



University of Tehran Press

ECO HYDROLOGY


Home Page: <https://ije.ut.ac.ir>

Online ISSN: 2423-6101

Efficiency of time series simulation of daily inflow to dams in Kerman province using deep learning, Case study: (Jiroft and Nesa Dams)

Armin Shahrokhi¹,  Nasrin Sayari^{2*}, 

1. Master's degree in Water Resources Engineering, Department of Water Science and Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran. Email: arminshahrokhi@agr.uk.ac.ir
2. Assistant Professor, Department of Water Science and Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran. Email: na_sa@uk.ac.ir

Article Info	ABSTRACT
<p>Article type: Research Article</p> <p>Article history: Received 29 December 2025 Revised 01 February 2026 Accepted 13 March 2026 Available online 21 March 2026</p> <p>Keywords: Deep Learning, GRU, LSTM, Recurrent neural network, Time Series.</p>	<p>Analyzing temporal and spatial changes in precipitation, temperature, and surface runoff is essential for water resources discussions and long-term forecasts for watershed management. Therefore, the aim of this study was to model the time series of inflow discharge to Jiroft and Nesa dams under different climatic conditions. For this purpose, two LSTM and GRU models were used in Jiroft and Nesa dams over a period of 25 and 12 years in the Python program environment. Based on the output results, the model is in its best state when it has reached the convergence point. Based on the output results, the model is in its best state when it has reached the convergence point. In the Jiroft Dam LSTM model, the RMSE criteria for training and testing the model were 0.72 and 0.78, respectively, and the MAE values were 0.10 and 0.12, respectively. These values in the GRU model were 0.94, 1.02, 0.15, and 0.20, respectively. Also, in the Nesa Dam in the LSTM model, the RMSE criteria for training and testing the model were 0.11 and 0.10, respectively, and the MAE values were 0.05 and 0.04, respectively. These values in the GRU model were 0.01, 0.09, 0.04, and 0.03, respectively. Also, by planning, it is possible to prevent damage from the dam outlet downstream and to drain and control possible floods as much as possible.</p>
<p>Cite this article: Shahrokhi, A., Sayari, N. (2026). Efficiency of time series simulation of daily inflow to dams in Kerman province using deep learning, Case study: (Jiroft and Nesa Dams). <i>Journal of ECOHYDROLOGY</i>, 13(1), 1106-1123. https://doi.org/10.22059/ije.2025.398750.1879</p>	
<p> © Armin Shahrokhi, Nasrin Sayari. Publisher: University of Tehran Press.</p>	
<p>DOI: https://doi.org/10.22059/ije.2025.398750.1879</p>	

Abstract

Introduction

Predicting the inflow to dam reservoirs is one of the key requirements for reliable water resources planning and operation. Temporal variability of precipitation and streamflow in different climatic conditions, together with increasing water demand, has intensified the need for accurate inflow forecasts to support reservoir operation, flood control, and drought management. This study aims to evaluate the efficiency of deep learning models in simulating the daily inflow time series to Jiroft and Nesa dams in Kerman Province (southeastern Iran) under different climatic conditions by comparing the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) networks.

Method

The case study includes the Jiroft and Nesa dams, located in the south of Kerman Province, Iran, where the Halil-Rud River constitutes the main inflow to the reservoir in the Jiroft dam. Daily inflow data for a period of 25 years for Jiroft Dam and 12 years for Nesa Dam were obtained from the Regional Water Company of Kerman. The data were checked for missing values and outliers and then normalized prior to modeling. The available time series were divided into training and testing subsets to evaluate the generalization ability of the models.

Two recurrent deep learning architectures, LSTM and GRU, were implemented in a Python environment. The models were trained using backpropagation through time with appropriate network depth and number of units, and early stopping was applied as a regularization technique to prevent overfitting once the convergence point was reached. Model performance was assessed using the Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) criteria for both training and testing phases in each dam.

