و دسترسی به آنها نیز تا حدی دشوار است، از سوی دیگر، رودخانه اصلی حوضه ماهیتی فصلی داشته و بر اثر شرایط اقلیمی غالب، وقوع فراوان مقادیر صفر دبی باعث ایجاد عدم قطعیت و خطا در فرآیند آموزش مدل می‌شود. با بهره‌گیری از داده‌های تاریخی ایستگاه هیدرومتری طی دوره ۱۹۹۱ تا ۲۰۲۴، به منظور تخمین شرایط پایه و همچنین داده‌های بارش ایستگاه‌های هواشناسی متناظر، از روش‌های پیشرفته‌ای نظیر تقویت گرادیان شدید (XGBoost)، تحلیل توضیحات افزایشی شپلی (SHAP) و تحلیل واریانس (ANOVA) برای تعیین مهم‌ترین عوامل مؤثر بر جریان رودخانه استفاده شد. یافته‌ها نشان دادند که مناسب‌ترین سناریوی انتخاب پارامترها، سناریوی M7 است که در آن دبی روز جاری با تأخیر زمانی دو روز قبل و داده‌های بارشی صرفاً از دو ایستگاه «علیقلی بردستان» و «فیض‌آباد» به‌جای استفاده از داده‌های ۹ ایستگاه حوضه به‌کار گرفته شد؛ این سناریو عملکرد مطلوبی با ضریب نش (NSE) برابر با ۰/۶ در مرحله آزمایش و ۰/۵ در مرحله آموزش ارائه داد. البته پیش‌بینی ارائه شده نشان داد که تخمین این مدل در دبی‌های اوج با چالش مواجه بوده و تمایل دارد دبی‌های اوج را با توجه به مقادیر وسیع صفر، بسیار کم تخمین بزند. این موضوع نشان می‌دهد که هرچند مدل‌های شبکه عصبی ابزار قدرتمندی برای مدل‌سازی هیدرولوژیکی هستند اما برای مدل‌سازی سری‌زمانی نرمال جریان آب و روندهای کلی مناسب است، و برای پیش‌بینی دقیق اوج‌های سیلاب به تنهایی کفایت نمی‌کند و تنها در صورت تکمیل با اصلاحات داده‌ای، تغییر تابع خطا، یا ترکیب با روش‌های دیگر (مدل‌های فیزیکی، طبقه‌بندی اوج، یا مدل‌های کوانتیلی/ensemble) برای روش‌های پیشرفته‌تر مانند هشدار سیلاب ایمن می‌گردد.

واژه‌های کلیدی: سیلاب، پیش‌بینی، هوش مصنوعی، یادگیری عمیق، شبکه عصبی حافظه طولانی کوتاه‌مدت

*۱- دانشگاه یزد، دانشکده هنر و معماری، مرکز پژوهشی بین‌المللی یادگیری، پژوهشگر پسادکتری، بنیاد ملی علم ایران
(نویسنده مسئول: Email:shahrister@gmail.com)

۲- دانشگاه خوارزمی - دانشکده علوم جغرافیایی - گروه آموزشی جغرافیای طبیعی، email:saffari@khu.ac.ir

مقدمه

سیل یکی از ویرانگرترین مخاطرات هیدرولوژیکی محسوب می‌شود که می‌تواند در کوتاه‌ترین زمان خسارات جدی به زیرساخت‌ها، سکونتگاه‌های انسانی و منابع طبیعی وارد سازد. تخمین احتمال وقوع و شدت سیلاب، نیازمند تحلیل دقیق داده‌های تاریخی شامل بارش، دما، تراز آب رودخانه و رطوبت خاک است. در سال‌های اخیر، کاربرد هوش مصنوعی و روش‌های بهینه‌سازی هوشمند در مهندسی آب به‌عنوان یکی از زمینه‌های پژوهشی پیشرو مطرح شده است. نیاز روزافزون به طراحی سامانه‌های کارآمد، کاهش هزینه‌های بهره‌برداری، و افزایش ایمنی سازه‌های آبی موجب شده است که مدل‌های مبتنی بر داده و رویکردهای پیش‌بینی‌گر در تحلیل، طراحی و مدیریت منابع آب جایگاه ویژه‌ای پیدا کنند. به‌ویژه در حوزه‌هایی نظیر شبکه‌های آبرسانی، رفتار گذرای جریان، تعیین ویژگی‌های مصالح، و مدیریت سیلاب، استفاده از مدل‌های هوش مصنوعی امکان‌پذیر و اثربخش بوده است.

از دهه ۲۰۱۰ به بعد، پیش‌بینی سیلاب عمدتاً بر مدل‌های آماری کلاسیک مبتنی بود؛ اما با گسترش داده‌های حجیم و پیچیده هیدرولوژیکی، روش‌های یادگیری ماشین به‌تدریج جایگزین روش‌های سنتی شدند. از سال ۲۰۲۰ به بعد، یادگیری عمیق با توانایی استخراج خودکار ویژگی‌ها از داده‌ها، به یکی از رویکردهای غالب در پیش‌بینی سری‌های زمانی هیدرولوژیکی تبدیل شده است و مطالعات متعددی بر برتری عملکرد این مدل‌ها تأکید کرده‌اند (Li et al., 2021; Wang et al., 2022; Zhang et al., 2023). در نخستین گام، بهره‌گیری از روش‌های بهینه‌سازی در طراحی سیستم‌های آبرسانی مورد توجه قرار گرفته است. کار پژوهشی (Ahadiyan & Kianfard, 2016) نشان داد که بهینه‌سازی شبکه‌های آبرسانی تحت فشار و جریان گذرا، نه تنها موجب کاهش افت فشار و مصرف انرژی می‌شود، بلکه می‌تواند طراحی اقتصادی‌تر با عملکرد مطمئن‌تر برای شبکه به همراه داشته باشد. این رویکرد نشان‌دهنده نقش موثر الگوریتم‌های هوشمند و مدل‌های تصمیم‌گیری در تحلیل هیدرولیکی و طراحی سازه‌ها است. بر اساس گزارش‌های

جهانی، حدود ۸۴٪ تلفات ناشی از بلایای طبیعی مربوط به سیلاب است (Jamal et al., 2020). همچنین برآورد شده که خسارات اقتصادی ناشی از سیلاب در بسیاری از کشورها سالانه حدود ۶۰ میلیارد دلار است (Convertino et al., 2019; Janizadeh et al., 2019). اثرات تغییر اقلیم موجب افزایش فراوانی و شدت سیلاب‌ها شده است؛ به‌گونه‌ای که در رخدادهای سال ۲۰۲۲-۲۰۲۳ در برخی مناطق، بیش از ۲۵ هزار واحد مسکونی تخریب و حدود ۲.۵ میلیارد دلار خسارت به زیرساخت‌های کشاورزی و منابع آب وارد شده است (Heinz et al., 2024; Spitalar et al., 2024). گام نخست مدیریت سیلاب، شناسایی و تحلیل خطر در پهنه‌های مستعد وقوع سیلاب است؛ زیرا این تحلیل امکان برنامه‌ریزی پیشگیرانه، کاهش خسارات و تخصیص بهینه منابع را فراهم می‌آورد. در راستای این هدف، نیاز به ابزارهایی دقیق و قابل اتکا وجود دارد که توانایی تخمین زمان، مکان و گستره وقوع سیلاب را داشته باشند (Biotayel, 2019; Choubin et al., 2019). در ابتدا، مدل‌سازی خطر سیلاب با روش‌های آماری دو و چندمتغیره نظیر نسبت فراوانی، وزن شواهد و رگرسیون لجستیک انجام می‌شد (Khosravi, 2018). با این حال، سادگی این مدل‌ها موجب کاهش دقت پیش‌بینی و چشم‌پوشی از رفتار پیچیده هیدرولوژیکی می‌شد. اهمیت بهینه‌سازی در طراحی سامانه‌های توزیع و انتقال آب، در پژوهش Ahadiyan و همکاران (۲۰۲۳) نیز برجسته شده است. در این تحقیق، ابعاد سیستم انتقال آب کشاورزی از سد کارون ۳ به کمک روش‌های تحلیلی و بهینه‌سازی مورد بازنگری قرار گرفت و نتایج نشان داد که استفاده از مدل‌های تصمیم‌یار هوشمند در پروژه‌های بزرگ انتقال آب، می‌تواند موجب کاهش هزینه‌ها، افزایش راندمان و کاهش تلفات آبی شود. به کارگیری مدل‌های مبتنی بر داده در این بخش از مهندسی آب گامی مهم در جهت ارتقای تصمیم‌سازی مهندسی و مدیریت منابع محسوب می‌شود.

از ابتدای دهه ۲۰۲۰، مدل‌های یادگیری ماشینی و سپس یادگیری عمیق، به‌طور گسترده برای پیش‌بینی مخاطرات



LSTM در بسیاری از کاربردهای سری زمانی نظیر هیدروکلیماتولوژی و مدل‌سازی جریان رودخانه استفاده شده است، اما استفاده از این شبکه‌ها برای نقشه‌برداری مکانی احتمال سیلاب هنوز در مرحله پژوهشی بوده و مطالعات کمی در این حوزه گزارش شده‌اند (Studies 2025; Studies 2024; 2023). برآیند این مطالعات نشان می‌دهد که هوش مصنوعی در مهندسی آب نه تنها ابزار تحلیلی یا محاسباتی، بلکه یک رویکرد تصمیم‌گیری متکی بر داده برای ارتقای دقت طراحی، کاهش اتلاف منابع، و مدیریت مخاطرات هیدرولوژیک است. از طراحی سامانه‌های آبرسانی تا پیش‌بینی سیلاب، ورود مدل‌های یادگیری ماشین و بهینه‌سازی نوین مسیر تازه‌های برای توسعه فناوری‌های آبی و افزایش سطح تاب‌آوری زیرساخت‌های هیدرولوژیکی به وجود آورده است.

