



## Research Article

# Comparison of Deep Learning Models for Streamflow Prediction in Western Iran and on the Kashkan River

Aliakbar Karamvand\*

Received: March 16, 2024

Accepted: September 14, 2024

Revised: August 26, 2024

Published online: December 21, 2024

Ph. D Graduate in Civil Engineering-Water and Hydraulic Structures, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

\*Corresponding Author's Email: [Ali.karamvand@gmail.com](mailto:Ali.karamvand@gmail.com)

## Abstract

### Background and Objectives

In recent years, the use of artificial intelligence methods, such as artificial neural network models, have become increasingly prevalent in simulating complex natural phenomena, including daily streamflow. The streamflow directly correlates with flood occurrences, and mitigating financial and human losses due to floods is crucial. Accurate streamflow simulation is essential for water resource management and river management. Consequently, in hydrology, deep learning methods have emerged as novel tools to address the longstanding challenge of daily streamflow modeling and are widely used in simulations.

Advancements in streamflow modeling with Artificial Intelligence (AI): In recent years, the field of hydrology has witnessed a significant shift toward leveraging AI techniques for streamflow modeling. Among these methods, artificial neural network (ANN) models have gained prominence due to their ability to capture complex relationships within hydrological systems. Streamflow, which represents the flow of water in rivers and streams, is a critical variable for understanding water availability, flood risk, and ecosystem health. By accurately simulating streamflow, researchers and water resource managers can make informed decisions regarding water allocation, flood preparedness, and environmental conservation. Hydrological processes are inherently nonlinear and influenced by various factors such as precipitation, temperature, land cover, and soil properties. Traditional hydrological models often struggle to capture these complexities. However, deep learning methods, including convolutional neural networks (CNNs) and recurrent neural networks (RNNs), offer promising solutions. These models can learn intricate patterns from historical streamflow data, adapt to changing conditions, and provide accurate predictions. As a result, they have become indispensable tools for addressing the longstanding challenge of daily streamflow modeling. Researchers continue to explore novel architectures, data augmentation techniques, and hybrid approaches to enhance the performance and robustness of AI-based streamflow simulations. In summary, the integration of deep learning methods into hydrological research has revolutionized streamflow modeling, enabling more accurate predictions and informed decision-making in water management and flood risk assessment.

### Methodology

In this study, we focused on selecting an appropriate input scenario for deep learning models and simulate daily streamflow on the Kashkan River using LSTM (Long Short-Term Memory) and GRU (Gated Recurrent Unit) deep learning methods. Prior to this, deep learning modeling with the GRU approach using native streamflow measurements had not been performed for Kashkan river. The study area is a flood-prone and mountainous region, specifically the western part of Iran, where a hydrological station with a history of flood events is situated on the Kashkan River. We employ four approaches for handling outliers (Mahalanobis, critical interval removal, Z-Score, and no removal) and four different preprocessing techniques for input data to train two models: LSTM and GRU. Ultimately, eight distinct models are generated and validated against historical data. The input features include regional average precipitation, normalized vegetation cover index, surface soil moisture, groundwater flow, and the Kashkan River's own flow at the hydrological station, with the best features selected using statistical correlation control.



## **Findings**

The results demonstrate that among the deep learning models generated with a 10-day time step, the model with the least error and consistent low error retention in error metrics is observed. Furthermore, the best performance is achieved using different approaches, in the following order: the GRU model with Z-Score-corrected inputs, followed by the Mahalanobis removal approach with average RMSE (Root Mean Square Error) and KGE (Kling-Gupta Efficiency) values of 5.41 and 0.99, respectively, and the critical interval removal approach with RMSE of 6.23 and KGE of 0.7. The results showed that among the deep learning models produced with a time step of 10 days in the model, the lowest amount of error and the persistence of low error can be seen in the error statistics, and among the different approaches used, the best performance is the GRU model with input modified by Z-Score elimination of outlier method, Mahalanobis elimination method with average RMSE and KGE values of 5.41, 0.99, 6.23, and 0.7 in the training phase and 8.17, 0.79, 4.21, and 0.81 in the validation phase and 5.01, 0.68, and 7.21 and 0.52 are in the testing phase. The obtained results do not reject the LSTM method in simulating the river flow, but state that the listed scenarios, especially in the GRU method, have a higher power in dealing with the data and recognizing the complex pattern of daily river flow, taking into account the limitation in use. They have seven years of regular daily data, and future research will show how the behavior of GRU and LSTM models will differ if data with higher convergence is used.

## **Conclusion**

GRU in future studies can make difference by enhanced flood forecasting accuracy, efficient computation and real-time applications, integration with lag time preprocessing, adaptability to changing climate and urbanization. Future studies will be on data driven method in flood prone areas. There remains ample room for future research and innovation. Here are some directions for further exploration: hydrological data fusion, spatially explicit models, uncertainty quantification, climate change resilience.

**Keywords:** Deep learning, Forecasting, Hydrology, RNN, Streamflow



## مقاله پژوهشی

# مقایسه مدل‌های آموزش عمیق در پیش‌بینی جریان رودخانه در غرب کشور و بر روی رودخانه کشکان

علی اکبر کرموند\*

تاریخ دریافت: ۱۴۰۳/۰۱/۱۹

تاریخ پذیرش: ۱۴۰۳/۰۶/۲۴

تاریخ ویرایش: ۱۴۰۳/۰۶/۰۵

تاریخ انتشار آنلاین: ۱۴۰۳/۱۰/۰۱

\*دانش آموخته دکتری مهندسی عمران- آب و سازه‌های هیدرولیکی، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه آزاد اسلامی واحد علوم تحقیقات، تهران، ایران.

\* مسئول مکاتبات، پست الکترونیکی: Ali.karamvand@gmail.com

## چکیده

شبیه‌سازی جریان رودخانه به با دقت بالا لازمه علم مدیریت رودخانه می‌باشد. در مواجه با چالش قدیمی مدل‌سازی روزانه جریان رودخانه، آموزش عمیق به عنوان ابزاری نوین مطرح شده است. در مطالعه حاضر، با تمرکز بر انتخاب سناریوی مناسب از ورودی‌های مدل آموزش عمیق، شبیه‌سازی جریان روزانه رودخانه کشکان در چندین نوبت به روش آموزش عمیق LSTM و GRU انجام شده است. پیش از این، مدل‌سازی آموزش عمیق به روش GRU و با استفاده از داده‌های بومی اندازه‌گیری جریان رودخانه انجام نشده است. منطقه، مستعد سیل و کوهستانی بوده و ایستگاه هیدرومتری با سابقه وقوع سیل، واقع بر روی رودخانه کشکان انتخاب شده است. با استفاده از ۴ رویکرد از روش‌های حذف داده‌های پرت، ورودی به دو مدل LSTM و GRU انتخاب شده و هشت مدل تولید شده است. ورودی‌های ممکنه، عبارت بوده است از میانگین بارش منطقه، شاخص پوشش گیاهی نرمال شده، رطوبت خاک سطحی، جریان‌ات آب زیرزمینی و همچنین خود جریان رودخانه کشکان در ایستگاه هیدرومتری. نتایج نشان داد بهترین عملکرد را به ترتیب، مدل GRU با ورودی‌های اصلاح شده به روش حذف Z-Score، ماه‌الانویس با مقادیر RMSE میانگین و KGE و ۵/۴۱ و ۰/۹۹ و ۶/۲۳ و ۰/۷ در آموزش و ۸/۱۷ و ۰/۷۹ و ۴/۲۱ و ۰/۸۱ در اعتبارسنجی و ۵/۰۱ و ۰/۶۸ و ۷/۲۱ و ۰/۵۲ و در مرحله تست می‌باشند. نتایج، روش LSTM را در شبیه‌سازی جریان رد نمی‌کند، اما سناریوهای برشمرده شده در روش GRU قدرت بالاتری در تشخیص الگوی پیچیده جریان روزانه رودخانه نشان دادند.

واژه‌های کلیدی: آموزش عمیق، پیش‌بینی، جریان رودخانه، حذف داده‌های پرت، علم داده

## مقدمه

(شاراما و ماچیاوال ۲۰۲۱). روش‌های هوش مصنوعی که در مدل‌سازی جریان رودخانه استفاده شده‌اند، بسیار گسترده می‌باشند. دسته‌ای از شبکه‌های عصبی مصنوعی<sup>۱</sup> (ANN) معروف به شبکه‌های عصبی پس‌انتشار<sup>۲</sup> وجود دارد که از زیرمجموعه هوش مصنوعی بوده و کاربرد زیادی در مدل‌سازی جریان رودخانه داشته است. توانایی برجسته مدل‌هایی از خانواده ANN، در یادگیری الگوهای پیچیده و حل مسائل غیر خطی بوده که می‌توانند در مساله شبیه‌سازی جریان رودخانه به کار برده شوند (زیلاند و همکاران ۱۹۹۹، ونگ و همکاران ۲۰۰۶).

اسلام و همکاران (۲۰۱۰)، ویی و همکاران (۲۰۱۲)، چت و همکاران (۲۰۱۳) در مطالعات خود از ANN به صورت مستقیم و غیرمستقیم و یا در ترکیب با روش‌های فراکوشی<sup>۳</sup> در شبیه‌سازی جریان رودخانه استفاده نمودند. مشکلی که در اکثر زیرمجموعه روش‌های شبکه‌های ANN وجود دارد این است که ورودی‌ها، تنها در جهت پیش رونده پردازش می‌شوند. در صورتی که در مدل‌سازی، از وزن‌های مراحل گذشته نیز استفاده گردد و یا در بر خورد با چنین مشکلی از داده‌های ورودی زیاد به روش آموزش عمیق استفاده شود، آنگاه امکان دارد توان مدل‌های شبکه عصبی مصنوعی افزایش یابد. امروزه در مدل‌سازی سری‌های زمانی از آموزش عمیق استفاده می‌گردد. مطالعات نشان داده که استفاده از روش آموزش عمیق به طور ویژه در پیش‌بینی سری‌های زمانی مؤثر واقع شده است. به این دلیل که می‌تواند داده‌های ورودی با حجم و تعداد بالا را دریافت و پردازش نموده، و سپس وابستگی‌ها و الگوهای پیچیده را شناسایی کند. مدل‌های آموزش عمیق می‌توانند با استفاده از شبکه‌های عصبی مصنوعی چند لایه آموزش ببینند تا الگوهای موجود در پدیده‌های طبیعی را شناخته و

وقوع پدیده‌های طبیعی مخرب مانند سیل، مساله‌ای اجتناب‌ناپذیر می‌باشد. این پدیده‌ها می‌توانند اجتماع بشری را با خسارت‌های مالی و جانی و اجتماعی تهدید نمایند. در همین راستا، دانشمندان همواره تلاش کرده‌اند میزان خسارت‌های ناشی از پدیده‌های مخرب را کاهش دهند. از آنجایی که وقوع پدیده سیلاب با میزان جریان رودخانه ارتباط مستقیم دارد، شبیه‌سازی و پیش‌بینی سری‌های زمانی جریان رودخانه در مقیاس زمانی روزانه همواره برای دانشمندان علوم مهندسی آب حائز اهمیت بوده و هنوز هم یک چالش محسوب می‌گردد. شبیه‌سازی جریان رودخانه، ابزاری مهم برای درک روندهایی است که سبب تغییر در کمیت و کیفیت جریان رودخانه می‌شوند. شبیه‌سازی جریان رودخانه کمک می‌کند تا اثر عوامل کلیدی موثر در جریان رودخانه شناسایی گردند و برهم‌کنش این عوامل در تعیین مقدار جریان رودخانه مشخص شود. از این عوامل می‌توان به کاربری اراضی، نوع و رطوبت خاک، الگوی بارش، توپوگرافی منطقه و اقلیم منطقه اشاره کرد که هر کدام از نظر عملکردی توابعی پیچیده هستند. همچنین، انجام شبیه‌سازی جریان رودخانه می‌تواند به میزان اثربخش بودن رویکردهای مدیریتی در جریان رودخانه کمک کند. رویکردهایی در مدیریت بازسازی حاشیه‌های رودخانه یا روش‌های مدیریت سیلابی که در حاشیه رودخانه‌ها انجام می‌گردند، شبیه‌سازی جریان رودخانه می‌تواند به دانشمندان نیز دیدگاهی مناسب ارائه کند تا اثرات رفتار انسان در مقابل محیط‌زیست و به ویژه منابع آبی را مطالعه و تحلیل کنند.