Results

The results confirmed that both LSTM and GRU networks are capable of accurately simulating the daily inflow time series to the studied dams, with small errors in both training and testing phases. In the Jiroft Dam LSTM model, RMSE values for training and testing were 0.72 and 0.78, respectively, while the corresponding MAE values were 0.10 and 0.12. For the Jiroft GRU model, RMSE values were 0.94 and 1.02 and MAE values were 0.15 and 0.20 for training and testing, respectively, indicating the superior performance of LSTM in this dam.

In Nesa Dam, the LSTM model achieved RMSE values of 0.11 and 0.10 and MAE values of 0.05 and 0.04 in the training and testing phases, respectively. The GRU model in Nesa Dam yielded RMSE values of 0.01 and 0.09 and MAE values of 0.04 and 0.03 for training and testing, respectively. These results show that, unlike Jiroft Dam, the GRU network slightly outperformed LSTM in Nesa Dam. Overall, the magnitude of the error indices reflects the high capability of deep learning models in capturing the nonlinear dynamics of inflow time series in the study area.

Conclusions

The findings of this research highlight the effectiveness of deep learning approaches, specifically LSTM and GRU networks, in modeling and simulating daily inflow to dams located in regions with variable climatic conditions. The comparative analysis showed that LSTM performs better for Jiroft Dam, while GRU provides slightly better results for Nesa

Dam. This suggests that the choice of model architecture should be tailored to the hydrological and climatic characteristics of each basin. The accurate simulation of inflow time series can support more reliable reservoir operation, assist in planning optimal water allocation among competing demands, and help reduce the risks associated with floods and droughts downstream of the dams.

Author Contributions

Armin Shahrokhi: data collection, model development, analysis of results, and preparation of the initial draft of the extended abstract. Nasrin Sayari: study design, scientific supervision, critical review, and final editing of the extended abstract. Both authors read and approved the final version of the manuscript.

Data Availability Statement

The hydrological data used in this study were obtained from the Regional Water Company of Kerman. Due to institutional restrictions, the data are not publicly available but can be provided by the corresponding author upon reasonable request.

Acknowledgements

This extended abstract is derived from a broader research project on forecasting the time series of inflow to the dams of Kerman Province under different climatic and hydrological conditions. The authors appreciate the support of the Regional Water Company of Kerman and the Planning Deputy of the organization for providing data and facilities.

Ethical considerations

This study used secondary hydrological data and did not involve human or animal subjects. Therefore, no specific ethics approval was required. The authors adhered to general principles of research ethics, including honesty in data analysis and accurate reporting of results.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors and was carried out using the authors' institutional and personal resources.

Conflict of interest

The authors declare that there is no conflict of interest regarding the publication of this extended abstract.

کارایی شبیه‌سازی سری زمانی جریان روزانه ورودی به سدهای استان کرمان با استفاده از یادگیری عمیق مطالعه موردی: (سدهای جیرفت و نساء)

آرمین شاه‌رخی^۱، نسرين سياري^{۲*}

۱. دانش‌آموخته کارشناسی ارشد مهندسی منابع آب، بخش علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، رایانامه: arminshahrokh@agr.uk.ac.ir
۲. استادیار، بخش علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، رایانامه: na_sa@uk.ac.ir