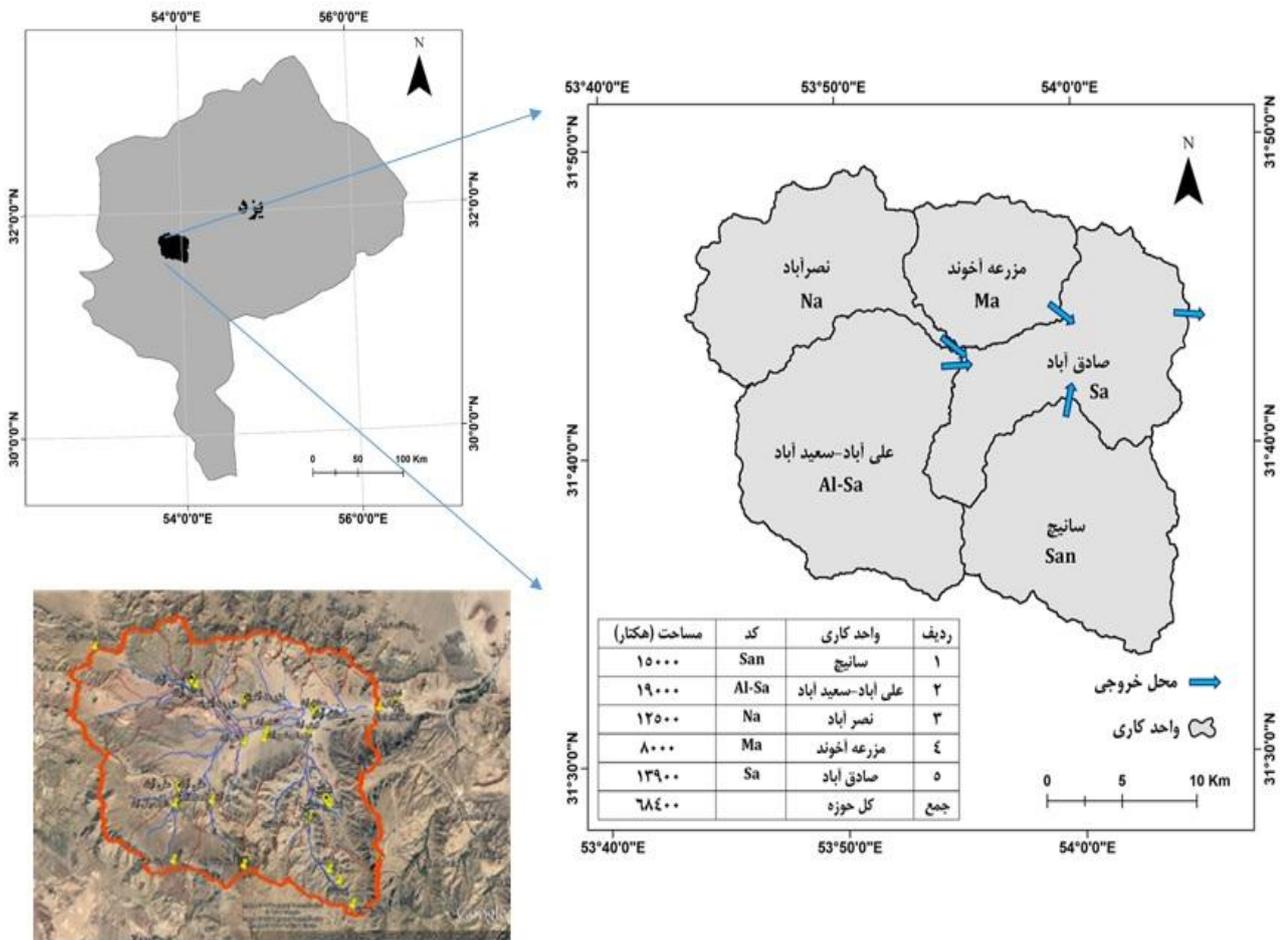
در مجموع ضرورت انجام مطالعات جدید و مروری بر مطالعات گذشته نشان می‌دهد که روش‌های آماری سنتی قادر به مدل‌سازی پیچیدگی رفتار سیلاب نیستند و مدل‌های یادگیری ماشین عملکرد بهتری برای رفتارهای پیچیده دارند، اما نیازمند ویژگی‌سازی مناسب‌اند. مدل‌های یادگیری عمیق به‌ویژه LSTM، توانایی استخراج ویژگی خودکار را دارند و مناسب داده‌های سری زمانی‌اند. با وجود این مزایا، کاربرد شبکه‌های عمیق به‌صورت نیمه‌نظارتی برای نقشه‌برداری مکانی احتمال سیلاب هنوز نوظهور بوده و به تحقیقات گسترده‌تر نیاز دارد. بنابراین، توسعه مدل‌های هوشمند مبتنی بر یادگیری عمیق نیمه‌نظارتی، طراحی چارچوب‌های داده‌محور برای مناطق فاقد داده کامل، و ارزیابی مدل‌ها در مقیاس مکانی، از ضرورت‌های مطالعات آینده به‌شمار می‌رود.

مراحل انجام پژوهش

در این تحقیق حوضه آبخیز پیشکوه تفت که از نظر جغرافیایی بین عرض‌های $31^{\circ} 17' 17''$ و $31^{\circ} 33' 31''$ شمالی و طول‌های $53^{\circ} 51' 14''$ و $54^{\circ} 22' 22''$ شرقی واقع شده، به عنوان منطقه مورد مطالعه انتخاب شد. این حوضه در شهرستان تفت و در فاصله ۳۰ کیلومتری استان یزد قرار گرفته است (شکل ۱).

طبیعی مانند آتش‌سوزی (Jafari et al., 2020)، خشکسالی (Alizadeh et al., 2021)، زلزله (Rahmati et al., 2021)، فرسایش (Azare et al., 2024)، فرونشست (Bouy et al., 2023) و رانش زمین (Chen et al., 2024) به‌کار گرفته شدند. این روند در ۲۰۲۴ و ۲۰۲۵ نیز ادامه یافته و به ارتقای چشم‌گیر دقت مدل‌ها منجر شده است. استفاده از روش‌های یادگیری ماشین در تحلیل رفتار مواد و سیستم‌های هیدرولوژیکی نسل جدیدی از قابلیت‌های هوش مصنوعی را معرفی کرده است. پژوهش Sharififard و همکاران (۲۰۲۴) با به‌کارگیری مدل یادگیری ماشینی هدایت‌شده توسط جریان گذرا، ضرایب خزش در لوله‌های ویسکوالاستیک را تعیین نمود. این روش هوش‌محور، امکان تحلیل دقیق‌تر رفتار دینامیکی لوله‌ها، پیش‌بینی عملکرد سازه و ارتقای قابلیت‌های طراحی را فراهم کرده است. در حوزه مدیریت ریسک سیلاب و ایمنی سازه‌های آبی نیز هوش مصنوعی به‌صورت کاربردی و مؤثر به کار گرفته شده است. در مطالعه Sajjadi و همکاران (۲۰۲۴)، بازطراحی سرریز اضطراری، فیوزپلاگ و سامانه هشدار سیلاب با استفاده از الگوریتم‌های تحلیل داده و روش‌های هوشمند انجام شد. نتایج این پژوهش نشان داد که مدل‌های هوش مصنوعی قادرند پیش‌بینی سیلاب را با دقت بیشتر انجام داده و راهکارهای کم‌هزینه‌تر و ایمن‌تر برای بهبود ایمنی سد و کاهش خسارات ناشی از وقوع سیلاب ارائه دهند.

همگام با توسعه یادگیری عمیق، مدل‌های نیمه‌نظارتی پیشنهاد شده‌اند که قادرند از داده‌های برچسب‌دار و بدون برچسب به‌صورت هم‌زمان استفاده کنند و به این ترتیب دقت پیش‌بینی را افزایش دهند. این رویکرد در حوزه پیش‌بینی سیلاب نیز اثرگذار بوده و توانسته محدودیت‌های روش‌های نظارت‌شده سنتی را کاهش دهد (Daou et al., 2020; Samin et al., 2021; Recent works 2024–2025). از میان مدل‌های یادگیری عمیق، شبکه‌های حافظه بلند-کوتاه مدت (LSTM) به دلیل توانایی ویژه در یادگیری الگوهای زمانی و تحلیل وابستگی‌های بلندمدت، در سال‌های اخیر توجه زیادی را به‌خود جلب کرده‌اند. اگرچه



شکل (۱): موقعیت حوضه پیشکوه تفت در استان یزد

حوضه که در نهایت روی دبی خروجی حوضه تاثیرگذار - باشد که امکان روندیابی و بررسی تغییرات دبی جریان در طول مسیر رودخانه وجود دارد. در این حالت می توان عملکرد مدل های نامبرده از هوش مصنوعی را در ارتفاعات مختلف (از بالادست به سمت پایین دست) ارزیابی کرد. در نتیجه، نه ایستگاه زیر جهت داده های بارش روزانه و تنها یک ایستگاه هیدرومتری فیض آباد جهت داده های دبی جریان انتخاب گردیدند که مشخصات و موقعیت آن ها در جدول ۱ و جدول ۲ و همچنین شکل ۲ آورده شده است.