همزمان با پیشرفت در علوم کامپیوتر و افزایش قدرت پردازش رایانه‌ها، روش‌های هوش مصنوعی در میان روش‌های مدل‌سازی بیشتر به کار برده شده‌اند

<sup>3</sup> Meta-Heuristic<sup>1</sup> Artificial Neural Networks<sup>2</sup> Feed Forward Network

مدل، ارجاع به وزن‌های گذشته دیده می‌شود. بدین ترتیب اهمیت توالی اندازه‌گیری داده‌های پدیده‌های طبیعی، که به عنوان ورودی تعریف می‌شوند، حفظ شده و در فرآیند آموزش در نظر گرفته می‌شود. شبکه‌های عصبی مصنوعی سنتی، توان انجام چنین عملیاتی را ندارند. اما در عوض، یک شبکه مصنوعی RNN با داشتن حلقه‌هایی که اجازه ماندگاری داده‌های یادگیری در مرحله آموزش را می‌دهند، توان یادگیری از اطلاعات گذشته را خواهد داشت و بنابراین می‌تواند اثرات این داده‌ها را به زمان حال منتقل کند. RNN پیش از این، در مطالعاتی جهت پیش‌بینی و شبیه‌سازی جریان رودخانه استفاده شده است. برای مثال در مطالعه‌ای که توسط ناگشکومار و همکاران (۲۰۰۴) انجام شد، ایشان به مقایسه شبکه‌های عصبی پس‌انتشار با RNN در پیش‌بینی جریان ماهانه رودخانه می‌پردازند و در نتایج خود اعلام می‌کنند که روش RNN دارای توانایی شبیه‌سازی با ساختار معماری ساده‌تر و در زمان کمتر نسبت به ANN است. مشکل محوشدگی گرادیان<sup>۲</sup> در مدل‌های RNN باعث می‌شود با مرور زمان، اثر وزنهایی که در فاصله زمانی دورتر قرار دارند در مراحل آموزش کمتر شود. این مشکل در زیرمجموعه‌ای از شبکه‌های عصبی مکرر که به نام شبکه‌های حافظه کوتاه مدت - بلند مدت<sup>۳</sup> یا LSTM شناخته می‌شود، تقریباً برطرف شده است. مدل‌های LSTM نسبت به مدل‌های قدیمی‌تر به روش RNN ترجیح داده می‌شوند و در مدل‌سازی‌های اخیر در علم هیدرولوژی بیشتر دیده می‌شود. با توجه به نداشتن مشکل محوشدگی گرادیان حل و توان بالاتر در تشخیص الگوهای پیچیده پدیده‌های طبیعی و غیرخطی که RNN با تشخیص آنها مشکل داشته است، توصیه شده است که در مطالعات آتی از روش LSTM استفاده شود (گرس ۱۹۹۹).

سپس از این اطلاعات بهره گیرند تا بتوانند پیش‌بینی دقیق ارائه نمایند (ون کوپولت و همکاران ۲۰۲۰). اهمیت استفاده از روش آموزش عمیق زمانی مشخص می‌شود که یک سری زمانی، پدیده طبیعی را پیش‌بینی می‌کند. زیرا سری زمانی پدیده‌های طبیعی، معمولاً متاثر از عوامل متعددی هستند که روش‌های قدیمی‌تر مثل روش‌های آماری، توان تشخیص و برخورد با دقت بالایی با آن را ندارند. علاوه بر مطالب مطرح شده، می‌توان گفت که روش آموزش عمیق توانایی تشخیص الگوهای تغییر کننده با زمان و مساله‌های با تعداد ورودی بالا را نیز دارند. به همین دلیل، تبدیل به گزینه مناسب برای انجام پیش‌بینی‌ها شده‌اند (فاواز و همکاران ۲۰۱۹). در یک مدل‌سازی جریان رودخانه، هر چه تعداد متغیرهای موثر در پیش‌بینی افزایش یابد و بتوان سابقه تاریخی این متغیرها را بیشتر در حافظه مدل در نظر گرفت، مدل‌سازی دقیق‌تر خواهد بود. البته این مساله یک بحث پیچیده بین زمان حل، دقت خروجی و طول تاریخی موثر مورد نیاز ایجاد کرده است که متخصصین علم داده، همچنان در مورد این مساله تحقیق می‌نمایند. شبکه عصبی بازگشتی یا مکرر<sup>۱</sup> RNN که زیرمجموعه‌ای از شبکه‌های عصبی است که هر دو قابلیت (سابقه تاریخی طولانی ورودی و تعداد متغیر ورودی بالا) را دارد. محتوی ریاضی RNN به شکلی پیچیده شده است که قابلیت شناسایی توالی عددی داده‌های پیچیده را دارد. مساله توالی داده‌ها، بسیار اهمیت دارد. زیرا یک پدیده طبیعی شبیه‌سازی می‌شود و پدیده‌های طبیعی ذاتاً تکرار شونده هستند. در صورتی که بتوان وزن‌ها را در یک روند آموزش عمیق به نحوی آموزش داد که از توالی سوابق تاریخی تأثیرپذیری بیشتری داشته باشند، احتمال یادگیری دقیق‌تر افزایش خواهد یافت. در مدل‌های RNN، به دلیل معماری خاص و بازگشتی این شبکه در روند آموزش

<sup>3</sup> Long Short-Term Memory Recurrent Neural Networks

<sup>1</sup> Recurrent Neural Network

<sup>2</sup> Vanishing Gradient

روابط در حوضه آبریز منطقه‌ای<sup>۳</sup> معرفی می‌کند. لی و همکاران (۲۰۱۹) در مطالعات خود به پیش‌بینی سیلاب با استفاده از دو ورودی بارش و دبی با مدل LSTM می‌پردازند و تاکید می‌کنند که نتایج نشان دهنده دقت بالای ۸۷٪ در هر سه مدل ساخته شده ایشان داشته است. نیفا و همکاران (۲۰۲۳) در مطالعه‌ای با استفاده از آموزش عمیق به روش LSTM جریان رودخانه را با مقیاس روزانه شبیه‌سازی کردند. برای این منظور، در تعریف ورودی‌های مدل، از داده‌های زمینی و سنجش از دور بارش و دما و مساحت منطقه تحت پوشش برف بین سال‌های ۲۰۰۱ تا ۲۰۱۰ استفاده شد. مدل‌های LSTM ساخته شده در آن مطالعه، شامل تابع بهینه ساز ADAM بوده و ویژگی خاص مطالعه ایشان استفاده از سناریوهای متفاوت در به کارگیری داده‌های ورودی بوده است. در همین راستا، با استفاده از توالی متفاوت در ورود اطلاعات به مدل، وقفه‌های خاصی در ورودی‌های سناریوها تعریف شد. این وقفه‌ها با روش پیشنهادی ریس و همکاران (۲۰۲۱) طراحی شدند که موجب شد در نهایت وقفه‌های ۰، ۱، ۲ و ۳ روزه و توالی ۲، ۱۰، ۲۰، ۲۵ و ۳۰ روزه از داده‌های ورودی انتخاب و به عنوان سناریوهای متفاوت به روش LSTM شبیه‌سازی شوند. نتایج ایشان نشان داد که مدل سناریوی با استفاده از داده‌های معمولی و بدون وقفه و یا توالی خاص، ضعیف‌ترین عملکرد را داشت. در حالی که قوی‌ترین عملکرد مربوط به مدل با طول توالی داده‌های ورودی به صورت ۳۰ روزه بود. نتایج مطالعه ایشان اهمیت استفاده از وقفه و توالی متفاوت در ورودی به مدل LSTM را نشان می‌دهد که امری منطقی به نظر می‌رسد. زیرا در طبیعت نیز بین وقوع پدیده‌های طبیعی و وقفه‌های زمانی منطقی وجود دارد. چو و ونو همکاران (۲۰۲۲) در مطالعه‌ای به بررسی نقش ترکیب داده‌های ورودی در مدل LSTM جهت شبیه‌سازی بارش-روان‌آب

مدل LSTM توانایی نگهداشت طولانی‌تر وزن‌ها برای شناسایی رفتار داده‌های ورودی و در نتیجه آموزش با دقت بیشتر را دارد. این شبکه‌های عصبی مصنوعی بازگشتی توسط هوچریتز و همکاران (۱۹۹۷) توسعه داده شده و تاکنون کاربردهای متفاوتی در پیش‌بینی سری‌های زمانی داشته‌اند. LSTM به ویژه در پیش‌بینی و طبقه‌بندی داده‌ها به عنوان یکی از قوی‌ترین روش‌های دینامیک شبکه عصبی مصنوعی شناخته می‌شود (ستاودمیر و همکاران ۲۰۱۹). به علاوه، این روش با قابلیت خاص خود یعنی «نگهداشت وابستگی‌های قدیمی»<sup>۱</sup> به طور خاصی در مدل‌سازی‌های هیدرولوژیکی اهمیت دارد. مدل‌های LSTM از جهت مقدار ورودی نیز مشخصه‌های جالب توجهی دارند. این مدل‌ها معمولاً می‌توانند ورودی‌های حجیم دریافت نمایند. این ویژگی اگر در روند اجرای مدل مشکلی ایجاد نکند، می‌تواند در یک روند آموزش عمیق در دقت خروجی مدل موثر باشد. تمامی ویژگی‌های مطرح شده، موجب خواهند شد تا مدل‌های LSTM به عنوان روشی با خروجی هدفمندتر و دقیق‌تر در شبیه‌سازی جریان روزانه رودخانه مورد استفاده قرارگیرد. در مدل‌های LSTM پس از انجام یک پیش‌بینی اولیه در سطح هر نورون با استفاده از تابعی بهینه‌ساز (معمولاً تابع ADAM)، بهینه‌ترین ضرایب انتخاب شده و مراحل آموزش ادامه می‌یابد. انتخاب یک الگوریتم بهینه‌ساز موثر در آموزش عمیق می‌تواند موجب کمتر شدن زمان حل و بهبود نتایج گردد. استفاده از تابع ADAM یک روش آماری جهت بهینه‌سازی<sup>۲</sup> بوده که توسط کینگما و همکاران (۲۰۱۵) ارائه شده است. مدل‌های LSTM در چند سال اخیر در مطالعات هیدرولوژی بیش از پیش استفاده شده‌اند. کارترزت و همکاران (۲۰۱۸) در نتایج شبیه‌سازی هیدرولوژیکی در مطالعه خود، مدل LSTM را به عنوان یک مدل هیدرولوژیکی با پتانسیل بالا در شناخت و شبیه‌سازی