چکیده	اطلاعات مقاله
تحلیل تغییرات زمانی و مکانی بارش، دما و همچنین، آبدهی سطحی در مباحث منابع آب و پیش‌بینی‌های بلندمدت برای مدیریت حوضه آبخیز امری ضروری است. از این‌رو هدف از این مطالعه، مدل‌سازی سری زمانی دبی ورودی به سدهای جیرفت و نساء در شرایط مختلف آب‌وهوایی بود. به این‌منظور، از دو مدل LSTM و GRU در سدهای جیرفت و نساء طی بازه زمانی ۲۵ و ۱۲ سال در محیط برنامه Python استفاده شد. براساس نتایج حاصل از خروجی، مدل زمانی در بهترین حالت خود قرار دارد که به نقطه همگرایی رسیده است. در سد جیرفت مدل LSTM، معیارهای RMSE، برای آموزش و آزمون مدل به ترتیب ۰/۷۲ و ۰/۷۸ و مقادیر MAE به ترتیب ۰/۱۰ و ۰/۱۲ بود. این مقادیر در مدل GRU به ترتیب ۰/۹۴ و ۱/۰۲ و ۰/۱۵ و ۰/۲۰ بود. همچنین در سد نساء در مدل LSTM، معیارهای RMSE، برای آموزش و آزمون مدل به ترتیب ۰/۱۱ و ۰/۱۰ و مقادیر MAE به ترتیب ۰/۰۵ و ۰/۰۴ بود. این مقادیر در مدل GRU به ترتیب ۰/۱۰ و ۰/۰۹ و ۰/۰۴ و ۰/۰۳ بود. همچنین، می‌توان با برنامه‌ریزی از ایجاد خسارت‌های ناشی از خروجی سد در پایین‌دست و تخلیه و مهار سیلاب‌های احتمالی در حد امکان جلوگیری کرد.	<p>نوع مقاله: پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۴/۱۰/۰۸</p> <p>تاریخ بازنگری: ۱۴۰۴/۱۱/۱۲</p> <p>تاریخ پذیرش: ۱۴۰۴/۱۲/۲۲</p> <p>تاریخ انتشار: ۱۴۰۵/۰۱/۰۱</p> <p>کلیدواژه‌ها: سری زمانی، شبکه عصبی بازگشتی، یادگیری عمیق، GRU، LSTM</p>

استاد: شاه‌رخی، آرمین؛ سیاری، نسرين. کارایی شبیه‌سازی سری زمانی جریان روزانه ورودی به سدهای استان کرمان با استفاده از یادگیری عمیق مطالعه موردی: (سدهای جیرفت و نساء). مجله اکوهیدرولوژی، ۱۳(۱)، ۱۱۰۶ - ۱۱۲۳. <https://doi.org/10.22059/ije.2025.398750.1879>