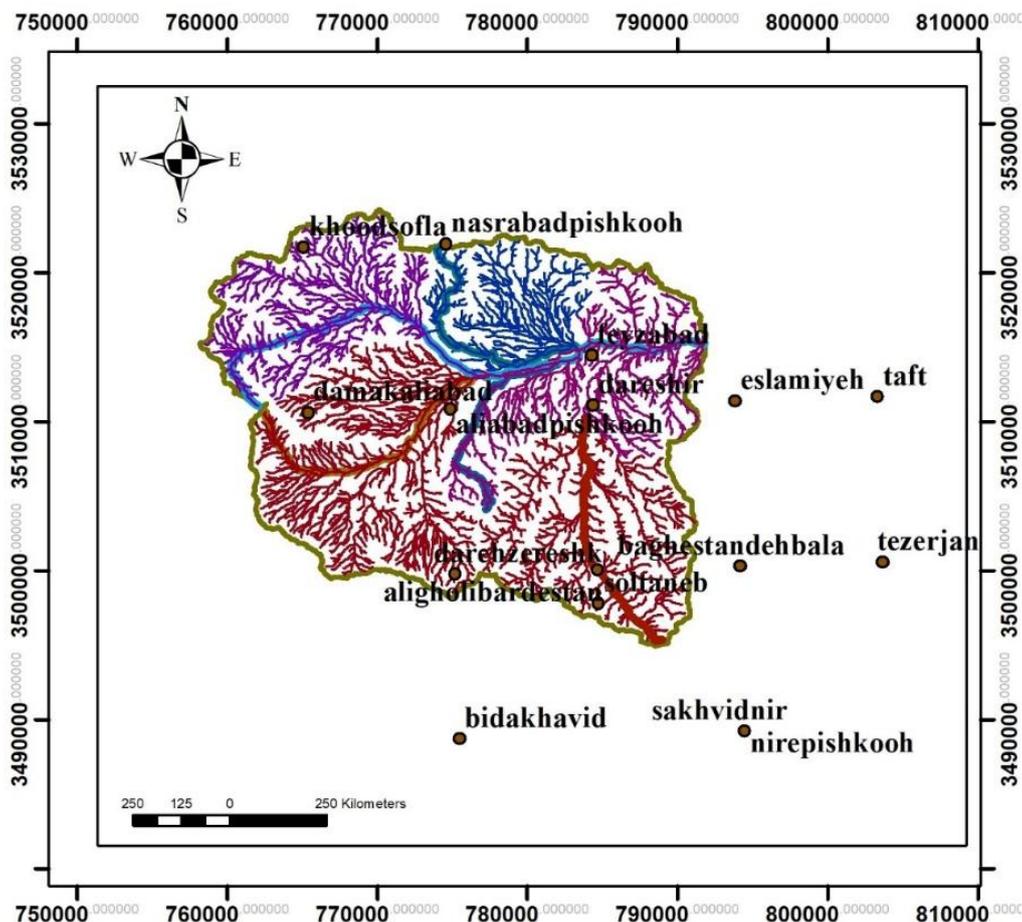
در پژوهش حاضر، سعی می شود میزان دقت مدل های داده-محور هوش مصنوعی، جهت پیش بینی مقدار دبی در ایستگاه های مختلف حوضه پیشکوه به منظور تعیین مدل بهینه برای هر ایستگاه، بررسی و عملکرد هر مدل در بخش های مختلف حوضه تعیین شود. بدین منظور برای انتخاب ایستگاه های موجود در سطح حوضه تنها ایستگاه هایی انتخاب شدند که یا بر روی شاخه اصلی رودخانه حوضه موجود بودند یا بر روی شاخه های فرعی ارتفاعات بالادست

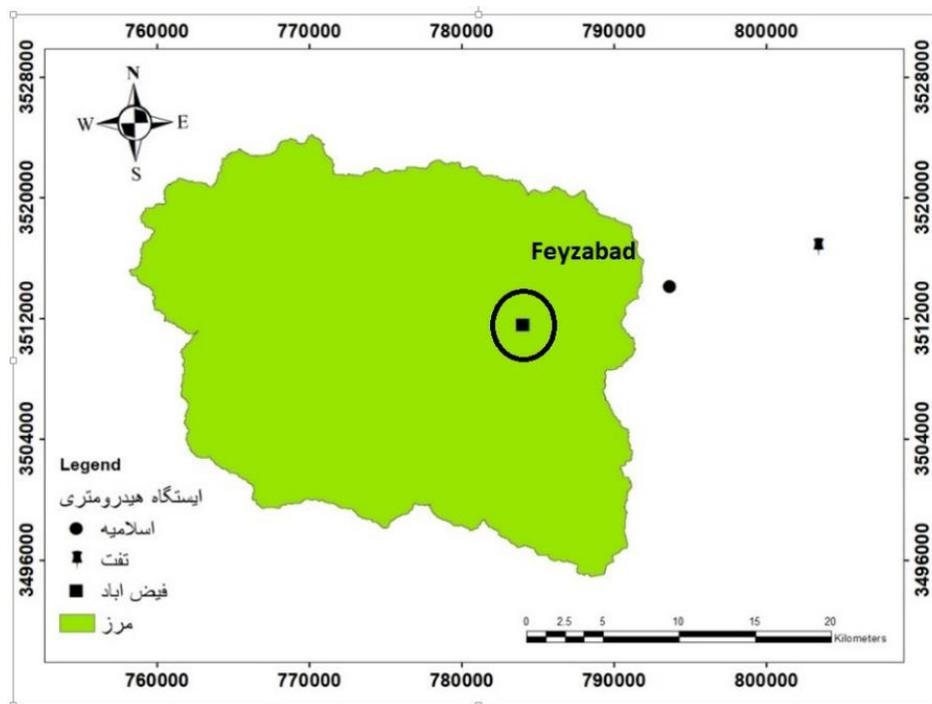
جدول (۱): موقعیت و مشخصات ایستگاه‌های انتخاب شده در محدوده حوضه پیشکوه

ردیف	طول جغرافیایی	عرض جغرافیایی	نام ایستگاه	ارتفاع	سال تأسیس	سازمان	نوع ایستگاه
۱	۵۳/۸	۳۱/۸	خود سفلی	۲۵۶۴	۱۳۷۶	وزارت نیرو	بارانسنجی
۲	۵۳/۸	۳۱/۷	دامک علی آباد	۲۲۹۵	۱۳۶۸	وزارت نیرو	بارانسنجی
۳	۵۳/۹	۳۱/۶	دره زرشک	۲۴۴۱	۱۳۷۵	هواشناسی	بارانسنجی
۴	۵۴	۳۱/۷	دره شیر	۲۲۹۶	۱۳۷۵	هواشناسی	بارانسنجی
۵	۵۴	۲۴/۶	سلطانپ	۲۵۶۲	۱۳۷۵	هواشناسی	بارانسنجی
۶	۵۳/۹	۳۱/۷	علی آباد پیشکوه	۲۱۲۳	۱۳۷۹	وزارت نیرو	تبخیرسنجی
۷	۵۴	۳۱/۶	علیقلی بردستان	۲۶۶۷	۱۳۶۸	وزارت نیرو	بارانسنجی
۸	۵۴	۳۱/۷	فیض آباد	۱۹۵۳	۱۳۷۰	وزارت نیرو	بارانسنجی
۹	۵۳/۹	۳۱/۸	نصر آباد پیشکوه	۲۲۷۸	۱۳۸۳	هواشناسی	اقلیم‌شناسی

جدول (۲): موقعیت و مشخصات ایستگاه هیدرومتری واقع در حوضه پیشکوه

ردیف	کد ایستگاه	نام ایستگاه	نام رودخانه	طول جغرافیایی	عرض جغرافیایی	سال تاسی	ارتفاع به متر	امکانات ایستگاه	وضعیت ایستگاه
۳	۴۶۰۵۵	فیض آباد	سانیچ	۵۳-۵۹-۴۸	۳۱-۴۲-۱۶	۱۳۷۰	۲۰۰۰	پل تلفریک لمینگراف اشل	فعال





شکل (۲) موقعیت ایستگاه‌های هواشناسی و هیدرومتری در منطقه مطالعاتی

ایستگاه هیدرومتری برای بررسی خروجی‌های مدل که همان پیش بینی سیلاب می باشد، استفاده شد. اصولاً وارد کردن داده‌ها به صورت خام بر میزان سرعت و دقت شبکه موثر بوده و موجب کاهش آنها می‌شود. نرمال سازی داده‌ها روشی است که برای جلوگیری از بروز چنین شرایطی، یکسان سازی ارزش داده‌ها برای شبکه و هماهنگی بین برد تابع محرک و خروجی انجام می‌گیرد. هدف از نرمال سازی، تغییر مقیاس داده‌ها برای محدود کردن مقادیر آنها در یک بازه خاص می باشد. بنابراین بهتر است کلیه داده‌های ورودی قبل از معرفی به شبکه نرمال شوند. این عمل به خصوص زمانی که دامنه تغییرات ورودی‌ها گسترده باشد، کمک قابل توجهی به آموزش بهتر و سریع تر مدل می‌کند. بنابراین در این پژوهش داده‌های ورودی با استفاده از فرمول ۱ در محدوده +۱ و -۱ نرمال می‌شوند. (کومار، ۲۰۱۹)

$$X_{normal} = \left[\frac{X_0 - X_{min}}{X_{max} - X_{min}} \right] \times 2 - 1 \quad (1)$$

جهت تحقق این مهم اقدامات زیر انجام شد:

جمع آوری و آماده سازی داده‌ها: بدین منظور در ابتدا داده‌های ایستگاه‌های هواشناسی و ایستگاه‌های هیدرومتری حوزه مورد مطالعه از سازمان‌های مربوطه تهیه شده و سپس ایستگاه‌های دارای آمار بالای ۲۵ سال و همچنین موقعیت قرارگیری روی شاخه‌های اصلی و فرعی رودخانه به منظور بررسی دقت مدل‌ها، انتخاب شدند. می‌توان گفت هر چه تعداد داده‌های در دسترس بیشتر باشد دقت مدل‌های داده‌مبنا بیشتر است. پس از انجام مقدمات لازم، شامل آزمون همگنی، حذف داده‌های پرت و بازسازی آمار ناقص بر روی کلیه داده‌های موجود، تمامی آمار ایستگاه‌های مورد استفاده، هم‌پایه شده و مورد استفاده قرار گرفتند. به منظور یکسان سازی داده‌ها از تاریخ ۱۹۹۱ تا ۲۰۲۴ برای تمامی ایستگاه‌ها انتخاب گردید. در این پژوهش از داده‌های دبی و بارش (پارامتر موثر بر سیلاب) به عنوان ورودی مدل‌ها و از داده‌های دبی



از رفتار داده‌ها حاصل شده و متغیرهای کم‌اهمیت حذف و پارامترهای کلیدی به‌صورت هدفمند انتخاب شوند. برتری ANOVA نسبت به روش‌های کلاسیک در توانایی بیشتر آن برای ارزیابی معناداری و اثرگذاری متغیرهاست. در نهایت، روش SHAP به‌عنوان یکی از جدیدترین و معتبرترین رویکردها در تحلیل حساسیت و تفسیر مدل‌های یادگیری ماشین، این قابلیت را دارد که اهمیت نسبی متغیرها و اثرات تعاملی آن‌ها را شناسایی کند. بر خلاف روش‌های سنتی که صرفاً بر همبستگی تکیه دارند، SHAP دارای پشتوانه نظری (بازی‌های مشارکتی Shapley) بوده و نتایج آن از تفسیرپذیری بالایی برخوردار است. در مقابل، بسیاری از روش‌های سنتی مانند PMML، PCA یا روش‌های ساده رتبه‌بندی ویژگی‌ها توانایی تحلیل روابط غیرخطی بین متغیرها را ندارند. برخی روش‌های دیگر نظیر روش‌های مبتنی بر الگوریتم‌های ژنتیک نیز با وجود دقت مناسب، بسیار زمان‌بر بوده و در داده‌های هیدرولوژیک که ذاتاً noisy و نوسانی هستند، پایداری کافی ندارند. همچنین مدل‌هایی مانند Random Forest و SVM اگرچه نتایج قابل قبولی ارائه می‌دهند، اما از نظر سرعت و تفسیرپذیری در سطح XGBoost در ترکیب با SHAP قرار ندارند. در مورد شبکه‌های عصبی نظیر ANN و LSTM نیز باید اشاره کرد که این روش‌ها به‌رغم توانایی مدل‌سازی، در تحلیل حساسیت و قابلیت تفسیر با محدودیت‌های جدی مواجه بوده و نتایج آنها از نظر احتمالاتی پایدار نیست. در نتیجه استفاده از این سه روش در پژوهش سهم هر متغیر را در خروجی مدل نشان می‌دهد و برای تعیین بهترین ترکیبات ورودی بکار گرفته می‌شود. این سه روش برای انتخاب ورودی‌ها در مطالعات هیدرولوژیکی بسیار کاربرد دارند و هدف اصلی آنها توسعه مدلی است که از داده‌های موثر ورودی با تاخیر زمانی به منظور پیش‌بینی زمان حال استفاده می‌کند.