<sup>3</sup> Regional Hydrological Model

<sup>1</sup> Long-Term Dependencies

<sup>2</sup> A Method for Stochastic Optimization

اما با استقبال خوبی در شبیه‌سازی جریان رودخانه استفاده شده است. برای مثال آدریان دی ملو و همکاران (۲۰۱۹) و نیز در مطالعه دیگری لی و همکاران (۲۰۲۱) برای شبیه‌سازی جریان رودخانه از این روش استفاده کرده و آن را برای پیش‌بینی جریان رودخانه توصیه می‌نمایند. در مطالعه دیگری وئوژاینهو و همکاران (۲۰۲۲)، با مطالعه بر روی کیفیت کارایی مدل‌های آموزش عمیق، دو مدل از خانواده LSTM و مدلی از نوع MLP و مدلی از GRU را برای پیش‌بینی کوتاه مدت جریان رودخانه استفاده نمودند. ایشان بیان داشتند که ویژگی‌های اقلیمی در اثر بخش بودن مدل پیش‌بینی کننده آموزش عمیق اهمیت ویژه‌ای دارد، اما در خصوص مقایسه مدل‌ها در شرایط مشابه، GRU را نسبت به دو مدل LSTM برتر معرفی کردند.

به عنوان جمع‌بندی بخش مقدمه تحقیق می‌توان بیان کرد که دانشمندان رشته‌های علمی مختلفی توانسته‌اند با بهره‌گیری از هوش مصنوعی و روش‌های آموزش ماشین، جریان رودخانه را با قدرت تفکیک زمانی و مکانی متفاوتی شبیه‌سازی کنند و تلاش‌ها برای بهبود دقت زمانی و مکانی همچنان ادامه دارد. در میان این روش‌ها و از بخش آموزش عمیق به نظر می‌رسد روش‌های GRU و LSTM توانایی قابل قبولی در پیش‌بینی جریان رودخانه داشته باشند. GRU و LSTM روش‌های آموزش عمیق قدرتمند با ویژگی‌های خاص هستند که در پیش‌بینی جریان روزانه رودخانه استفاده می‌گردند. این دو روش از شبکه‌های عصبی بازگشتی ارتقاء یافته‌ای در مرحله آموزش استفاده می‌نمایند و به این ترتیب، در صورتی که داده‌های مناسبی به مدل وارد شده باشد، می‌توانند با دقت خوبی جریان روزانه رودخانه را پیش‌بینی نمایند. توانایی خاص این دو مدل در شناسایی مدل‌های پیچیده می‌تواند ابزاری برای مطالعه سیلاب و کنترل سطح آب رودخانه‌ها باشد. از

می‌پردازند. بررسی‌های ایشان نشان داد که با استفاده از داده‌های هواشناسی بیشتر، می‌توان کارایی مدل LSTM را در شبیه‌سازی بارش-روان آب بهبود بخشید. همچنین در ادامه بیان می‌کنند که ترکیب استفاده از داده‌های مختلف هواشناسی به عنوان روشی در آموزش مدل می‌تواند حجم داده‌های کلی مورد نیاز برای آموزش کامل و صحیح مدل LSTM را کاهش دهد. این روش در مورد حوضه‌های انتخابی ایشان در پیش‌بینی جریان‌های کم، موفق عمل کرد. در مطالعه دیگری، هانت و همکاران (۲۰۲۲) عملکرد روش LSTM را در پیش‌بینی جریان رودخانه در ۱۰ ایستگاه در شرایط آب و هوایی متفاوتی در مناطقی از غرب کشور آمریکا را بررسی کردند. این مدل، با استفاده از ورودی‌هایی به شرح زیر به پیش‌بینی جریان رودخانه می‌پردازد:

خود جریان رودخانه، میانگین از داده‌های سیستم آگاهی بخشی جهانی از سیلاب<sup>1</sup> GioFAS در حوضه آبخیز مورد مطالعه و داده‌های باز آنالیز شده از پیش‌بینی میان مدت آب و هوایی در اروپای مرکزی ERA5<sup>2</sup> در حوضه آبخیز مورد مطالعه. نتایج ایشان نشان داد که روش LSTM می‌تواند به عنوان روشی معتبر در پیش‌بینی جریان رودخانه عمل کند.

در برخورد با مشکل محو شدگی گرادیان در شبکه‌های عصبی بازگشتی، مدل‌های دیگری نیز طراحی شدند. مدلی که در سال‌های بعد از ارائه LSTM پیشنهاد شده است، مدل GRU می‌باشد که توسط چوو و همکاران (۲۰۱۴) ارائه شد. این مدل می‌تواند با تعداد داده‌های کمتری، عملیات آموزش عمیق را با موفقیت پیاده‌سازی کند. این مدل‌ها در تشخیص الگوی سری‌های زمانی که در آنها ترتیب و توالی اهمیت دارد، مانند تبدیل گفتار به متن استفاده شده و کاربرد دارد (شواکر و همکاران ۲۰۱۹). با وجود این که مدل GRU نسبتاً جدید است،

<sup>2</sup> European Centre for Medium-Range Weather Forecasts Reanalysis

<sup>1</sup> Global Flood Awareness System

مرور ادبیات تحقیق مشخص شد در مطالعات همچنان تلاش برای ارتقای روش‌های شبیه‌سازی جریان رودخانه ادامه دارد. مطالعه حاضر به دنبال یافتن پیش‌پردازشی مناسب از داده‌های مدل‌های آموزش عمیق در پیش‌بینی جریان روزانه رودخانه است. به همین علت، تمرکز تحقیق بر روی ورودی‌های مدل بوده و از داده‌های سنجش از دور، داده‌های خروجی مدل‌سازی‌ها، داده‌های میدانی، و داده‌های ابتکاری جمعی استفاده خواهد شد. در ادامه، ترکیبات متفاوتی از پیش‌پردازش داده‌های ورودی مدل در دو مدل LSTM و GRU با روش‌های متفاوتی از حذف داده‌های پرت سناریوهای مختلف ایجاد خواهد شد. در صورتی که بتوان ترکیب مناسبی از ورودی‌ها را در شبیه‌سازی جریان رودخانه به کار برد، ممکن است پیشرفت‌هایی در دقت مدل شبیه‌سازی جریان رودخانه ایجاد گردد. سناریوهای مختلف در داده‌های ورودی ممکن است پیش‌بینی خروجی را تحت تاثیر قرار داده و بتواند توان مدل را بهبود دهد (یافوزو و همکاران ۲۰۲۱). بنابراین در مطالعه حاضر، با هدف ارائه یک سناریو مناسب از داده‌های ورودی در شبیه‌سازی جریان رودخانه تلاش می‌گردد تا مدل‌های متفاوتی ساخته و مورد بررسی قرار گیرند. در این راستا، از پایگاه‌های داده GLDAS و CHIRPS و نیز داده‌های سنجش از دور سنجنده MODIS و همچنین اندازه‌گیری میدانی داده‌های رودخانه استفاده می‌شود که در ادامه بیشتر توضیح داده خواهند شد.

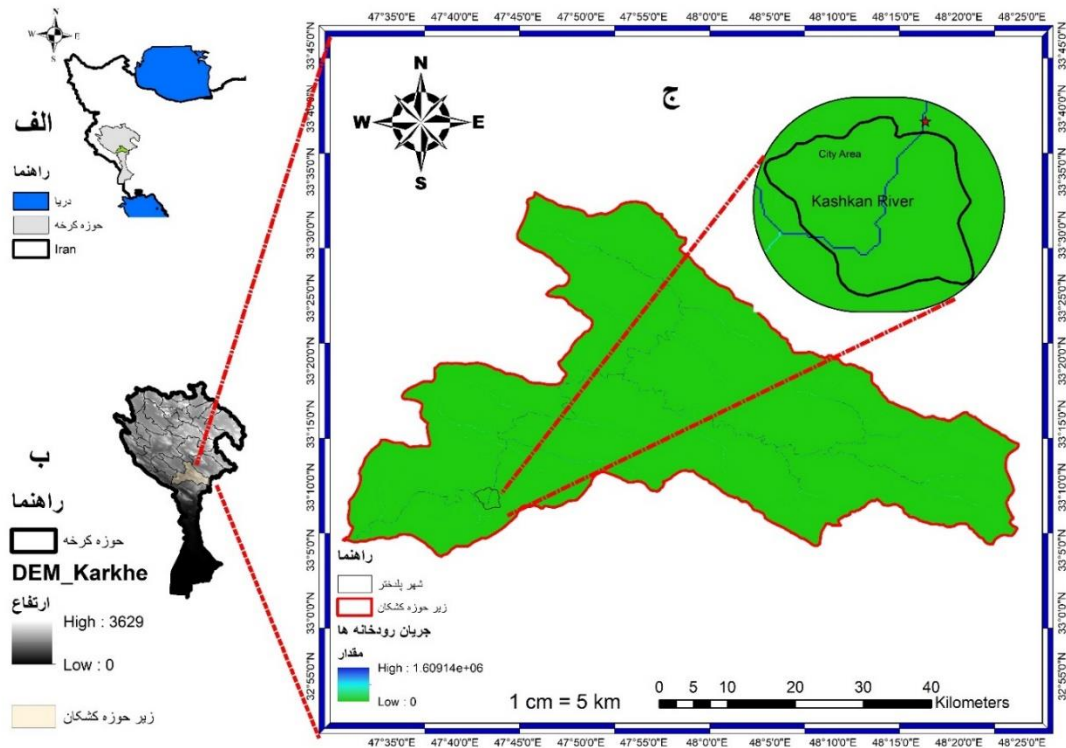
## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبخیز کرخه منطقه‌ای وسیع در محدوده غربی کشور است که بین طول‌های جغرافیایی ۳۱ تا ۳۴ درجه و عرض‌های جغرافیایی ۴۶ تا ۴۹ درجه واقع شده است. این محدوده دارای مساحت  $51643 \text{ Km}^2$  است (جواد