مقدمه

پیش‌بینی جریان ورودی به مخزن سدها، یکی از مسائل مهم در برنامه‌ریزی و مدیریت بهینه آن‌ها برای تولید انرژی‌های پاک نظیر انرژی برق‌آبی و تخصیص آب به منابع مصرف‌گوناگون، به حساب می‌آید. شناخت و تحلیل نوسانات زمانی و مکانی بارش، دما، رواناب و آب‌های سطحی در مباحث منابع آب، هیدرولوژی و پیش‌بینی‌های بلندمدت برای مدیریت حوضه آبخیز بسیار بااهمیت است. از بااهمیت‌ترین روش‌های مهار و نگهداشت منابع آبی، احداث سد است. کمبود منابع آب شیرین در ایران، استحصال غیراستاندارد آب‌های زیرزمینی، عدم توانایی در مهار آب‌های سطحی و جاری، افزایش آلاینده‌گی منابع آب ناشی از پساب‌های خانگی، کشاورزی، صنعتی و غیره و نبود برنامه هدفمند و بلندمدت در مدیریت منابع آب را می‌توان به عنوان چالش‌های مهم مدیریت پایدار منابع آب در ایران معرفی کرد (سازمان مدیریت و برنامه‌ریزی کشور، ۱۳۸۴). مطابق مطالعه شفافی بجستانی (۱۹۹۹) روزنبلات^۱ (۲۰۰۱) اولین کارایی عملی شبکه‌های عصبی مصنوعی را هم‌زمان با معرفی شبکه پرسپترون مطرح کرد. روزنبلات شبکه‌ای ایجاد کرد که توانایی تشخیص الگوها را از یکدیگر داشت. طی پژوهشی، فتحی و همکاران (۲۰۰۹) برای مدل‌سازی هوشمند سری زمانی آورد ماهانه ورودی به سد وحدت سندانج از روش‌های شبکه عصبی مصنوعی، شبکه استاتیکی و پارامترهای ارتباط غیرخطی بین متغیرهای مستقل و وابسته استفاده کردند. سپس، براساس طراحی انجام‌شده و بسط مدل شبکه عصبی دینامیکی بر مبنای کارکرد سری زمانی، توانستند مقدار آورد ماهانه ورودی به سد را پیش‌بینی کنند. نتایج پژوهش آن‌ها نشان داد انطباق خوبی بین مقادیر پیش‌بینی‌شده با شبکه‌های عصبی ترکیبی و داده‌های مشاهداتی وجود دارد. همچنین، مدل شبکه عصبی دینامیکی سری زمانی با دقت بیشتری نسبت به مدل استاتیکی، مقدار آورد ماهانه را پیش‌بینی کرد. بهارلو (۱۳۸۸) در مطالعه‌ای به پیش‌بینی سری زمانی با وابستگی‌های بلندمدت با استفاده از شبکه عصبی بازگشتی پرداخت. نتایج پژوهش ایشان نشان داد مدل‌های خودبرگشتی غیرخطی با ورودی‌های برون‌زاد نارکس^۲ حساسیت کمتری به وابستگی‌های درازمدت دارند و می‌توان میرا شدن گرادیان خطا را در آن‌ها به تأخیر انداخت و نارکس توانایی یادگیری و فراگیر شدن بهتری از خود نشان داد. در مطالعه‌ای دیگر، انوری (۲۰۱۸) مدلی را به منظور پیش‌بینی جریان ورودی به مخزن سد جیرفت ارائه کرد. او برای پیش‌بینی سناریوهای احتمالاتی جریان یک تا دوازده ماه آینده هلیل‌رود از مدل جریان ESP و مدل‌های شبکه عصبی مصنوعی ANNs استفاده کرد. در ادامه، برای پیش‌بینی‌های تجمعی جریان با مدل‌های ANN^۳ از داده‌های هواشناسی و هیدرولوژیکی حوضه هلیل‌رود بهره برد و سپس از این پیش‌بینی‌ها نیز برای جریان با رویکرد ESP^۴ مصنوعی استفاده کرد. نتایج پژوهش یادشده نشان داد با افزایش بازه زمانی، پیش‌بینی دقت نتایج بر اساس مقیاس ماهانه تا سالانه کاهش می‌یابد. همچنین، از ترکیب مدل‌های ANN با رویکرد ESP مصنوعی، می‌توان سناریوهای احتمالاتی جریان را به‌خوبی پیش‌بینی کرد. صمدی و فتح‌آبادی (۲۰۱۹) در پژوهشی برای پیش‌بینی مقادیر دبی ماهانه ورودی به سد گرگان از داده‌های هیدرومتری ایستگاه قزاقلی با دوره آماری ۴۷ ساله، از روش‌های مدل‌سازی مانند سری زمانی، شبکه عصبی و ماشین بردار پشتیبان بهره گرفتند. نتایج به‌دست‌آمده از این مدل‌ها نشان داد مدل سری زمانی بر اساس معیارهای آکایک و شوارتز، مدل (۱,۰,۱) (۱,۰,۰) ARIMA به عنوان بهترین مدل بهینه‌شده است. مقادیر RMSE و AARE برای مدل ماشین بردار پشتیبان به ترتیب ۵/۳۱ و ۱/۰۷، برای مدل شبکه عصبی به ترتیب ۹/۸۸ و ۲/۷۸ و برای مدل سری زمانی به ترتیب ۸/۸۴ و ۱/۲۰ به دست آمد. با توجه به خروجی‌های پژوهش، مدل ماشین بردار پشتیبان بهترین مدل برای پیش‌بینی دبی ماهانه ورودی به سد گرگان بود. در مطالعه‌ای احمدی و همکاران (۲۰۲۰) برای پیش‌بینی دبی متوسط ماهانه رودخانه کارون نوعی رویکرد ترکیبی