بررسی دقت هر مدل با اعمال ورودی‌های موثر:

پس از مشخص شدن ترکیبات ورودی‌های موثر، که برای حوضه مورد مطالعه طبق نتایج به دست آمده دبی جریان یک روز قبل و دو روز قبل همچنین بارش

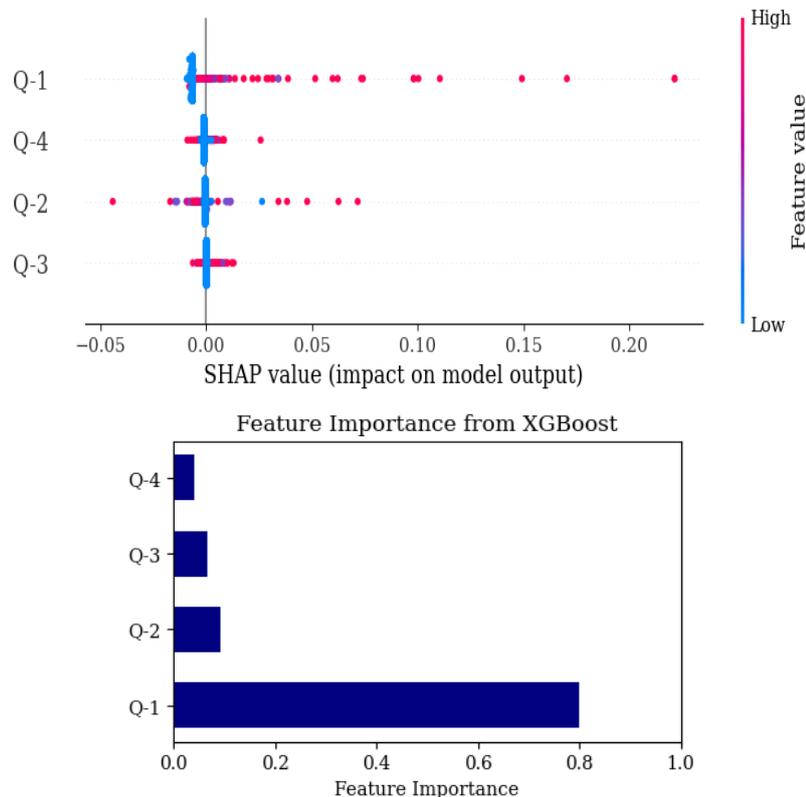
۲صحت سنجی، تصحیح و تکمیل داده‌های هواشناسی و آبسنجی و انتخاب پارامترهای موثر:

از آنجا که اطلاعات اساسی مربوط به سیستمی که مدل‌سازی می‌شود توسط داده‌های ورودی مشخص می‌شوند و در واقع داده‌های ورودی مهمترین پارامتر در تعیین ویژگی‌های یک سیستم می‌باشند، بنابراین از مسائل مهم در استفاده از روش‌های یادگیری ماشین و داده‌مبنا، انتخاب پارامترهای ورودی بهینه است. روش‌های مختلفی برای شناسایی و انجام آزمون‌های آماری جهت کنترل کیفی داده‌ها استفاده می‌شود که از جمله آنها می‌توان روش‌های گاما، PMI، SHAPLY, XGboost, PACF ANOVA, ACF و... را نام برد. در این پژوهش از الگوریتم XGBoost که یکی از پرکاربردترین و قدرتمندترین الگوریتم‌های یادگیری ماشین در مسائل طبقه‌بندی (Classification) و رگرسیون (Regression) است که دلیل اصلی محبوبیت آن، سرعت بالا و دقت زیاد در پیش‌بینی‌ها است، همچنین «تحلیل واریانس» (Analysis of Variance) با نام مخفف ANOVA به‌عنوان یکی از ابزارهای پرکاربرد در آزمون فرض و تحقیقات آماری. و نیز روش SHAP (Shapley Additive Explanations) که یکی از پیشرفته‌ترین روش‌ها برای تحلیل حساسیت در مدل‌های پیچیده یادگیری ماشین است استفاده شد. به‌طور کلی، انتخاب الگوریتم‌ها در این پژوهش بر مبنای قابلیت علمی و کارایی عملی آنها صورت گرفته است. نخست، الگوریتم XGBoost طی سال‌های اخیر در حوزه هیدرولوژی و مدل‌سازی محیطی به‌عنوان یکی از معتبرترین روش‌ها مطرح شده است؛ زیرا توانایی بالایی در مدل‌سازی روابط غیرخطی پیچیده بین متغیرهای مؤثر بر دبی رودخانه و خروجی‌ها داشته و امکان مدل‌سازی سریع، دقیق و پایدار را فراهم می‌کند. همچنین از آنجا که خروجی این مدل قابلیت تفسیر و تحلیل دارد، به‌ویژه در ترکیب با روش SHAP، استفاده از آن بسیار توصیه می‌شود. در مرحله دوم، تحلیل واریانس (ANOVA) به‌عنوان یک روش آماری معتبر، این امکان را فراهم می‌آورد که پیش از فرآیند مدل‌سازی، شناخت دقیقی

هر مدل تعیین می‌شود و در واقع مدل‌ها آموزش داده می‌شوند.

جهت انجام این پروسه ابتدا داده‌های دبی (Q) برای ایستگاه هیدرومتری فیض آباد با تاخیر زمانی یک روز قبل (Q-1)، دو روز قبل (Q-2)، سه روز قبل (Q-3)، و حتی چهار روز قبل (Q-4)، به مدل‌ها داده شد و طبق نتایجی که هر سه مدل ارائه دادند موثرترین پارامتر ورودی دبی جریان با تاخیر زمانی یک روز قبل (Q-1) و دو روز قبل (Q-2)، تشخیص داده شد که نتایج در شکل ۳ آورده شده است.

```
Feature: Q-1, F-value: 247.4280, p-value: 0.0000
Feature: Q-2, F-value: 94.3715, p-value: 0.0000
Feature: Q-3, F-value: 82.5949, p-value: 0.0000
Feature: Q-4, F-value: 59.4929, p-value: 0.0000
Selected Features based on ANOVA F-test: ['Q-1', 'Q-2', 'Q-3', 'Q-4']
```



شکل (۳): نتایج حاصل از سه مدل XGboost, SHAP و ANOVA جهت تعیین پارامترهای موثر بر روی دبی جریان در ایستگاه هیدرومتری فیض آباد

بارش‌های روزانه هر ایستگاه هواشناسی به طور مجزا با دبی جریان همان روز با تاخیرهای زمانی یک روز

یک روز قبل و دو روز قبل تشخیص داده شد، به ازای هر ورودی، میزان دقت هر مدل را (با مقایسه‌ی مقادیر بدست آمده از مدل و مقادیر مشاهده‌ای) محاسبه می‌کنیم. در این مرحله از عملگرهای پیش فرض هر مدل استفاده می‌شود.

آموزش مدل‌ها: پس از مشخص شدن ورودی‌های موثر برای هر مدل، به بررسی ساختارهای مختلف موجود برای هر مدل پرداخته می‌شود. هر مدل آموزش داده شده و در نهایت با بررسی شاخص‌های عملکرد، بهترین ساختار برای

در مرحله بعد با توجه به دبی جریان ایستگاه هیدرومتری فیض آباد (Q) به عنوان پارامتر اصلی،



(اولا، ۲۰۱۸). این مدل نوع خاصی از شبکه عصبی بازگشتی بوده که بجای توابع ساده، از توابع پیچیده و ترکیبی به منظور تنظیم و تقویت حافظه کوتاه مدت استفاده می کند و قابلیت یادگیری وابستگی های بلندمدت را علاوه بر وابستگی های کوتاه مدت دارد. هدف این نوع شبکه، پردازش داده هایی است که نیاز است وابستگی های بلندمدت آنها در مدل در نظر گرفته شود. این نوع از شبکه عصبی می تواند در پیش بینی داده های سری زمانی استفاده شود. با توجه به نوع مسئله و ویژگی های خاص هر سری زمانی، می توان یکی از انواع مدل های LSTM را استفاده نمود. مدل های LSTM می توانند به صورت تک متغیره (Univariate) و چند متغیره (Multivariate) بر اساس تعداد سری زمانی ورودی تقسیم بندی شوند. در توسعه مدل، ابتدا مدل پیش بینی یک گام جلوتر در فرآیند توسعه مدل به دست می آید. سپس یک راهبرد بازگشتی در مدل های آموزش دیده اتخاذ می شود تا بتوان پیش بینی چندمرحله ای را به دست آورد. مطابق شکل ۴، شبکه های LSTM نیز شبیه ساختار استاندارد شبکه های بازگشتی دارای زنجیره ای از سلول ها است، با این تفاوت که ساختار هر سلول بجای یک لایه دارای چهار لایه مرتبط و متعادل است.