نژاد و همکاران ۲۰۲۰). با توجه به گستردگی وسعت و تنوع عوارض و جنس خاک، رودخانه‌های متفاوتی با شدت و جریان‌های گوناگون در این حوضه آبخیز وجود دارد. رودخانه کشکان به عنوان یک منبع مهم و موثر به ویژه در کشاورزی و زندگی مردم ساکن این محدوده شناخته می‌شود. به طور کلی، این حوضه آبخیز به عنوان یک محدوده مهم از دیدگاه منابع آبی برای کشور می‌باشد که بخش مهمی از آب‌های کشاورزی و صنعتی و نوشیدنی کشور را تامین می‌کند (گراوند و همکاران ۲۰۲۰). رودخانه کشکان حدوداً دارای  $300 \text{ Km}$  طول است و از میان اکوسیستم‌های متنوعی از جنگل تا دشت عبور می‌کند. بررسی سابقه تاریخی رودخانه کشکان نشان داده است که این رودخانه به صورت بالقوه مستعد سیلاب است و با توجه به املاح و رسوبات زیادی که با خود حمل می‌کند در هنگام سیلاب می‌تواند مخرب‌تر از سایر رودخانه‌های مشابه باشد و هزینه‌های احیای مناطق سیلاب‌زده نیز بیش از موارد مشابه تحت سیل خواهد بود. در حد فاصله بین سال‌های ۱۹۹۵ تا سال ۲۰۲۰، این رودخانه ۱۶ سیلاب با بیش از ۱۰۰۰ متر مکعب بر ثانیه را ثبت کرده است (حسینی و همکاران ۲۰۲۱). شکل ۲ نشان می‌دهد که در حد فاصل بین سال‌های ۲۰۱۶ تا آوریل ۲۰۲۱، چهار مورد سیلاب بیش از ۱۰۰۰ متر مکعب بر ثانیه در دهانه ورودی شهر پلدختر رخ داده است که یک مورد آن بیش از ۴۰۰۰ متر مکعب بر ثانیه بوده است. منطقه‌ای که روش ارائه شده در این مطالعه در آن پیاده‌سازی می‌گردد، زیرحوضه‌ای از حوضه آبخیز کرخه به مساحت و ویژگی‌های ارائه شده در جدول ۱ است. همچنین شکل ۱ محدوده مورد مطالعه به همراه موقعیت آن در حوضه آبخیز کرخه را نمایش می‌دهد. به علاوه، برای نمایش محل قرارگیری ایستگاه هیدرومتری مورد استفاده، موقعیت مکانی شهر پلدختر در این محدوده مورد مطالعه بزرگنمایی شده است.

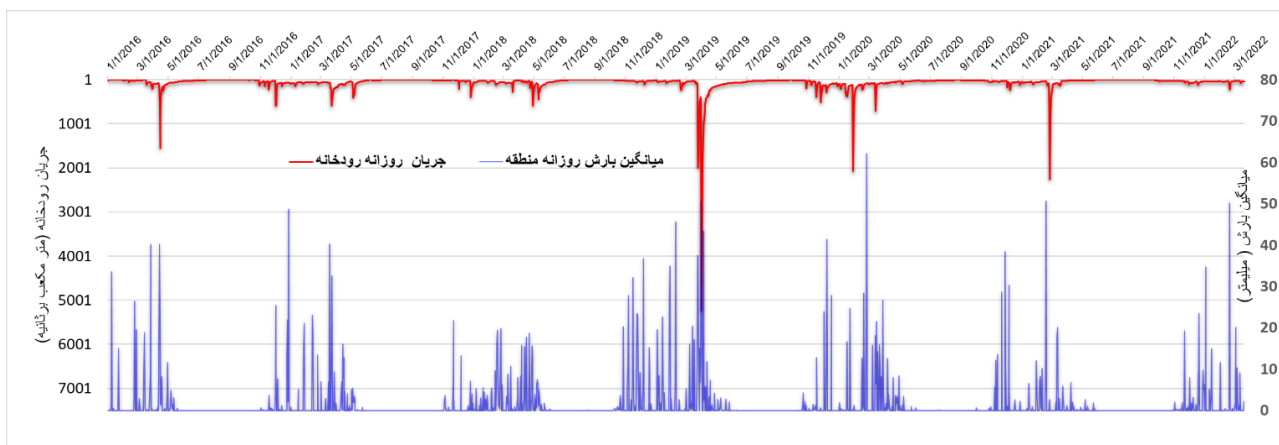




شکل ۱- منطقه مورد مطالعه (الف) جایگاه منطقه مورد مطالعه در کشور (ب) جایگاه منطقه مورد مطالعه در حوزه آبخیز کرخه (ج) موقعیت ایستگاه اندازه گیری جریان آب رودخانه.

جدول ۱- ویژگی های جغرافیایی منطقه مورد مطالعه.

مهمترین رودخانه	مساحت (کیلومترمربع)	کمترین ارتفاع (متر)	بیشترین ارتفاع (متر)	میانگین ارتفاع (متر)	منطقه مورد مطالعه	حوضه آبخیز
کاشکان	۲۰۳۱	۵۳۳	۲۹۵۸	۱۳۱۲	زیر حوضه کاشکان	کرخه



شکل ۲- نمایش بارش میانگین منطقه مورد مطالعه در مقابل جریان رودخانه در ایستگاه هیدرومتری ورودی شهر پلدختر با قدرت تفکیک زمانی روزانه.

## داده‌های مورد استفاده

در خصوص داده‌های ورودی به مدل‌های هیدرولوژی همواره پیشرفت‌هایی حاصل شده است، در علم هیدرولوژی در سال‌های اخیر استفاده از داده‌های ماهواره‌ای به تنهایی یا در ترکیب با روش‌های پس پردازشی و داده‌های میدانی بیشتر دیده می‌شود. در حقیقت می‌توان گفت در عصر حاضر ماهواره‌ها به منظور استفاده‌های تجاری و عمومی، محیط زیستی، پایش و جمع آوری داده‌های سطح زمین و یا امور نظامی و غیره، طراحی و بهره‌برداری می‌شوند (لانس و همکاران ۲۰۱۹). در دسته ماهواره‌های تجاری داده‌های خروجی و یا تصاویر انحصاراً در اختیار سازمان‌های دولتی و خصوصی قرار دارد. در برخی موارد با پرداخت هزینه دسترسی عموم به این داده‌ها و یا تصاویر امکان پذیر خواهد بود. امروزه به سبب توسعه علم سنجش از دور و انتشار وسیع داده‌های خروجی این علم در سراسر کره زمین، اطلاعاتی مانند داده‌های علمی هواشناسی، کشاورزی و اقلیمی در پایگاه‌های اطلاعاتی متنوعی موجود است. همچنین انجام دادن عملیات تحلیل مجدد و تولید داده‌های ثانویه دقیق‌تر نیز با استفاده از ترکیب داده‌ها یا تحلیل‌های داده محور در تحقیقات علمی فراوانی دیده می‌شود.

ورودی‌هایی از نوع داده‌های هواشناسی مانند بارش، درجه حرارت و تبخیر و تعرق معمولاً در مدل‌های شبیه‌سازی LSTM در تحقیقات استفاده شده‌اند. همچنین داده‌های دیگری چون رطوبت خاک و مقدار دبی جریان رودخانه می‌توانند مفید واقع گردند. پیش پردازش داده ورودی در نتایج مدل به شکل محسوسی اثر گذار است و می‌بایست ورودی مدل، بدون خطا و داده‌های پرت بوده و با قدرت تفکیک مکانی و زمانی مناسب تهیه گردند. زیرا هر گونه خطای فاحش در

ورودی‌ها می‌تواند عملیات پردازش و شناخت الگوی انجام شده در روند آموزش عمیق را مختل و متاثر نماید. به علاوه، انتخاب نوع داده‌ها نیز بسیار مهم بوده و داده‌های ورودی مدل می‌بایست عوامل موثره واقعی رفتار پدیده در اکوسیستم طبیعی باشند. برای مثال بسیار واضح است که بارش نقش مهم و اثرگذاری در جریان رودخانه دارد. بنابراین می‌تواند یک گزینه مناسب برای ورودی به مدل تخمینگر جریان رودخانه باشد. در مطالعه حاضر، از داده‌های مدل‌های داده گواری سطح زمین GLDAS به عنوان ورودی استفاده شده است. داده گواری به این معنی که خروجی حاصل ترکیب داده‌های اندازه‌گیری میدانی و سنجش از دور با مدل‌های کامپیوتری است. اطلاعات مدل‌های GLDAS با استفاده از ورودی‌های مختلفی چون بارش و دما و طبقه‌بندی خاک و غیره تولید می‌شوند که از هر دو روش سنجش از دور و روش میدانی تهیه شده‌اند. تولید کننده این اطلاعات از زیرمجموعه مرکز خدمات اطلاعاتی علوم زمین سازمان هوا و فضای امریکا (GES DISC) می‌باشد (تنج و همکاران ۲۰۱۶).

## پایگاه داده GLDAS

این پایگاه داده، انواع مختلفی از اطلاعات مربوط به شارهای انرژی در کره زمین و روندهای طبیعی در جریان در سطح زمین و نیز چرخه آب بین زمین و اتمسفر را در وسعت تمام کره زمین با قدرت تفکیک زمانی و مکانی مختلف ارائه می‌کند. این داده‌ها، ترکیبی از داده‌های استخراج شده با روش سنجش از دور، روش اندازه گیری میدانی و روش مدل‌سازی کامپیوتری می‌باشند. پیش از این، در مطالعات مختلفی داده‌های این پایگاه داده به منظور تحقیقات هیدرولوژیکی و هواشناسی مورد استفاده و تایید قرار گرفته‌اند. این داده‌ها می‌توانند در امور مربوط به پیش‌بینی یا اقلیم‌شناسی و یا رصد خشکسالی نیز

و اقلیم شناسی و کشاورزی و الگوهای بارش استفاده شده است (فوونک و همکاران ۲۰۱۵). بارش میانگین در مطالعه حاضر با مقیاس زمانی روزانه در حد فاصل بین سال‌های مشترک با اندازه گیری‌های میدانی جریان رودخانه استفاده شده است.

#### داده‌های سنجنده MODIS

شاخص NDVI اختلاف نرمال شده شاخص پوشش گیاهی منطقه است که بر اساس خصوصیات انعکاسی پوشش گیاهی در سنجش موج الکترومغناطیسی قرمز RED و مادون قرمز نزدیک Near-IR از رابطه ۱ بدست می‌آید (گسس و میلیسی ۲۰۱۹). در حال حاضر با استفاده از ماهواره TERRA و سنجنده MODIS که براساس بازتاب نور عمل می‌کند، می‌توان این شاخص را با قدرت تفکیک مکانی ۱۰۰۰ متر و به صورت روزانه محاسبه کرد.

$$NDVI = \frac{\rho_{NIR}^* - \rho_{RED}^*}{\rho_{NIR}^* + \rho_{RED}^*} \quad [1]$$

در معادله (۱)،  $\rho_{RED}^*$  برابر است با مقدار بازتاب بدست آمده در محدوده طیفی رنگ قرمز مرئی و  $\rho_{NIR}^*$  برابر است با مقدار بازتاب بدست آمده در محدوده طیفی مادون قرمز نزدیک و NDVI شاخص پوشش گیاهی می‌باشد. در مطالعه حاضر با توجه به این‌که در محاسبات این شاخص، عوامل متعددی چون ابرناکی و یا عدم وجود نور در شب و روز احتمالاً تا حدی در سنجش نهایی ایجاد خطا خواهند کرد، از فیلتر ریاضی «ساویتزکی-گلوئی» برای رفع نوسانات NDVI استفاده شده است (ساویتزکی و همکاران ۱۹۶۴). این فیلتر برای رفع نوسانات شدید سری زمانی استفاده می‌شود و پیش از این سانچز و همکاران (۲۰۱۶) و همچنین کرموند و همکاران (۲۰۲۲) در مطالعات جداگانه‌ای از

استفاده کردند (رودل و همکاران ۲۰۰۴). داده‌های این پایگاه داده، از ابتدای سال ۲۰۰۰ تاکنون با قدرت تفکیک مکانی 0.25 arc درجه برابر حدوداً ۲۷/۸ کیلومتر مربع در دسترس بوده و برای استفاده در تحقیق حاضر ابتدا داده‌ها با قدرت تفکیک زمانی ۳ ساعته دریافت شده و سپس از هر ۸ داده‌ی مربوط به یک روز، میانگین گیری شده و داده‌ها تبدیل به داده‌های روزانه شده‌اند. این عملیات، همچنین کمک خواهد کرد تا خطای احتمالی ناشی از ورودی‌ها به مدل نهایی کاسته شود. داده‌های مورد استفاده از این پایگاه داده، عبارت از رطوبت خاک سطحی و سطح رواناب در آب‌زیرزمینی پایه است. این اطلاعات می‌توانند در پیش‌بینی جریان رودخانه موثر واقع گردند (اوجیادا و همکاران ۲۰۰۲، وینتر ۲۰۰۷). داده‌ها در ۲۲۷۱ روز متوالی در حد فاصله تاریخی بین ۲۰۱۶/۰۱/۱ تا ۲۰۲۲/۰۳/۲۰ استخراج و استفاده شده‌اند.