1. Frank Rosenblatt
2. Narex
3. Artificial Neural Network
4. Ensemble Streamflow Prediction

ارائه دادند که در آن از ترکیب شبکه‌های عصبی LSTM^۱ و GRU^۲ استفاده شده بود. این مدل شامل دروازه‌های زیادی بود که سبب کندی عملکرد این شبکه می‌شد و برای رفع این نقص، از لایه‌های GRU استفاده کردند. در این مطالعه از داده‌های آماری ایستگاه ملائانی برای دوره ۲۱ ساله (از ۱۳۷۴ تا ۱۳۹۴) به منظور پیش‌بینی دبی متوسط ماهیانه رودخانه کارون استفاده شد و مدل‌سازی با مقادیر دبی رودخانه با تأخیر یک‌ماهه مبتنی بر پنج مدل ترکیبی ورودی انجام گرفت. نتایج حاصل از پژوهش یادشده نشان داد با مقایسه مدل پیشنهادی با مدل‌های دیگر مانند ماشین بردار پشتیبان، سیستم استنتاج فازی - عصبی تطبیقی و مدل رگرسیون خطی چندگانه، مدل پیشنهادی نسبت به سایر روش‌های مقایسه‌شده دقت بسیار زیادی داشت. مؤمنه (۲۰۲۲) مدل‌سازی جریان برای حوضه آبریز رودخانه گاماسیاب، واقع در غرب ایران را مورد بررسی و مطالعه قرار داد. برای این منظور، مؤمنه از مدل‌های هوش مصنوعی AI شامل، مدل‌های شبکه عصبی مصنوعی ANN از نوع پرسپترون چندلایه MLP^۳ شبکه عصبی تابع پایه شعاعی RBF^۴ و مدل حافظه طولانی کوتاه‌مدت LSTM استفاده کرد. نتایج پژوهش یادشده براساس معیار NSE برای مدل‌های LSTM، RBF، ANN، در دوره صحت‌سنجی به ترتیب برابر ۰/۹۳۰، ۰/۹۰۷ و ۰/۹۰۳ بود که نشان داد مدل LSTM عملکرد بهتری در دوره صحت‌سنجی نسبت به سایر مدل‌ها در تخمین دبی جریان ارائه می‌کند. در ضمن، نتایج بیانگر عملکرد بهتر مدل‌های ANN، RBF و LSTM به‌ویژه در نقاط اوج جریان در مدل‌سازی جریان برای منطقه مورد مطالعه بود. در کل، نتایج نشان داد مدل‌های AI، ابزار مفید برای مدل‌سازی نوسان‌های جریان بود. در پژوهشی خلیلی و مریدی (۲۰۲۳) مدل‌های مختلف هوش مصنوعی در فرایندهای تصفیه آب و فاضلاب را ارائه دادند و پس از مرور مطالعات انجام‌شده، چالش‌ها و مشکلات پژوهش‌ها را نیز بیان کردند. با توجه به مزیت‌های فراوان در هوش مصنوعی، این فناوری با محدودیت‌هایی نیز مواجه است که مانع گسترش آن در فرایندهای تصفیه آب می‌شود. با توجه به مدل‌های بررسی‌شده در پژوهش نشان داده شد که استفاده از مدل‌های DNN^۵، ANN و تکنیک‌های هوش مصنوعی ترکیبی گزینه‌های خوبی برای دستیابی به دقت و پیش‌بینی دقیق‌تر هستند. مطابق پژوهش دی (۱۹۸۵) برای پیش‌بینی‌های بلندمدت جریان که در آن‌ها عدم قطعیت پیش‌بینی درصد بالایی دارد، پیشنهاد شد از یک رویکرد احتمالاتی، که خروجی مدل پیش‌بینی‌شده شامل مقادیر یا دسته‌های مختلفی از جریان رودخانه است، در یک شرایط خاص استفاده شود. یکی از نمونه روش‌های پیش‌بینی احتمالاتی جریان ESP است. ژانگ و گویندرجو (۲۰۰۰) طی پژوهشی با استفاده از روش شبکه عصبی مصنوعی برای پیش‌بینی میزان رواناب ماهانه در سه حوزه با وسعت متوسط در کانزاس آمریکا مورد بررسی قرار دادند. طبق خروجی‌های مدل، مشاهده شد که شبکه پیشنهادی در پیش‌بینی جریان‌های حداقل و متوسط نتایج قابل قبولی ارائه می‌دهد، اما در پیش‌بینی جریان‌ها حداکثر کارایی بالایی نداشتند. براساس نتایج پژوهش فرانک و همکاران (۲۰۰۱) شبکه‌های عصبی بازگشتی توانایی بالقوه خوبی برای پیش‌بینی سری‌های زمانی دارند. اصلی‌ترین ویژگی شبکه عصبی بازگشتی، حالت مخفی آن است که اطلاعات یک توالی را ذخیره می‌کند. همچنین، حتماً نیاز نیست در هر گام زمانی، یک خروجی و یا یک ورودی داشته باشد. دامله و یالچین (۲۰۰۷) در پژوهشی با استفاده از سری‌های زمانی به پیش‌بینی جریان در رودخانه می‌سی‌سی‌پی آمریکا پرداختند. خروجی مدل‌های آن‌ها نشان داد توانایی سری زمانی در ساخت داده‌های دبی روزانه و صحت پیش‌بینی‌های آن بسیار بالا است. طی پژوهشی وانگ و همکاران (۲۰۰۹) با بهره‌گیری از مدل‌های ماشین بردار پشتیبان، الگوریتم ژنتیک و سیستم استنتاج عصبی - تطبیقی فازی اقدام به مدل‌سازی دبی دو رودخانه مانوان و هونگ‌جیادو کردند. مطابق نتایج پژوهش آن‌ها، مدل‌های سیستم استنتاج عصبی - تطبیقی فازی، ژنتیک و ماشین بردار پشتیبان به ترتیب بالاترین سطح عملکرد در راستای داده‌های استفاده‌شده در مراحل آموزش و آزمون را داشتند. در پژوهش