قبل (P-1)، دو روز قبل (P-2)، سه روز قبل (P-3)، و حتی چهار روز قبل (P-4)، به مدل ها داده شد و طبق نتایجی که هر سه مدل ارائه دادند موثرترین پارامتر ورودی بارش نیز با تاخیر زمانی یک روز قبل (P-1) و برای اطمینان بیشتر دو روز قبل (P-2)، تشخیص داده شد که البته این تحلیل های آماری برای تک تک ایستگاه ها نیز انجام شد و نتیجه آنها نیز مشابه همین ایستگاه هیرومتری نشان دهنده تاثیر بارش در هر نقطه با تاخیر زمانی یک و دو روزه بود.

توسعه و پیاده سازی مدل های پیش

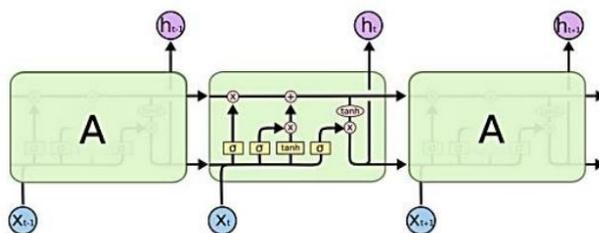
بینی جریان

در مرحله اول از مدل LSTM با استفاده از رویکرد مدلسازی داده محور مبتنی بر یادگیری عمیق جهت توسعه مدل های پیش بینی جریان استفاده شد.

شبکه عصبی حافظه کوتاه و بلند مدت

(LSTM)

یکی از مدل های محبوب در شبکه های بازگشتی، مدل LSTM است. این نوع شبکه برای اولین بار در سال ۱۹۹۷ میلادی توسط هوخرایتر و اشمیدیهوهر معرفی شد. طراحی شبکه های LSTM به منظور حل مشکلات ناشی از وابستگی بلندمدت داده ها انجام شد



شکل (۴): ساختار شبکه های بازگشتی (LSTM) (ساختار تکرار شونده و چهار لایه ای (Olah ۲۰۱۵)).

۱ تا ۴ ماه به عنوان ورودی استفاده می شود که این موضوع در ساختار مدل های LSTM مدنظر قرار گرفته است و از نقاط قوت آن می باشد. لازم به ذکر است که به دلیل پتانسیل زیاد مدل LSTM در مواجه شدن با تعداد زیادی از متغیرهای ورودی (مسائل دارای ابعاد بالا)، نیازی به پیش پردازش داده های ورودی قبل از مدلسازی با الگوریتم جنگل تصادفی جهت انتخاب مناسبترین پیش بینی کننده ها

تشکیل پنجره های متحرک (Sliding window)

منطق و اساس پنجره های متحرک به این صورت است که برای پیش بینی گام n ام از پیش بینی های گام های زمان قبل ($n-1$ و $n-2$ و ...) استفاده می شود. به عنوان مثال برای پیش بینی جریان با افق پیش بینی ۵ ماه آینده از تمامی جریان های پیش بینی شده از افق

دوره (Epoch) آموزش دید که نرخ یادگیری اولیه ۰.۰۱۲ است و بعد از ۵۰ دوره، نرخ یادگیری ۱۰ برابر کاهش می‌یابد و آموزش با دسته‌های کوچک (batch size = 1) انجام می‌شود.

پس از ساخت و آموزش شبکه معماری مدل LSTM در ۵ لایه نرون (NEROUN)، در نهایت پیش بینی دبی با شبکه آموزش دیده و شاخص های عملکرد محاسبه گردید و نتایج در قالب شبکه و نمودار و جدول ارائه شد.

تجربه و تحلیل نتایج

در مدل سازی پدیده‌های هیدرولوژیکی مانند سیلاب یا افزایش ناگهانی دبی، استفاده از الگوریتم‌های یادگیری عمیق (Deep Learning) به دلیل توانایی یادگیری روابط غیرخطی و پیچیده بین متغیرهای ورودی (مانند بارش، دبی، خاک، پوشش گیاهی، شیب، ...) موضوع اصلی در کاربرد روش‌های مبتنی بر شبکه‌های عصبی عمیق در پیش‌بینی سطح آب یا وقوع سیلاب چالش عدم توازن داده‌هاست که جهت رفع این مشکل، یکی از راهکارهای مؤثر کلاسه‌بندی یا طبقه‌بندی داده‌ها پیش از آموزش مدل است. با تفکیک داده‌ها به بازه‌های مشخص (مثلاً: خشک، نرمال، بارش متوسط، و سیلابی)، می‌توان مدل را به گونه‌ای آموزش داد که حساسیت آن نسبت به محدوده‌های بحرانی افزایش یابد. این روش موجب می‌شود شبکه یادگیری عمیق بتواند الگوهای دینامیکی هر طبقه را به صورت مجزا استخراج کند و در نتیجه، دقت پیش‌بینی در شرایط سیلابی به شکل محسوسی بهبود یابد. به عبارت دیگر، کلاسه‌بندی داده‌ها نوعی بازتعادل آماری (Statistical Rebalancing) در مجموعه داده ایجاد می‌کند که باعث می‌شود مدل در فرآیند یادگیری، توجه بیشتری به داده‌های با اهمیت بالا ولی تعداد کم نشان دهد. بنابراین، بدون انجام این مرحله پیش‌پردازشی، شبیه‌سازی سیلاب با استفاده از شبکه‌های یادگیری عمیق معمولاً منجر به نتایجی می‌شود که در بازه‌های نرمال قابل قبول ولی در رخدادهای حدی (Extreme)

نیست. لازم به ذکر است که تمامی مراحل مربوط به پیش‌پردازش و ساخت مدل در محیط برنامه‌نویسی متلب انجام شد.

شاخص‌های ارزیابی توسعه مدل‌ها

دقت عملکرد مدل‌های پیش‌بینی با شاخص‌های ارزیابی ضریب همبستگی (R) (رابطه ۲)، مربع میانگین ریشه خطا (RMSE-Root) (رابطه ۳)، ضریب نش-ساتکلیف (NSE) (Suftlife-Nash) (رابطه ۴)، و میانگین خطای مطلق (MAE) (رابطه ۵)، مورد بررسی قرار گرفت. هر چه مقادیر R و NSE به ۱ نزدیکتر باشد و هر چه مقادیر RMSE و MAE به صفر نزدیکتر باشد دقت مدل‌های پیش‌بینی بهتر است.

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(F_i - \bar{F})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (F_i - \bar{F})^2}} \quad \text{رابطه ۲}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (F_i - O_i)^2}{N}} \quad \text{رابطه ۳}$$

$$NSE = \frac{\sum_{i=1}^N (O_i - F_i)^2}{\sum_{i=1}^N (O_i - \bar{F})^2} \quad \text{رابطه ۴}$$

$$MAE = \sqrt{\sum_{i=1}^N |F_i - O_i|} \quad \text{رابطه ۵}$$

در رابطه ۲ تا ۵، F_i : مقدار پیش‌بینی شده متغیر جریان، O_i : مقدار مشاهداتی متناظر با آن و N : تعداد سال‌های دارای آمار می‌باشد.

محیط توسعه کدهای کامپیوتری در بخش

مدلسازی

در این بخش کد تهیه شده در چندبخش مختلف در محیط متلب نوشته شد به این صورت که ابتدا محیط پاک‌سازی و سپس وارد کردن داده‌ها صورت گرفت، در بخش بعد داده‌ها بین صفر و ۱ نرمال سازی و سپس ورودی‌ها و خروجی‌ها آماده‌سازی شدند و به دو دسته آموزش و آزمون تقسیم بندی گردیدند که در این تحقیق ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای آزمون در نظر گرفته شدند. در این از بهینه‌ساز Adam استفاده شد و شبکه در ۷۰

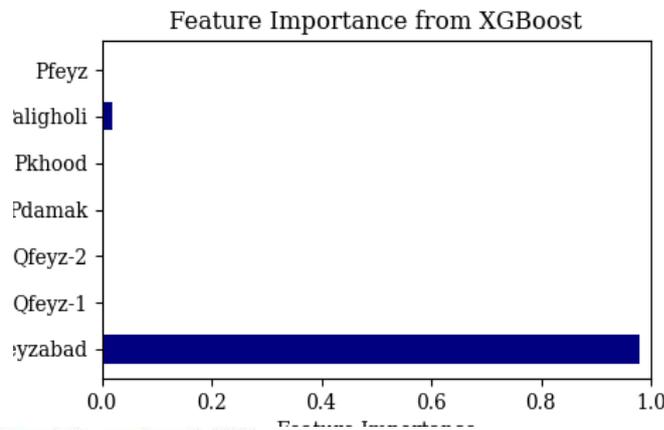
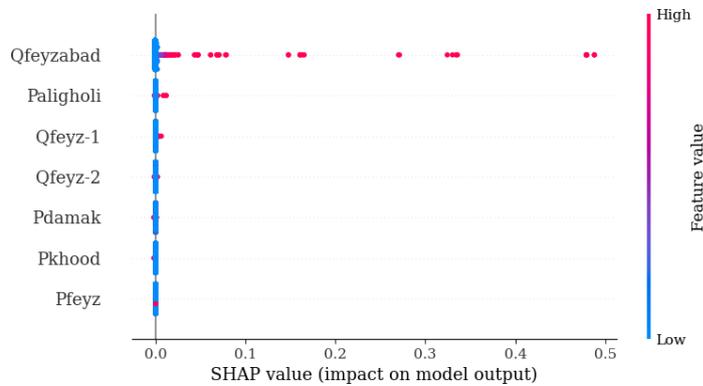


در مرحله بعد بارش های آستانه ای را برای حوضه در نظر گرفتیم که در اینجا بارش های کمتر از ۱۳ میلی متر در هر ایستگاه که دبی متناظر آن نیز صفر بودند نیز حذف گردیدند، و در نهایت همبستگی میان دبی ایستگاه هیدرومتری فیض آباد با داده های بارش ایستگاههای حوضه بررسی شد و تنها ۴ ایستگاه از ۹ ایستگاه حوضه که بارش آن در دبی ایستگاه هیدرومتری تاثیر داشت انتخاب گردیدند.