#### پایگاه داده CHIRPS

پایگاه داده CHIRPS<sup>۱</sup> یک پایگاه داده با سوابق تاریخی بالا و در وسعت تمام کره زمین است که می‌تواند در مطالعه حاضر به عنوان ورودی میانگین بارش منطقه استفاده شود. علت استفاده از چنین پایگاه داده‌ای این است که در منطقه مورد مطالعه، فاصله ایستگاه‌های اندازه‌گیری بارش با یکدیگر زیاد بود به همین دلیل، برای بدست آوردن میانگین بارش منطقه به این پایگاه داده استناد شده است. این پایگاه داده توسط گروه خطرات اقلیمی دانشگاه کالیفرنیا، سانتا باربارا توسعه داده شده است و بر مبنای مقایسه تصاویر سنجش از دور و اندازه‌گیری میدانی و تخمین‌های ارائه شده توسط گروه خطرات اقلیم تولید داده است.

این پایگاه داده، اطلاعات بارش از سال ۱۹۸۱ تاکنون را برای بیش از ۸۰ کشور در خود جای داده و پیش از این در مطالعات مختلفی در خصوص علوم هیدرولوژی

<sup>2</sup> Climate Hazards Group Rainfall Estimates (CHGREE)

<sup>1</sup> Climate Hazards Group InfraRed Precipitation with Station

پلدختر رودخانه کشکان مورد بررسی قرار خواهد گرفت.

داده‌های مورد استفاده در یک نگاه در جدول ۲ قابل بررسی هستند. این جدول پیش از هر گونه فیلتر ریاضی و اصلاح داده‌ها تهیه شده است و یک دید کلی نسبت به شرایط داده‌های مورد استفاده ارائه می‌کند. در این جدول و در ادامه این تحقیق، رطوبت خاک سطحی با SSM و جریان رودخانه با Q، جریان آب زیرزمینی پایه با G.Water، بارش با P و نیز شاخص پوشش گیاهی نرمال شده با NDVI نمایش داده شده‌اند.

آن استفاده کرده‌اند، همچنین این فیلتر به صورت یک تابع در محیط پایتون قابلیت فراخوانی دارد.

### داده‌های هیدرومتری میدانی جریان رودخانه

داده‌های ایستگاه هیدرومتری در مطالعه حاضر ناشی از اندازه‌گیری میدانی جریان رودخانه در ایستگاه پلدختر، با تفکیک زمانی روزانه است (علامت ستاره در شکل ۱). این داده‌ها در کشور ایران توسط سازمان مدیریت منابع آب کشور جمع آوری می‌گردد. در واقع هدف اصلی این مطالعه ارائه روشی برای پیش‌بینی این دسته سری زمانی‌ها خواهد بود. محل اندازه‌گیری این داده‌ها بسیار حیاتی بوده و در موقعیت ورودی شهر

جدول ۲- شرایط پراکنندگی و تغییرات داده‌های مورد استفاده.

عنوان	NDVI (-)	G.Water (kg m <sup>-2</sup> )	SSM (kg m <sup>-2</sup> )	P(mm day <sup>-1</sup> )	Q (m <sup>3</sup> s <sup>-1</sup> )
تعداد	۲۲۷۱	۲۲۷۱	۲۲۷۱	۲۲۷۱	۲۲۷۱
میانگین	-۰/۲۰۵	-۰/۰۵۶	۱۹/۲۴	۱/۴۱۲	۶۳/۵۹
انحراف‌معیار	-۰/۰۳۸	-۰/۱۱۱	۸/۴۱	۵/۲۷	۱۸۵/۳۲
کمینه	-۰/۰۰۴	-۰/۰۰۲	۸/۵۶	۰	۱/۶۴
۲۵%	-۰/۱۸۴	-۰/۰۰۵	۱۰/۰۲۱	۰	۱۱/۸
۵۰%	-۰/۲۰۳	-۰/۰۱۴	۲۰/۲۰۴	۰	۳۲/۳
۷۵%	-۰/۲۲۸	-۰/۰۶۷	۲۷/۰۲۵	۰	۶۴/۶
بیشینه	-۰/۳۰۹	۱/۷۰۴	۳۸/۷۲۸	۶۲/۰۸	۵۲۳۷

### مدل LSTM

مدل شبکه‌ی عصبی حافظه‌ی کوتاه مدت - طولانی مدت یا به اختصار LSTM نوعی خاص از شبکه عصبی بازگشتی است که می‌تواند وزن‌های قدیمی یا بلند مدت را در حافظه خود نگه دارد. این مدل که در مطالعات مربوط به پردازش زبان، ترجمه و تایپ صوتی و تشخیص صدا به شکل گسترده‌ای استفاده می‌گردد، ویژگی منحصر به فردی در تشخیص توالی اطلاعات دارد. اگر مساله با جزئیات بیشتری باز شود می‌توان به محتوای ریاضی این برنامه اشاره کرد، در مرحله‌ای

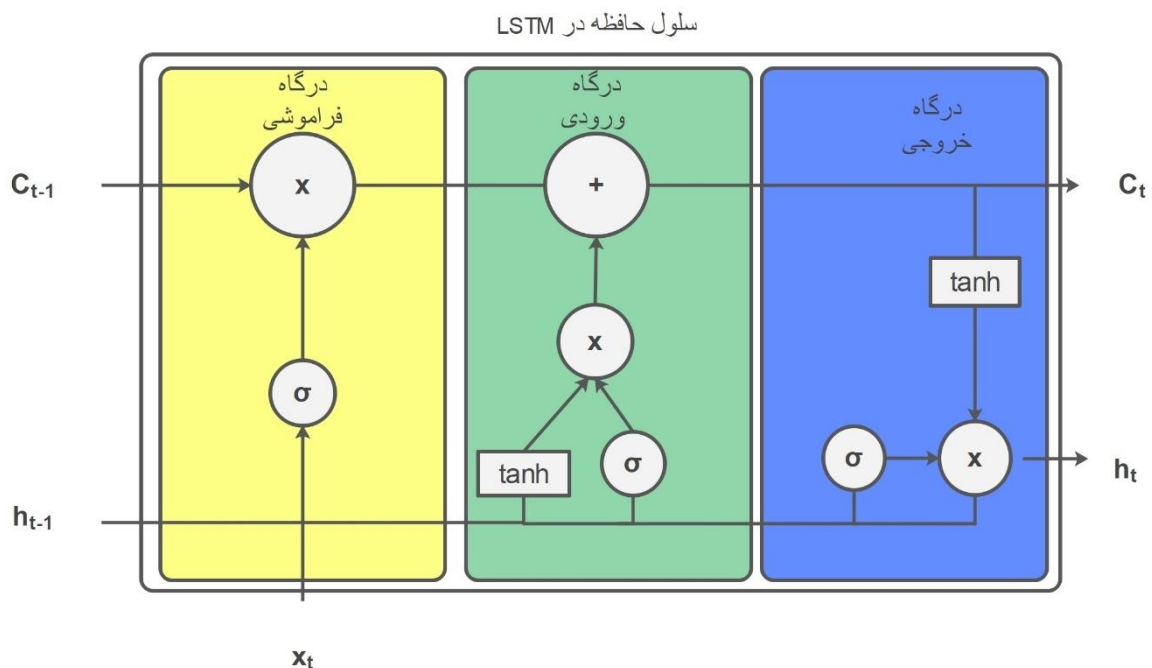
از پردازش داده‌ها، درگاه‌هایی<sup>۱</sup> وجود دارد که در شکل ۳ نشان داده شده است. این درگاه‌ها به شبکه اجازه می‌دهند تا بر روی اطلاعات مهم تمرکز کند. همچنین، این درگاه‌ها به شبکه کمک می‌کنند تا وزن‌های قدیمی را برای مدت طولانی در خود نگه دارد، تا بدین‌وسیله الگوهای پیچیده راحت‌تر شناسایی گردند. هر سلول در شبکه LSTM یک واحد خودنگهدار<sup>۲</sup> است که حاوی مجموعه‌ای از سلول‌های حافظه و درگاه‌ها است. سلول‌های حافظه، مقادیر را از گام زمانی قبلی در توالی مشخص نگهداری می‌کنند، در حالی که درگاه‌ها

<sup>2</sup> Self-Contained Unit

<sup>1</sup> Gates

ورودی‌ها و  $C_t$  نشان دهنده (Cell State) یا حافظه بلندمدت و  $C_{t-1}$  نشان دهنده حافظه بلندمدت در گام قبلی،  $H_t$  نشان دهنده حافظه پنهان یا کوتاه مدت (Hidden state) و  $H_{t-1}$  نشان دهنده حافظه کوتاه مدت در گام زمانی قبلی می‌باشند. اضافه کردن با (+) و مقیاس‌سازی داده‌ها نیز با (X) نشان داده شده است.

تعیین می‌کنند که کدامیک از اطلاعات می‌توانند به گام بعدی راه پیدا کنند. درگاه‌ها همچنین به شبکه کمک می‌کنند تا داده‌های قدیمی‌تر را نگهداری کرده و محتوای داده‌ها را شناسایی کنند (هوچریتز و همکاران ۱۹۹۷). در ادامه و در شکل ۳  $\tanh$  تابع فعال‌ساز تانژانت هایپربولیک، و  $\sigma$  تابع فعال‌ساز سیگما،  $X_t$  نشان دهنده



شکل ۳ - ساختار و معماری سلول حافظه در یک شبکه عصبی LSTM.

گام اول محاسبه، در درگاه فراموشی است (رابطه ۱). در این مرحله، تصمیم بر اساس یک تابع سیگما گرفته می‌شود.

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad [۶]$$

$$h_t = o_t \times \tanh(C_t) \quad [۷]$$

#### مدل GRU

این مدل که در مطالعات مربوط به پردازش زبان، ترجمه و تایپ صوتی و تشخیص صدا به شکل گسترده‌ای استفاده می‌گردد، ویژگی منحصر به فردی در تشخیص توالی اطلاعات دارد. در این مدل در

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad [۲]$$

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad [۳]$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad [۴]$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad [۵]$$

مرحله‌ای از پردازش داده‌ها درگاه‌هایی<sup>۱</sup> وجود دارد که در شکل ۳ نشان داده شده است. این درگاه‌ها به شبکه اجازه می‌دهند تا بر روی اطلاعات مهم تمرکز کند. این نوع معماری از مفاهیمی به نام دروازه به‌روزرسانی<sup>۲</sup> و دروازه بازنشانی<sup>۳</sup> سود می‌برد. این دو درگاه، تعیین کننده این موضوع خواهند بود که چه اطلاعاتی می‌توانند و چه اطلاعاتی نمی‌توانند عبور کنند. نکته مهم در خصوص دروازه‌ها، قابل آموزش بودن آن‌ها است، تا اطلاعات مربوط به گام‌های زمانی بسیار قبل را بدون آنکه دستخوش تغییر شوند در خود نگهداری کنند. دروازه بروزرسانی که با گاما یو، نمایش داده می‌شود، تعیین خواهد کرد در یک گام زمانی حالت قبلی مورد استفاده قرار گیرد یا ورودی و یا ترکیبی از هر دو استفاده گردد. با استفاده از این قابلیت، شبکه خواهد

توانست در دنباله‌های طولانی یک حالت از چندین گام زمانی قبل را در چند گام زمانی بعدی اثر دهد. این مدل در مطالعه حاضر به زبان پایتون پیاده‌سازی شده و با سخت افزار پردازش کننده GPU محور<sup>۴</sup> پردازش شده است. مشخصات مدل در تمامی سناریوهایی که در ادامه توضیح داده خواهند شد ثابت بوده و به شرح جدول ۳ می‌باشد. از میان تمامی داده‌های ممکن، ۷۰٪ برای استفاده در مرحله آموزش، ۱۵٪ در مرحله آزمون و ۱۵٪ در مرحله اعتبارسنجی استفاده شده‌اند. در شکل ۴ تابع فعال‌ساز tanh تابع فعال‌ساز تانژانت هایپربولیک،  $\sigma$  تابع فعال-ساز سیگما،  $X_t$  نشان دهنده ورودی‌ها،  $C_t$  نشان دهنده (Cell State) یا حافظه بلند مدت و  $C_{t-1}$  نشان دهنده حافظه بلند مدت در گام قبلی می‌باشند.

جدول ۳ - ویژگی‌های مدل‌ها.

نام مدل	تعداد لایه	واحد <sup>۵</sup>	گذر آموزشی <sup>۶</sup>	سایز هر پاس <sup>۷</sup>	تابع خسارت <sup>۸</sup>	عامل فشار <sup>۹</sup>	تابع فعال ساز همه هر چهار لایه
GRU	چهار لایه	۳۰	۵۰	۳۲	MSE	۰/۲	Tanh
LSTM	چهار لایه و LSTM و یک لایه پنهان	۶۰	۱۶۰	۳۲	MAE	۰/۶	ADAM

<sup>5</sup> Unit

<sup>6</sup> Epoch

<sup>7</sup> Batch Size

<sup>8</sup> Loss

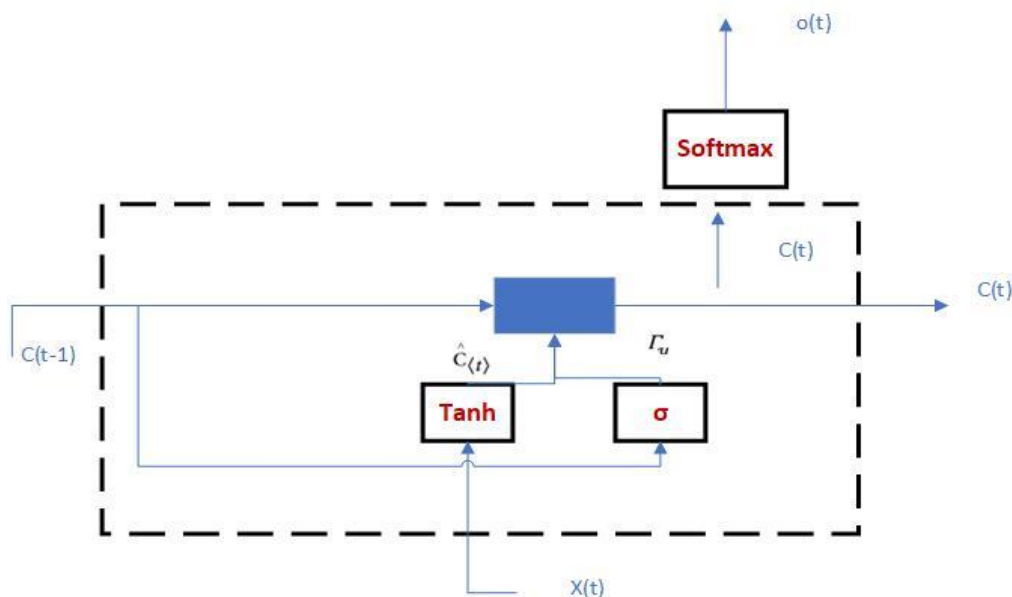
<sup>9</sup> Dropout

<sup>1</sup> Gates

<sup>2</sup> Update Gate

<sup>3</sup> Reset Gate

<sup>4</sup> Intel Xeon CPU @2.20 GHz, 13 GB RAM, Tesla K80 accelerator, and 12 GB GDDR5 VRAM



شکل ۴ - ساختار و معماری سلول حافظه در یک شبکه عصبی GRU.

نهایت، برای هر نقطه در مجموعه داده، فاصله ماحالانوبیس با استفاده از رابطه زیر محاسبه می‌شود:

$$MD = \sqrt{(u - v)V^{-1}(u - v)^T} \quad [8]$$

در معادله (۸)،  $u, v$  ورودی‌ها بوده و از جنس آرایه یک بعدی می‌باشند.  $V$  نماینده ماتریس کوواریانس داده‌ها است.  $MD$  نشان‌دهنده فاصله ماحالانوبیس می‌باشد.

در گام آخر، تعیین آستانه انجام می‌شود. هیچ مقدار آستانه ثابتی برای فاصله ماحالانوبیس وجود ندارد که بتواند به طور قطعی نقاط پرت را مشخص کند. روش رایجی که برای تعیین آستانه وجود دارد استفاده از تابع توزیع احتمال  $\chi^2$  می‌باشد.

آستانه بر اساس  $\chi^2$ ، از توزیع  $\chi^2$  با درجه آزادی برابر با تعداد ابعاد داده‌ها استفاده می‌کند. سطح معنی داری مورد نظر را انتخاب کرده (معمولاً ۰/۰۵ یا ۰/۰۱) و سپس آستانه براساس این سطح معنی‌داری و درجه آزادی بدست می‌آید. هر نقطه‌ای که فاصله ماحالانوبیس آن از آستانه بیشتر باشد، به عنوان نقطه پرت در نظر

#### روش ماحالانوبیس

تشخیص داده‌های پرت نوعی پیش‌پردازش در محاسبات مدل‌های شبیه‌سازی جریان رودخانه بوده و امری مهم محسوب می‌شود. از آنجایی که چنین داده‌هایی را با استفاده از مدل‌های آماری خارج می‌کنیم باید مطمئن باشیم که اثرات حذف آنها در مدل‌های پیش‌بینی کننده تا چه مقدار می‌باشد. تابع فاصله ماحالانوبیس<sup>۱</sup> به عنوان روشی برای اندازه‌گیری فاصله مشاهدات از یکدیگر استفاده می‌شود. فاصله ماحالانوبیس، نشان دهنده انحراف هر نقطه از مرکز خوشه داده‌ها، با در نظر گرفتن همبستگی و واریانس ابعاد مختلف است و با استفاده از گام‌های زیر قابل محاسبه است:

ابتدا، ماتریس کوواریانس برای مجموعه داده‌ها محاسبه خواهد شد که این ماتریس نشان دهنده واریانس هر بعد و همبستگی بین آنها است. سپس، بردار میانگین برای مجموعه داده‌ها محاسبه می‌شود. این بردار، نشان دهنده مرکز خوشه داده‌ها است. در

<sup>2</sup> Chi-Square

<sup>1</sup> Mahalanobis Distance

گرفته می‌شود.

### روش Z-Score

این روش را می‌توان از دسته روش‌های نرمال سازی تلقی کرد. در این روش، مقدار Z-score از طریق رابطه (۹) قابل محاسبه است که در آن،  $\mu$  مقدار میانگین جمعیت آماری و  $\sigma$  انحراف معیار جمعیت می‌باشد. مقدار قدر مطلق محاسبه شده برای  $z$ ، فاصله آن ردیف از داده‌ها را از میانگین کل جمعیت بر حسب انحراف معیار نشان می‌دهد. هنگامی که این مقدار مثبت باشد، یعنی Z-score بالاتر از میانگین و اگر منفی باشد، نشان دهنده کمتر بودن مقدار خاص، از میانگین کل داده‌ها می‌باشد (کورا و همکاران ۲۰۲۰). در مطالعه حاضر، بازه  $\pm 2/5$  برای انتخاب داده‌ها در نظر گرفته شده است. کلیه عملیات محاسبه و حذف داده‌های پرت در محیط پایتون پیاده سازی شده است.

$$z = \frac{x - \mu}{\sigma} \quad [9]$$

### روش حذف مقطع بحرانی - روش رویکرد بدون

#### حذف

یکی دیگر از روش‌های پالایش داده‌ها، خارج کردن مقطعی است که سیل آنچنان شدید بوده که سبب شده جریان رودخانه در دسته‌های آماری با احتمال رخداد پایین قرار گیرد. به این منظور، در یک سناریو انتخابی تحت نام سناریوی خروج مقاطع بحرانی، بخشی از سال ۲۰۱۹ که جریان رودخانه کشکان به شدت طغیان داشته است از ورودی‌ها حذف شده است. سناریو دیگری نیز انتخاب شده که در آن هیچ داده‌ای از ورودی‌ها حذف نگردد و به نام سناریو رویکرد بدون حذف نام برده خواهد شد.

#### سناریوها

با ترکیب دو مدل با ۴ رویکرد حذف داده‌های پرت، ۸ سناریوی متفاوت از مدل‌های شبیه‌سازی جریان رودخانه تشکیل خواهد شد.

جدول ۴- رویکرد پیش‌پردازش و ساخت مدل‌ها.