در واقع یافته های آماری که نتایج آن در شکل های قبل یعنی ۳ و ۴ آورده شده است، مبنایی برای انتخاب ورودی های مناسب در مدل هوش مصنوعی جهت پیش بینی دبی جریان فراهم کرد. اما آنچه از اهمیت بالایی برخوردار است با شناسایی الگوهای موثر، ورودی های کلیدی مدل، تعیین و دقت پیش بینی ها افزایش یافت. برای مثال سناریوهای مختلفی برای تک تک ایستگاه ها تعریف شد و در نهایت سناریویی که مورد استقبال قرار گرفت ترکیبی از دبی ایستگاه هیدرومتری ما به عنوان تابع هدف و دبی تاخیر زمانی یک روز و دو روز قبل و بارش های چهار ایستگاه موثر بر دبی آن نقطه به عنوان ورودی مدل در نظر گرفته شد که نتایج این سناریو در جداول ۳ و ۴ آورده شده است. همچنین جهت اطمینان بیشتر، مجدد تحلیل های آماری روی سناریوها انجام شد و تقریباً تمام تحلیل ها نشان دهنده تاثیر فراوان بارش ایستگاه "علیقلی" و سپس بارش ایستگاه "فیض آباد" و از همه مهمتر دبی همان روز ایستگاه هیدرومتری فیض آباد با تاخیر زمانی یک روز و دو روز بود، که نتایج تحلیل ها به علت کمبود فضا در یک تحلی خلاصه و در شکل ۵ آورده شده است.

Events فاقد دقت کافی هستند. وقتی مجموعه داده عمدتاً شامل نمونه هایی از حالت های عادی یا کم شدت است (مثلاً بارش کم، جریان کم یا تقریباً صفر) و بخشی اندک به رخدادهای شدید تعلق دارد، الگوریتم یادگیری عمیق در فرایند آموزش بیشتر «الگوی غالب» را فرا می گیرد و در نتیجه حساسیت آن به نمونه های نادر (یعنی رخدادهای سیلابی) کاهش می یابد. به عبارت دیگر، تابع هزینه (Loss Function) و فرآیند بهینه سازی عمده تمرکز خود را بر داده های با فراوانی بالا می گذارند، در حالی که نمونه های بسیار مهم ولی کم تعداد (سیلاب ها) یا شدیده ها به مقدار کافی وزن نمی شوند. مطالعات اخیر نشان داده اند که این مسئله می تواند به کاهش دقت پیش بینی در بخش رخدادهای حدی (extreme events) منجر شود، حتی اگر عملکرد کلی مدل نسبتاً خوب به نظر برسد. به عبارت دیگر، مدل ممکن است در پیش بینی میانگین عملکرد خوبی داشته باشد، اما در پیش بینی «وقوع سیلاب شدید» یا مقادیر بزرگ دبی، عملکرد ضعیفی از خود نشان دهد (Lennart Schmidt, 2020).

به منظور رفع این چالش، یکی از راهکارهای مؤثر، انجام مرحله پیش پردازش داده ها با هدف "کلاسه بندی" (Classification) یا تقسیم بندی داده ها به بازه های موضوعی مشخص (مثلاً «خشک»، «بارش متوسط»، «بارش شدید / سیلابی») قبل از اعمال الگوریتم یادگیری عمیق است. در مرحله اول تمام دبی های صفر با بارش صفر متناظر با آن تاریخ؛ در ایستگاه های حوضه حذف شدند که با توجه به اینکه رودخانه دائمی در حوضه وجود ندارد و تمامی رودخانه های اصلی و فرعی فصلی هستند مقدار این داده ها قابل توجه بود.



Feature: Qfeyzabad, F-value: inf, p-value: 0.0000
 Feature: Qfeyz-1, F-value: 295.9218, p-value: 0.0000
 Feature: Qfeyz-2, F-value: 147.3105, p-value: 0.0000
 Feature: Pdamak, F-value: 14.3646, p-value: 0.0000
 Feature: Pkhood, F-value: 18.9670, p-value: 0.0000
 Feature: Paligholi, F-value: 10.4425, p-value: 0.0000
 Feature: Pfeyz, F-value: 11.4187, p-value: 0.0000
 Selected Features based on ANOVA F-test: ['Qfeyzabad', 'Qfeyz-1', 'Qfeyz-2', 'Pdamak', 'Pkhood', 'Paligholi', 'Pfeyz']
 Final Selected Features: ['Pkhood', 'Pfeyz', 'Paligholi', 'Qfeyz-1', 'Qfeyzabad', 'Pdamak', 'Qfeyz-2']

شکل (۵): نتایج حساسیت سنجی مدل‌های آماری XGboost, SHAP و ANOVA برای تعیین پارامترهای موثر در ترکیب ورودی‌ها

جدول (۳) - سناریوهای طراحی شده برای افزایش دقت پیش بینی جریان در انتخاب ورودی‌های موثر

Scenarion	Input structure	Output
M0	Q(t), Q(t-1), P1(t), P1(t-1), P2(t), P2(t-1), P3(t), P3(t-1), P4(t), P4(t-1)	Q(t)
M1	Q(t), P1(t), P2(t), P3(t), P4(t)	Q(t)
M2	Q(t), Q(t-1), P1(t), P2(t), P3(t), P4(t)	Q(t)
M3	Q(t), Q(t-1), Q(t-2), P1(t), P2(t), P3(t), P4(t)	Q(t)
M4	Q(t), Q(t-1), Q(t-2), P1(t), P1(t-1), P2(t), P2(t-1), P3(t), P3(t-1), P4(t), P4(t-1)	Q(t)
M5	Q(t), Q(t-1), Q(t-2), P3(t), P3(t-1), P4(t), P4(t-1)	Q(t)
M6	Q(t), Q(t-1), Q(t-2), P3(t)	Q(t)
M7	Q(t), Q(t-1), Q(t-2), P3(t), P4(t)	Q(t)

جدول (۴): نتایج آموزش مدل برای سناریوهای تعریف شده

M0 Train Set Metrics	M0 Test Set Metrics	M1 Train Set Metrics	M1 Test Set Metrics	M2 Train Set Metrics	M2 Test Set Metrics	M3 Train Set Metrics	M3 Test Set Metrics
MSE: 0.00024047	MSE: 0.00046593	MSE: 0.0004207	MSE: 0.00070516	MSE: 0.00025168	MSE: 0.00043948	MSE: 0.00034206	MSE: 0.00026012
RMSE: 0.015507	RMSE: 0.021585	RMSE: 0.020511	RMSE: 0.026555	RMSE: 0.015865	RMSE: 0.020964	RMSE: 0.018495	RMSE: 0.016128
MAE: 0.0033621	MAE: 0.0037648	MAE: 0.0057905	MAE: 0.0061924	MAE: 0.0040899	MAE: 0.004415	MAE: 0.0044077	MAE: 0.0043437
NSE: 0.58014	NSE: 0.46637	NSE: 0.23457	NSE: 0.24122	NSE: 0.56057	NSE: 0.49667	NSE: 0.50496	NSE: 0.56284
M4 Train Set Metrics	M4 Test Set Metrics	M5 Train Set Metrics	M5 Test Set Metrics	M6 Train Set Metrics	M6 Test Set Metrics	M7 Train Set Metrics	M7 Test Set Metrics
MSE: 0.00034975	MSE: 0.0002827	MSE: 0.0002712	MSE: 0.00049962	MSE: 0.00038442	MSE: 0.00030752	MSE: 0.00032883	MSE: 0.0002239
RMSE: 0.018702	RMSE: 0.016814	RMSE: 0.016468	RMSE: 0.022352	RMSE: 0.019607	RMSE: 0.017536	RMSE: 0.018134	RMSE: 0.014963
MAE: 0.0045961	MAE: 0.0046252	MAE: 0.0043518	MAE: 0.0047333	MAE: 0.0035905	MAE: 0.0035632	MAE: 0.0038801	MAE: 0.0038572
NSE: 0.49383	NSE: 0.5249	NSE: 0.52649	NSE: 0.42779	NSE: 0.44365	NSE: 0.48318	NSE: 0.5241	NSE: 0.62372

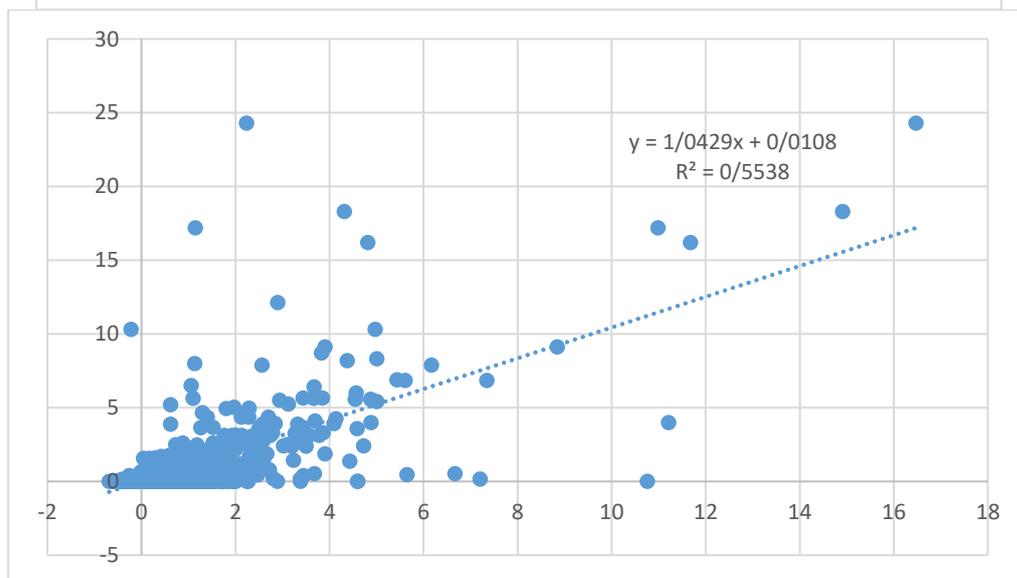
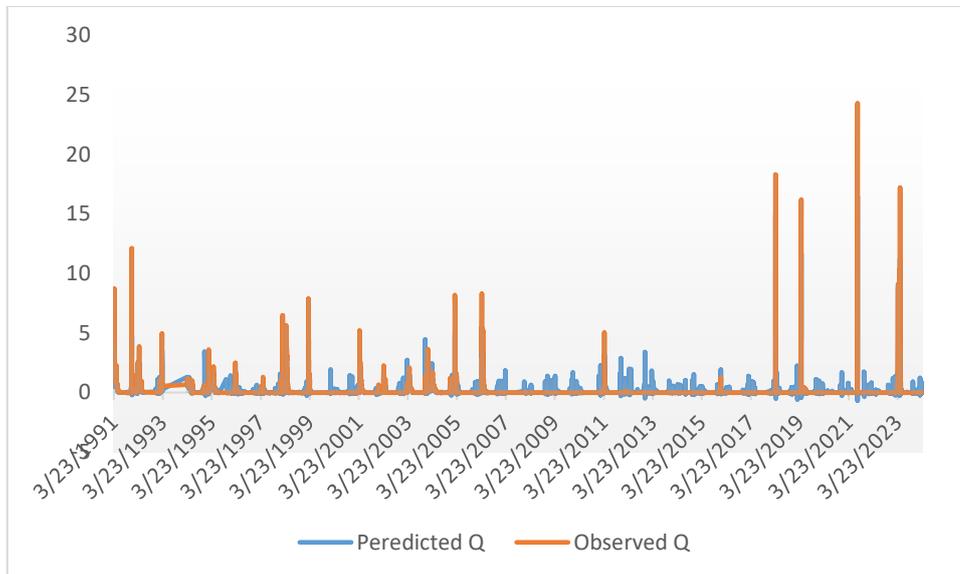
(نزدیک صفر) مدل تقریباً دقیق است و در کل مدل نسبت به مقدار واقعی رفتار محافظه کارانه دارد (دبی پیش‌بینی شده همیشه کمتر از دبی مشاهده شده برآورد می‌گردد). روند کلی جریان آب از ۱۹۹۱ تا ۲۰۲۴ کاهش یافته است و مقدار حداکثر دبی واقعی حدود ۳۰٪ بالاتر از پیش‌بینی است.