سناریو	سناریو-۰۱	سناریو-۰۲	سناریو-۰۳	سناریو-۰۴	سناریو-۰۵	سناریو-۰۶	سناریو-۰۷	سناریو-۰۸
مدل	مدل GRU	مدل GRU	مدل GRU	مدل GRU	مدل LSTM	مدل LSTM	مدل LSTM	مدل LSTM
روش حذف	ماهالانوبیس	بدون حذف	Z-Score	مقطع بحرانی	ماهالانوبی س	بدون حذف	Z-Score	مقطع بحرانی

### آماره‌های اندازه گیری خطا

در آخرین مرحله این تحقیق، نتایج بدست آمده در بخش‌های آموزش، آزمون و اعتبارسنجی مدل به روش کنترل آماره‌های خطای زیر بررسی شده و پیرامون نتایج بحث می‌شود. میانگین قدرمطلق خطا از رابطه زیر محاسبه شده است.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad [10]$$

در رابطه (۱۰)،  $n$  تعداد کل داده‌های جامعه آماری بوده و  $Y_i$  یک داده در سری زمانی در مرحله  $i$  ام و  $\hat{Y}_i$  مقدار داده پیش‌بینی در مرحله  $i$  ام می‌باشد و میانگین قدرمطلق خطا با MAE نمایش داده شده است. ضریب تعیین از رابطه زیر محاسبه می‌گردد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad [11]$$

معیار ضریب تعیین معیاری که با  $R^2$  نمایش داده شده،



معیار جامع برای ارزیابی دقت مدل های هیدرولوژیکی استفاده می شود و می تواند به عنوان یک ابزار مفید برای انتخاب و ارزیابی مدل های پیش بینی هیدرولوژیکی در مطالعات آب و هوا و منابع آب مورد استفاده قرار گیرد (وگایو و مولن ۲۰۲۲). رابطه اصلی این شاخص به شرح رابطه ۱۳ است. با استفاده از عدد بدست آمده، مدل را به چندین دسته می توان تقسیم بندی کرد:

درجه عالی، که مقدار KGE بیشتر از (۰/۸) است، درجه خوب بین (۰/۶ الی ۰/۸)، متوسط مقدار بین (۰/۴ تا ۰/۶) و عملکرد ضعیف کمتر از (۰/۴).

در صورتی که  $r$  نماینده و نشانگر قابلیت اعتماد به داده ها (همبستگی پیرسون خطی بین مشاهدات و شبیه سازی ها) باشد و بتا ضریب بایاس<sup>۴</sup> رابطه و گاما عدد حاصل از تقسیم میانگین داده های شبیه سازی بر داده های واقعی) رابطه به شکل زیر تعریف می گردد.

$$KGE = 1 - \sqrt{(1 - \beta)^2 + (1 - r)^2 + (1 - \gamma)^2} \quad [13]$$

### نتایج و بحث

بعد از عملیات های پیش پردازش و اجرای مدل، نتایج به شرح زیر بیان می گردد:

با عنایت به حجم بالای نتایج در این تحقیق، تلاش شد با رعایت اختصار و دسته بندی مناسب نتایج ارائه گردد. جدول زیر نشان دهنده حجم داده های مورد استفاده در هر یک از مدل ها می باشد.

برای تعیین دقت داده های پیش بینی استفاده می شود. خروجی رابطه مربوط به این معیار، همواره یک عدد بین بازه ۰ تا ۱ را نمایش می دهد و هر چه به عدد ۱ نزدیکتر باشد، نشان دهنده دقت بالاتر در پیش بینی است. مجذور میانگین مربعات خطا از رابطه زیر محاسبه می شود.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{1}{n} (Y_i - \hat{Y}_i)^2} \quad [12]$$

RMSE نشان دهنده آماره جذر میانگین مربعات خطا بوده و  $n$  تعداد کل داده های جامعه آماری می باشد و  $Y_i$  یک داده در سری زمانی و  $\hat{Y}_i$  مقدار داده پیش بینی در هر مرحله می باشد.

برای کنترل عملکرد مدل های آموزش ماشین شاخص KGE<sup>۱</sup> وجود دارد که می توان از آن به عنوان یک معیار برای ارزیابی دقت مدل های پیش بینی هیدرولوژیکی استفاده کرد. این شاخص از ترکیب دقت<sup>۲</sup>، قابلیت اطمینان<sup>۳</sup> و تغییرپذیری<sup>۴</sup> در پیش بینی های هیدرولوژیکی برای یک سری زمانی یا مکانی استفاده می کند. بخش های اصلی این شاخص را می توان به ترتیب زیر توضیح داد:

اولاً قابلیت اطمینان که بیانگر میزان توانایی مدل در باز تولید مقادیر واقعی داده ها است. دوماً دقت که نشان دهنده توانایی مدل در پیش بینی تغییرات داده ها است و در نهایت تغییر پذیری توانایی مدل در باز تولید تغییرات مقیاس داده ها است.

با ترکیب این سه مؤلفه، شاخص KGE به عنوان یک

جدول ۵- تعداد داده های مورد استفاده در هر روش.

عنوان	بدون حذف	ماهالانویس	زد- اسکور	مقطعی
آموزش	۱۵۸۹	۱۳۷۴	۱۵۷۰	۱۳۸۹
آزمون	۳۴۱	۲۹۵	۳۶۶	۳۰۰

<sup>4</sup> Bias Ratio

<sup>5</sup> Bias Term

<sup>1</sup> Kling-Gupta Efficiency

<sup>2</sup> Sharpness

<sup>3</sup> Reliability

اعتبار سنجی	۳۴۱	۲۹۵	۳۶۶	۳۰۰
تمام داده‌ها	۲۲۷۱	۱۹۶۴	۲۲۴۲	۱۹۹۸

آنچه در جدول ۶ درج شده حاصل بررسی آماره‌های خطا در بین نتایج مدل‌های تولید شده در هر سه مرحله

جدول ۶ - ارزیابی آماره‌های خطا در مدل‌ها.

سناریو	آموزش				اعتبار سنجی				آزمون				مدل
	RMSE	MAE	KEG	R <sup>2</sup>	RMSE	MAE	KEG	R <sup>2</sup>	RMSE	MAE	KEG	R <sup>2</sup>	GRU
1	6.23	2.86	0.70	0.91	4.21	2.54	0.81	0.81	7.21	3.79	0.52	0.31	LSTM
2	14.42	5.73	0.21	0.43	13.72	5.82	-1.10	0.37	22.46	10.78	-1.44	0.12	
3	5.41	2.37	0.99	0.80	8.17	3.42	0.79	0.89	5.01	2.27	0.68	0.80	
4	7.67	2.54	0.32	0.79	12.52	6.61	0.40	0.25	22.21	19.14	-0.90	0.04	
5	8.11	3.15	0.39	0.96	9.33	3.92	0.21	0.26	28.44	12.37	-0.70	0.32	
6	8.29	3.47	0.25	0.45	10.62	4.01	0.34	0.29	29.73	16.01	-0.62	0.05	
7	8.84	3.71	0.78	0.55	18.21	9.45	0.29	0.56	31.42	14.23	-1.90	0.38	
8	9.40	3.99	0.31	0.69	17.69	8.12	-0.27	0.28	28.86	18.12	-1.50	0.11	

منفی را نشان می‌دهند که نشان دهنده تناسب ضعیف و حتی عملکرد نامناسب مدل است.

- ضریب تعیین (R<sup>2</sup>): باز هم مشاهده می‌شود که در سناریوهای ۱، ۳ و ۶ دارای مقادیر R<sup>2</sup> مناسبی هستند. اما در سناریوهای ۲، ۴، ۵، ۷ و ۸ مقادیر R<sup>2</sup> کمتری را نشان می‌دهند که به معنای عملکرد ضعیف‌تر مدل است. به طور خلاصه، به نظر می‌رسد سناریوی ۳ در تمام معیارها عملکرد خوبی دارد. سناریو ۲ عملکرد ضعیفی دارد، به خصوص در هنگام آزمون. سناریوهای ۱، ۵، ۶ و نتایج معقولی را نشان می‌دهند. سناریوهای ۴، ۷ و ۸ به دلیل خطاهای بیشتر مورد پذیرش نمی‌باشند.

مقایسه نتایج عملکرد تمامی سناریوهای مدل LSTM در مقایسه با تحقیقات نیفا و همکاران (۲۰۲۳) که از روش LSTM برای پیش‌بینی جریان رودخانه استفاده کرده است، نشان می‌دهد مدل‌های تولید شده در تحقیق حاضر کمتر موثر بوده و در بیشتر موارد به احتمال زیاد مساله بیش‌برازش و کم‌برازش حاصل شده است (KEG منفی شده است). به نظر می‌رسد این اتفاق به دو

- ریشه میانگین مربعات خطا (RMSE): در خصوص این آماره خطا، می‌توان گفت که برای سناریوی ۱، مقادیر RMSE در تمام مراحل (آموزش، اعتبارسنجی و آزمایش) معقول هستند. در سناریو ۲، RMSE به طور قابل توجهی بالا است، به خصوص در مرحله آزمون و سناریوهای ۳، ۴، ۵، ۶، ۷ و ۸ مقادیر متفاوت بوده و دائماً کم و زیاد شده است.

- میانگین خطای مطلق (MAE): این آماره خطا در سناریوهای ۱، ۳، ۵ و ۶ نتایج نسبتاً مطلوبی داشته است و در سناریوهای ۲، ۴، ۷ و ۸ مقادیر بالاتری را نشان می‌دهد که مطلوب نمی‌باشد.

- بازده کلینگ-گوپتا (KGE): از آنجا که KGE تناسب بین داده‌های مشاهده شده و پیش‌بینی شده را ارزیابی می‌کند. مقادیر مثبت KGE نشان دهنده عملکرد مطلوب و بدون بیش‌برازش و کم‌برازش مدل بوده است. بنابراین می‌توان گفت که سناریوهای ۱ و ۳ دارای مقادیر KGE مثبت هستند که نشان دهنده عملکرد معقول مدل است. اما سناریوهای ۲، ۴، ۵، ۷ و ۸ مقادیر KGE

LSTM و GRU بوده است. همانطور تحقیقات گذشته نشان داده این منطقه کوهستانی با شرایط اقلیمی خاص و توپوگرافی با تغییرات ارتفاعی شدید می باشد و خطرات سیلاب می تواند عوارض جانی و مالی جبران ناپذیری همچون گذشته داشته باشد. تاکنون با استفاده از داده های بومی اندازه گیری جریان رودخانه پیش بینی جریان آب کشکان به روش آموزش عمیق GRU انجام نشده است و برای اولین بار این روش اعمال شد و نتایج حاصله نشان داد با انجام پیش پردازش مناسب از داده ها و تولید مدل صحیح می توان با دقت مناسبی سیلاب های آتی را پیش بینی کرد. به طور خلاصه نتایج این تحقیق نشان داد به کار گیری روش Z-Score در حذف داده های پرت می تواند در تقریب این سیلاب ها موثر باشد، هر چند اعلام دقیق سیلاب های حدی پس از انجام یک پیش بینی آموزش عمیق نیز برای دوره ای از زمان که بازگشت سیلاب های شدید کوتاهتر از قبل شده به طور کامل بعید به نظر می رسد، اما سیستم های اعلام هشدار که براساس تحقیق حاضر یا تحقیقات مشابه آتی تولید گردند، می توانند در جهت ایجاد آمادگی و حداقل کردن خسارات ممکنه موثر واقع گردند.

دلیل عمده رخ داده است. اولاً رودخانه ای که در مطالعه حاضر استفاده شده رفتارهای حدی بیشتری در سابقه دبی خود دارد. دوماً تعداد داده های مورد استفاده و در دسترس در مقایسه با داده های ایشان کمتر بوده است و در چنین شرایطی مدل GRU بهتر عمل کرده است. اگر چه رفتارهای حدی همچنان شرایطی را ایجاد می کند که در خصوص هیچکدام از سناریوها در دو مدل به صورت قطعی اظهار نظر کرد، اما KGE مثبت مرحله آزمون در کنار مقادیر نسبی پایین خطا و در محدوده مطالعاتی که توسط نیفا و همکاران (۲۰۲۳) انجام شده است. همگی نشان از این موضوع دارد که سناریوهای شماره ۱ و ۳ در مدل GRU می توانند بهتر عمل کنند و به نظر می رسد در صورتی که در مطالعات آتی از حجم داده های بیشتر در کنار تنوع داده های موثر مرتبط بیشتر استفاده شود بتوان مدلی قابل اعتمادتر تولید کرد.