نتایج در تمامی سناریوها معرف این موضوع بود که تخمین این مدل در دبی‌های اوج با چالش مواجه بوده و تمایل دارد دبی‌های اوج را با توجه به مقادیر وسیع صفر در داده‌ها، بسیار کم تخمین بزند به عبارتی دیگر، دقت مدل در مقادیر بالا کمتر است ولی در مقدارهای نزدیک صفر خیلی خوب عمل می‌کند، میانگین خطاها کوچک است، پس پیش‌بینی‌ها به داده واقعی نزدیک‌اند. مقدار $R^2=0.55$ نشان می‌دهد مدل قابل استفاده است اما بهینه نیست. و این موضوع نشان می‌دهد که هرچند مدل‌های شبکه عصبی ابزار قدرتمندی برای مدل‌سازی هیدرولوژیکی هستند ولی بسیار وابسته به داده‌های دقیق و منظم و همچنین نیازمند به آمارهای با سری‌های زمانی طولانی مدت هستند. (شکل ۶)

همانطور که از مقایسه نتایج سناریوها طبق جداول بالا و همچنین نتیجه تحلیل آماری مدل‌های XGboost، SHAP و ANOVA برآورد می‌شود، به راحتی قابل تشخیص است که بهترین سناریو همان سناریو M7 بوده و موثرترین پارامترهای ورودی بارش ایستگاه "علیقلی بردستان" و بارش ایستگاه "فیض آباد"، همچنین مقدار دبی موجود در رودخانه به همراه تاخیر زمانی یک روزه و دو روز می‌باشد.

نتایج پیش‌بینی دبی جریان

پس از اینکه به کمک ساختار بهینه، موثرترین سناریو تعیین شد، پیش‌بینی دبی جریان توسط مدل LSTM جهت داده‌های سری زمانی از سال ۱۹۹۱ تا ۲۰۲۴، برای یک روز آینده انجام شد، و آنچه از روند پیش‌بینی حاصل می‌توان دریافت این است که مقادیر از ابتدای سال ۱۹۹۱ بسیار بالا هستند (بیش از ۲ مورد)، اما در بازه پایانی (سال‌های ۲۰۲۳-۲۰۲۴) تقریباً به صفر می‌رسند که بیانگر کاهش تدریجی جریان در بازه زمانی است. چشمگیرترین نکات در اختلاف بین Predicted و Observed در کل داده این است که در مقادیر بالای جریان (۲ تا ۲.۶) مدل خطای ۲۰ تا ۴۰ درصد دارد ولی در مقادیر پایین



شکل (۶): سری زمانی داده های مشاهده ای و پیش بینی شده دبی جریان توسط مدل LSTM در سناریو M7

کوچک تر از RMSE نشان می دهد چند مقادیر دور افتاده (Outlier) داریم. $MSE = 0.175$ میانگینی از مربع خطاست و به Outlier حساس است. $R^2 = 0.55$ یعنی مدل حدود ۵۵ درصد از تغییرات واقعی را توضیح می دهد و این مقدار بیانگر عملکرد متوسط رو به خوب است. (جدول ۴)

از نتایج تحلیل آماری مدل پیش بینی نسبت به داده های واقعی و ارزیابی شاخص های دقت مدل می توان چنین برآورد کرد که، بین مقدار پیش بینی شده و واقعی به طور متوسط حدود ۰.۴ واحد اختلاف وجود داشته است ($RMSE = 0.418$)، که با توجه به مقادیر کلی (۲ تا ۰)، این مقدار قابل قبول است. ($MAE = 0.083$)، یعنی در حالت میانگین حدود ۰.۰۸ واحد خطا وجود داشته است که مقدار خیلی کم و خوب محسوب می شود، MAE



جدول (۴): شاخص‌های دقت مدل

مقدار	شاخص	مقدار	شاخص
0.0829	MAE (میانگین قدر مطلق خطا)	0.175	MSE (میانگین مربعات خطا)
0.5524	R ² (ضریب تعیین)	0.4183	RMSE (ریشه میانگین مربعات خطا)

نتیجه گیری

بر اساس نتایج ارائه شده (داده‌های سری زمانی ۱۹۹۱-۲۰۲۴، پیش‌بینی یک‌روزه، $R^2 = 0.55$ ، خطای ۲۰٪-۴۰٪ در مقادیر اوج و دقت خوب در مقادیر نزدیک صفر، تمایل مدل به «کم‌تر» پیش‌بینی کردن دبی‌های اوج و کاهش تدریجی روند دبی طی سال‌ها)، می‌توان چنین نتیجه‌گیری کرد که مدل LSTM برای این حوزه ابزار امیدوارکننده‌ای است ولی به‌تنهایی کافی و بهینه نیست، خصوصاً اگر هدف مکانیزم هشدار سیلاب یا تخمین دقیق اوج‌ها باشد. مدل قابلیت مدل‌سازی ساختار کلی سری زمانی و دبی‌های پایین را دارد، اما در تخمین رخداد‌های اوج (پرخطر از منظر سیلاب) ضعف معناداری نشان می‌دهد که باید با اصلاحات و تکمیل داده/مدل جبران شود.

اگر هدف صرفاً «تعیین روند کلی» یا «مدیریت منابع آب در شرایط نرمال» باشد LSTM کاملاً مناسب و کاربردی است، اما اگر هدف «هشدار سیلاب» یا «پیش‌بینی دقیق اوج‌ها» باشد: وضعیت نامطمئن و نیازمند اصلاح است، زیرا زیربرآورد اوج‌ها ریسک‌زا است.

البته پیشنهادهای جهت بهبود عملکرد مدل در این زمینه مطرح می‌شود تا ریسک برآورد کاهش یابد که شامل موارد ذیل است:

- اصلاح تابع هزینه برای تمرکز بر اوج‌ها: وزن‌دهی نمونه‌ها (sample weighting) یا استفاده از تابع هزینه ترکیبی تا خطا در مقادیر اوج وزن بیشتری بگیرد. (به عنوان مثال: وزن‌دهی نمونه‌هایی که دبی < آستانه را دارند یا استفاده از Huber/Quantile loss برای حساسیت به اوج‌ها).

- افزایش نمونه‌های اوج (data augmentation): رویدادهای اوج را بیش‌نمونه‌گیری (Oversampling) کنیم یا از روش‌های شبه SMOTE برای داده‌های سری

زمانی استفاده کنیم تا مدل با نمونه‌های بیشتری از الگوهای اوج روبه‌رو شود.

- دومرحله‌ای کردن مدل (hybrid approach): که مرحله اول، یک مدل طبقه‌بندی (binary) برای تشخیص «احتمال رخداد اوج/سیلاب» است و در مرحله دوم، اگر احتمال بالا بود، از مدل رگرسیونی (ویژه اوج یا مدل فیزیکی-ریاضی مانند HBV دریناچ) استفاده شود. این کار جلوی زیربرآورد سیستماتیک اوج را می‌گیرد.

- افزودن ورودی‌های برون‌زا (exogenous features): بارش پیش‌بینی شده، رطوبت خاک، وضعیت سدها، برف ذوب‌شده و پیشینه چندروزه‌ی جریان می‌تواند توانایی مدل برای شکار اوج را افزایش دهد.

- استفاده از مدل‌های ترکیبی فیزیک‌محور + داده‌محور: استفاده از یک مدل فیزیکی یا شبه‌فیزیکی برای تخمین حداکثر ظرفیت و سپس تصحیح آن با LSTM (physics-informed / hybrid) می‌تواند دقت اوج را به‌طور چشمگیری بهتر کند.

- کالیبراسیون و تصحیح سوگیری (bias correction): می‌توان پس از پیش‌بینی، از روش‌هایی مثل quantile mapping یا multiplicative bias correction برای از بین بردن سوگیری سیستماتیک زیربرآورد استفاده شود.

- مدل‌سازی عدم قطعیت و خروجی‌های کوانتیلی: می‌توان به‌جای پیش‌بینی نقطه‌ای تنها، پیش‌بینی توزیع یا بازه‌ی اطمینان (مثلاً کوانتیل ۹۰٪) ارائه گردد تا ریسک تصمیم‌گیرندگان بهتر منعکس شود.

- اعتبارسنجی متریک‌های مناسب برای هیدرولوژی: می‌توان علاوه بر R² از Probability of Detection, POD, یا False Alarm Rate (FAR) برای ارزیابی اوج‌ها استفاده کرد.

دبی) به گونه‌ای است که بخش بزرگی از سال، دبی بسیار کم یا نزدیک صفر است و تنها بخش‌های محدود زمانی رقم قابل توجهی مشاهده می‌شود. با توجه به این نانرازی، روش‌های ساده‌تر تجربی و استفاده از روابط هیدرولوژیکی و مدل‌های فیزیکی در آموزش مدل‌های یادگیری ماشین برای شبیه‌سازی سیلاب می‌توانند کمک بیشتری به ما کنند.

در یک جمع بندی کلی، LSTM ابزاری توانمند و مناسب برای مدل‌سازی سری‌زمانی جریان آب و روندهای کلی است، اما برای پیش‌بینی دقیق و ایمن اوج‌های سیلاب به تنهایی کفایت نمی‌کند و باید با اصلاحات داده‌ای، تغییر تابع خطا، یا ترکیب با روش‌های دیگر (مدل‌های فیزیکی، طبقه‌بندی اوج، یا مدل‌های کوانتیلی/ensemble) تکمیل و کالیبره شود تا برای هشدار سیلاب قابل اتکا گردد.

در تحقیق حاضر همانطور که از نتایج می‌توان برآورد کرد، ساختار بهینه برای مدل LSTM جهت پیش‌بینی دبی جریان برای هر سناریوی ورودی متفاوت بوده به طوریکه طبق این نتایج توابع با تعداد محدودی نرون در لایه پنهان، عملکرد بهتری نسبت به سایر توابع دارد که طبق این مطالعه مناسبترین ساختار همان M7 می‌باشد، هرچند این ساختار هم با توجه به مواردی که بیان شد خیلی نمی‌تواند رضایت بخش باشد ولی در کل با توجه به اینکه حوضه ما علی‌رغم کلاسه‌بندی داده‌ها و رفع چالش عدم توازن داده‌ها تا حد ممکن، باز هم یک حوضه خشک با رودخانه فصلی محسوب می‌شود، و فور داده‌های صفر و همچنین سری‌های کوتاه زمانی ۳۴ ساله نمی‌تواند پاسخگوی مدل‌های ماشینی یادگیری عمیق باشد و آموزش مدل رو با مشکل مواجه می‌کند، به بیانی دیگر، در حوضه‌های خشک و نیمه‌خشک، توزیع بارش و خروجی رودخانه

منابع

- Ahadiyan J., Kiani S., Asiaban P., Azizi Nadian H., Omidvarinia M. (2023). 'Optimizing the dimensions of the agricultural water transfer system from the Karun 3 dam to the northeastern cities of Khuzestan province', *Journal of New Approaches in Water Engineering and Environment*, 1(2), pp. 112-126. doi: 10.22034/nawee.2023.367835.1030.
- Alizadeh, M., Alizadeh, E., Asadollahpour Kotenaee, S., Shahabi, H., Beiranvand Pour, A., Panahi, M., Bin Ahmad, B., Saro, L., 2018. Social vulnerability assessment using artificial neural network (ANN) model for earthquake hazard in Tabriz city, Iran. *Sustainability* 10 (10), 3376.
- Azareh, A., Rahmati, O., Rafiei-Sardooi, E., Sankey, J.B., Lee, S., Shahabi, H., Ahmad, B.B., 2019. Modelling gully-erosion susceptibility in a semi-arid region, Iran: Investigation of applicability of certainty factor and maximum entropy models. *Sci. Total Environ.* 655, 684–696.
- Bui, D.T., Hoang, N.-D., Martínez-Álvarez, F., Ngo, P.-T.T., Hoa, P.V., Pham, T.D., Samui, P., Costache, R., 2019a. A novel deep learning neural network approach for predicting flash flood susceptibility: a case study at a high frequency tropical storm area. *Sci. Total Environ.* 701, 134413.
- Bui, D.T., Moayedi, H., Gör, M., Jaafari, A., Foong, L.K., 2019b. Predicting slope stability failure through machine learning paradigms. *ISPRS Int. J. Geo-Inform.* 8 (9), 395.
- Bui, D.T., Ngo, P.-T.T., Pham, T.D., Jaafari, A., Minh, N.Q., Hoa, P.V., Samui, P., 2019c. A novel hybrid approach based on a swarm intelligence optimized extreme learning machine for flash flood susceptibility mapping. *Catena* 179, 184–196.
- Bui, D.T., Panahi, M., Shahabi, H., Singh, V.P., Shirzadi, A., Chapi, K., Khosravi, K., Chen, W., Panahi, S., Li, S., 2018a. Novel hybrid evolutionary algorithms for spatial prediction of floods. *Sci. Rep.* 8 (1), 15364.
- Bui, D.T., Shahabi, H., Shirzadi, A., Chapi, K., Pradhan, B., Chen, W., Khosravi, K., Panahi, M., Ahmad, B.B., Saro, L., 2018b. Land subsidence susceptibility mapping in South Korea using machine learning algorithms. *Sensors.* 18 (8), 2464.

Chen, W., Hong, H., Panahi, M., Shahabi, H., Wang, Y., Shirzadi, A., Pirasteh, S., Alesheikh, A.A., Khosravi, K., Panahi, S., 2019a. Spatial prediction of landslide susceptibility using GIS-based data mining techniques of ANFIS with whale optimization algorithm (WOA) and grey wolf optimizer (GWO). *Appl. Sci.* 9 (18), 3755.

Chen, W., Panahi, M., Tsangaratos, P., Shahabi, H., Ilia, I., Panahi, S., Li, S., Jaafari, A., Ahmad, B.B., 2019b. Applying population-based evolutionary algorithms and a neuro-fuzzy system for modeling landslide susceptibility. *Catena* 172, 212–231

Convertino, M., Annis, A., Nardi, F., 2019. Information-theoretic portfolio decision model for optimal flood management. *Environ. Model Softw.* 119, 258–274

Ebrahim Sharififard, Mohamad Azizipour, Javad Ahadiyan, Ali Haghighi; Determination of creep function coefficients of viscoelastic pipes using a transient-guided machine learning model. *AQUA - Water Infrastructure, Ecosystems and Society* 1 November 2024; 73 (11): 2132–2149. doi: <https://doi.org/10.2166/aqua.2024.091>.

Haynes, K., Coates, L., Van Den Honert, R., Gissing, A., Bird, D., Dimer De Oliveira, F., D'arcy, R., Smith, C., Radford, D., 2017. Exploring the circumstances surrounding flood fatalities in Australia—1900–2015 and the implications for policy and practice. *Environ. Sci. Pol.* 76, 165–176.

Jaafari, A., Gholami, D.M., Zenner, E.K., 2017. A Bayesian modeling of wildfire probability in the Zagros mountains, Iran. *Ecol. Inform.* 39, 32–44.

Jaafari, A., Najafi, A., Melón, M.G., 2015a. Decision-making for the selection of a best wood extraction method: an analytic network process approach. *Forest Pol. Econ.* 50, 200–209.

Jaafari, A., Najafi, A., Rezaeian, J., Sattarian, A., 2015b. Modeling erosion and sediment delivery from unpaved roads in the north mountainous forest of Iran. *GEM – Int. J. Geomathematics.* 6 (2), 343–356.

Jaafari, A., Panahi, M., Pham, B.T., Shahabi, H., Bui, D.T., Rezaie, F., Lee, S., 2019a. Meta optimization of an adaptive neuro-fuzzy inference system with grey wolf optimizer and biogeography-based optimization algorithms for spatial prediction of landslide susceptibility. *Catena.* 175, 430–445.

Jaafari, A., Razavi Termeh, S.V., Bui, D.T., 2019b. Genetic and firefly metaheuristic algorithms for an optimized neuro-fuzzy prediction modeling of wildfire probability. *J. Environ. Manag.* 243, 358–369.

Jaafari, A., Zenner, E.K., Panahi, M., Shahabi, H., 2019c. Hybrid artificial intelligence models based on a neuro-fuzzy system and metaheuristic optimization algorithms for spatial prediction of wildfire probability. *Agric. For. Meteorol.* 266, 198–207.

Jamali, B., Bach, P.M., Deletic, A., 2020. Rainwater harvesting for urban flood management – an integrated modelling framework. *Water Res.* 171, 115372.

Janizadeh, S., Avand, M., Jaafari, A., Phong, T.V., Bayat, M., Ahmadisharaf, E., Prakash, I., Pham, B.T., Lee, S., 2019. Prediction success of machine learning methods for flash flood susceptibility mapping in the Tafresh watershed, Iran. *Sustainability* 11 (19), 5426.

Khosravi, K., Pham, B.T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., Prakash, I., Bui, D.T., 2018. A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Sci. Total Environ.* 627, 744–755.

Khosravi, K., Shahabi, H., Pham, B.T., Adamowski, J., Shirzadi, A., Pradhan, B., Dou, J., Ly, H.B., Gróf, G., Ho, H.L., Hong, H., Chapi, K., Prakash, I., 2019. A comparative assessment of flood susceptibility modeling using multi-criteria decision-making analysis and machine learning methods. *J. Hydrol.* 573, 311–323.

Kianfard, M., Ahadiyan, J. (2016). 'Optimization of under pressure water supply network with transient flow using linear programming method', *Iranian Water Researches Journal*, 10(2), pp. 37-46. https://iwrij.sku.ac.ir/article_10477.html?lang=en.

Kumar, V., Kumar, R., Singh, J. and Kumar, P. (2019) Contaminants in Agriculture and Environment: Health Risks and Remediation. *Agriculture and Environmental Science, India.* <https://doi.org/10.26832/AESA-2019-CAE>

Lee, S., Oh, H.J., 2019. Landslide susceptibility prediction using evidential belief function, weight of evidence and artificial neural network models (*Korean Journal of Remote Sensing.* 35 (2), 299–316



Lennart Schmidt, Falk Heße, Sabine Attinger, Rohini Kumar, 2020, Challenges in Applying Machine Learning Models for Hydrological Inference: A Case Study for Flooding Events Across Germany, *Water Resource Research*, Volume 56, Issue 5, First published: 23 April 2020 <https://doi.org/10.1029/2019WR025924>

Olah C (2015) Understanding LSTM Networks.

Rahmati, O., Panahi, M., Kalantari, Z., Soltani, E., Falah, F., Dayal, K.S., Mohammadi, F., Deo, R.C., Tiefenbacher, J., Tien Bui, D., 2019. Capability and robustness of novel hybridized models used for drought hazard modeling in Southeast Queensland, Australia. *Sci. Total Environ.* 718, 134656

Sajjadi, S.M.; Barihi, S.; Ahadiyan, J.; Azizi Nadian, H.; Valipour, M.; Bahmanpouri, F.; Khedri, P. Redesigning the Fuse Plug, Emergency Spillway, and Flood Warning System: An Application of Flood Management. *Water* 2024, 16, 3694. <https://doi.org/10.3390/w16243694>.