### نتیجه گیری کلی

همانطور که پیشتر توضیح داده شد در تحقیق حاضر مسئله اصلی پیشنهاد مدلی پیش بینی کننده برای جریان روزانه رودخانه با استفاده از مقایسه بین مدل های

### منابع مورد استفاده

- Adriano de Melo G, Sugimoto DN, Tasinaffo PM, Moreira Santos AH, Cunha AM and Vieira Dias LA, 2019. A new approach to river flow forecasting: LSTM and GRU multivariate models. *IEEE Latin America Transactions* 17(12):1978–1986. <https://ieeexplore.ieee.org/document/9011542>
- Ch S, Anand N, Panigrahi BK and Mathur S, 2013. Streamflow forecasting by SVM with quantum behaved particle swarm optimization. *Neurocomputing* 101:18–23. <https://linkinghub.elsevier.com/retrieve/pii/S0925231212005838>
- Cho K, Van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H and Bengio Y, 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. Pp.1724–1734. *Proceedings of the EMNLP 2014 - Conference on Empirical Methods in Natural Language Processing*.
- Choi J, Won J, Jang S and Kim S, 2022. Learning enhancement method of long short-term memory network and its applicability in hydrological time series prediction. *Water* 14(18):2910. <https://www.mdpi.com/2073-4441/14/18/2910>
- Collura T and Tarrant J, 2020. Principles and statistics of individualized live and static Z-Scores. *Neuro Regulation* 7(1):45–55. <https://www.neuroregulation.org/article/view/19753>
- Funk C, Peterson P, Landsfeld M, Pedreros D, Verdin J, Shukla S, Husak G, Rowland J, Harrison L, Hoell A and Michaelsen J, 2015. The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. *Scientific Data*. Nature Publishing Group 2(1):1–21. <https://www.nature.com/articles/sdata201566>

- Geravand F, Hosseini SM and Ataie-Ashtiani B, 2020. Influence of river cross-section data resolution on flood inundation modeling: Case study of Kashkan river basin in western Iran. *Journal of Hydrology* 584,124743. <https://doi.org/10.1016/j.jhydrol.2020.124743>
- Gers FA, 1999. Learning to forget: continual prediction with LSTM. 9th International Conference on Artificial Neural Networks: ICANN '99. IEE, 850–855. [https://digital-library.theiet.org/content/conferences/10.1049/cp\\_19991218](https://digital-library.theiet.org/content/conferences/10.1049/cp_19991218)
- Gessesse AA and Melesse AM, 2019. Temporal relationships between time series CHIRPS-rainfall estimation and eMODIS-NDVI satellite images in Amhara Region, Ethiopia. *Extreme Hydrology and Climate Variability: Monitoring, Modelling, Adaptation and Mitigation*. Elsevier 81–92
- Hochreiter S and Schmidhuber J, 1997. Long Short-Term Memory. *Neural Computation* 9(8):1735–1780. <https://direct.mit.edu/neco/article/9/8/1735-1780/6109>
- Hosseini FS, Sigaroodi SK, Salajegheh A, Moghaddamnia A and Choubin B, 2021. Towards a flood vulnerability assessment of watershed using integration of decision-making trial and evaluation laboratory, analytical network process, and fuzzy theories. *Environmental Science and Pollution Research* 28(44):62487–62498. <https://link.springer.com/10.1007/s11356-021-14534-w>
- Hunt KMR, Matthews GR, Pappenberger F and Prudhomme C, 2022. Using a long short-term memory (LSTM) neural network to boost river streamflow forecasts over the western United States. *Hydrology and Earth System Sciences* 26(21):5449–5472. <https://hess.copernicus.org/articles/26/5449/2022/>
- Islam AS, 2010. Improving flood forecasting in Bangladesh using an artificial neural network. *Journal of Hydroinformatics* 12(3):351–364. <https://iwaponline.com/jh/article/12/3/351/3040/>
- Ismail Fawaz H, Forestier G, Weber J, Idoumghar L and Muller PA, 2019. Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery* 33(4):917–963. <https://link.springer.com/10.1007/s10618-019-00619-1>
- Javadinejad S, Dara R and Jafary F, 2020. Examining the association between dust and sediment and evaluating the impact of climate change on dust and providing adaptation. *Resources Environment and Information Engineering* 2(1):61–70. <https://www.syncsci.com/journal/index.php/REIE/article/view/470>
- Karamvand A, Hosseini SA and Sharafati A, 2022. SMAP products for prediction of surface soil moisture by ELM network model and agricultural drought index. *Acta Geophysica*. Springer International Publishing. <https://doi.org/10.1007/s11600-022-00973-7>
- Kingma DP and Ba JL, 2015. Adam: A method for stochastic optimization. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, 1–15
- Kratzert F, Klotz D, Brenner C, Schulz K and Herrnegger M, 2018. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. *Hydrology and Earth System Sciences* 22(11):6005–6022. <https://hess.copernicus.org/articles/22/6005/2018/>
- Lance VP and Digiacomo PM, 2019. NOAA Coastwatch/Oceanwatch/Polarwatch: A bridge from ocean satellite data to applications and information. OCEANS 2019 MTS/IEEE Seattle, OCEANS 2019. Institute of Electrical and Electronics Engineers Inc.
- Le Ho, Lee and Jung, 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water* 11(7):1387. <https://www.mdpi.com/2073-4441/11/7/1387>
- Le X-H, Nguyen D-H, Jung S, Yeon M and Lee G, 2021. Comparison of Deep Learning Techniques for River Streamflow Forecasting. *IEEE Access* 9:71805–71820. <https://ieeexplore.ieee.org/document/9423961/>
- Nagesh Kumar D, Srinivasa Raju K and Sathish T, 2004. River Flow Forecasting using Recurrent Neural Networks. *Water Resources Management* 18(2):143–161. <http://link.springer.com/10.1023/B:WARM.0000024727.94701.12>
- Nifa K, Boudhar A, Ouatiki H, Elyoussfi H, Bargam B and Chehbouni A, 2023. Deep learning approach with LSTM for daily streamflow prediction in a semi-arid Area: A case study of Oum Er-Rbia River Basin, Morocco. *Water* 15(2):262. <https://www.mdpi.com/2073-4441/15/2/262>
- Reis GB, da Silva DD, Fernandes Filho EI, Moreira MC, Veloso GV, Fraga M de S and Pinheiro SAR, 2021. Effect of environmental covariable selection in the hydrological modeling using machine learning models to predict daily streamflow. *Journal of Environmental Management* 290:112625. <https://linkinghub.elsevier.com/retrieve/pii/S0301479721006873>
- Rodell M, Houser PR, Jambor U, Gottschalck J, Mitchell K, Meng CJ, Arsenault K, Cosgrove B, Radakovich J, Bosilovich M and Toll D, 2004. The Global Land Data Assimilation System. *Bulletin of*

- the American Meteorological Society. *American Meteorological Society* 85(3):381–394.  
<https://journals.ametsoc.org/view/journals/bams/85/3/bams-85-3-381.xml>
- Sánchez N, González-Zamora Á, Piles M and Martínez-Fernández J, 2016. A new soil moisture agricultural drought index (SMADI) Integrating MODIS and SMOS products: A case of study over the Iberian Peninsula. *Remote Sensing* 8(4):287. <http://www.mdpi.com/2072-4292/8/4/287>
- Savitzky A and Golay MJE, 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*. American Chemical Society 36(8):1627–1639.  
<https://pubs.acs.org/doi/abs/10.1021/ac60214a047>
- Sharma P and Machiwal D, 2021. *Advances in Streamflow Forecasting*. *Advances in Streamflow Forecasting*. Elsevier. <https://linkinghub.elsevier.com/retrieve/pii/C20190021632>
- Shewalkar A, Nyavanandi D and Ludwig SA, 2019. Performance evaluation of deep neural networks Applied to speech recognition: RNN, LSTM and GRU. *Journal of Artificial Intelligence and Soft Computing Research* 9(4):235–245. <https://www.sciendo.com/article/10.2478/jaiscr-2019-0006>
- Staudemeyer RC and Morris ER, 2019. Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks. 1–42. <http://arxiv.org/abs/1909.09586>
- Teng W, Rui H, Strub R and Vollmer B, 2016. Optimal Reorganization of NASA Earth Science Data for Enhanced Accessibility and Usability for the Hydrology Community. *Journal of the American Water Resources Association*, 825–835
- Uchida T, Kosugi K and Mizuyama T, 2002. Effects of pipe flow and bedrock groundwater on runoff generation in a steep headwater catchment in Ashiu, central Japan. *Water Resources Research* 38(7).  
<https://agupubs.onlinelibrary.wiley.com/doi/10.1029/2001WR000261>
- van Kuppevelt D, Meijer C, Huber F, van der Ploeg A, Georgievska S and van Hees VT, 2020. Mcfly: Automated deep learning on time series. *SoftwareX* 12:100548.  
<https://linkinghub.elsevier.com/retrieve/pii/S2352711019300202>
- Wang W, Gelder PHAJM Van, Vrijling JK and Ma J, 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology* 324(1–4):383–399.  
<https://linkinghub.elsevier.com/retrieve/pii/S0022169405004981>
- Wegayehu EB and Muluneh FB, 2022. Short-Term Daily Univariate Streamflow Forecasting Using Deep Learning Models. *Advances in Meteorology*.
- Wei S, Zuo D and Song J, 2012. Improving prediction accuracy of river discharge time series using a Wavelet-NAR artificial neural network. *Journal of Hydroinformatics* 14(4):974–991.  
<https://iwaponline.com/jh/article/14/4/974/3201/>.
- Winter TC, 2007. The Role of Ground Water in Generating Streamflow in Headwater Areas and in Maintaining Base Flow 1. *JAWRA Journal of the American Water Resources Association* 43(1):15–25.  
<https://onlinelibrary.wiley.com/doi/10.1111/j.1752-1688.2007.00003.x>
- Yafouz A, Ahmed AN, Zaini N, Sherif M, Sefelnasr A and El-Shafie A, 2021. Hybrid deep learning model for ozone concentration prediction: comprehensive evaluation and comparison with various machine and deep learning algorithms. *Engineering Applications of Computational Fluid Mechanics* 15(1):902–933. <https://www.tandfonline.com/doi/full/10.1080/19942060.2021.1926328>
- Zealand CM, Burn DH and Simonovic SP, 1999. Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology* 214(1–4):32–48.  
<https://linkinghub.elsevier.com/retrieve/pii/S002216949800242X>
- Zounemat-Kermani M, 2014. Principal component analysis (pca) for estimating chlorophyll concentration using forward and generalized regression neural networks. *Applied Artificial Intelligence* 28(1):16–29.  
<http://www.tandfonline.com/doi/abs/10.1080/08839514.2014.862771>