1. Long Short-Term Memory
2. Gated Recurrent Unit
3. Multilayer Perceptron
4. Radial Basis Function
5. Deep Neural Networks

ولی‌پور و همکاران (۲۰۱۳) برای مدل‌سازی جریان ماهانه ورودی به مخزن سد دز به کمک مدل‌های آرما، آریما و مدل شبکه عصبی مصنوعی خودهمبسته، مطالعه‌ای صورت گرفت. مطابق خروجی مدل‌ها، هرچه مرتبه مدل‌های سری زمانی افزایش یابد دقت مدل‌سازی بهبود می‌یابد که طبق مطالعه مدل آریما نسبت به آرما جریان ماهانه را با دقت بیشتری پیش‌بینی کرد. در حالت کلی، مدل شبکه عصبی مصنوعی خودهمبسته به شکل مطلوب‌تری نسبت به مدل‌های سری زمانی جریان ورودی ماهانه به سد دز را مدل‌سازی کرد. در مطالعه دیگر زایتر و الامرانی (۲۰۱۶) یک معماری عمیق شبکه عصبی را برای سری‌های زمانی داده‌های هواشناسی ارائه کردند. این روش مبتنی بر شبکه‌های حافظه طولانی کوتاه‌مدت LSTM بود. نتایج پژوهش آن‌ها نشان داد شبکه‌های عصبی بر پایه LSTM نسبت به روش‌های سنتی عملکرد قابل قبولی دارد و می‌توان از این روش به منظور یک روش جامع برای پیش‌بینی شرایط جوی استفاده کرد. در پژوهش خوزه (۲۰۱۸) برای مدل‌سازی جریان رودخانه از روش شبکه عصبی بازگشتی برای محاسبه رابطه بین دبی و عمق جریان استفاده شد. در همین زمینه، مدل پیش‌بینی جریان روزانه با استفاده از سطح آب و دبی با دوره‌های مختلف تأخیر به عنوان ورودی و جریان به عنوان خروجی به دست آمد. بهترین عملکردها برای مدل‌های مختلف به منظور اندازه‌گیری تخلیه‌ها طی دوره اوج باران‌های موسمی مشخص شد. در میان ماه‌های ژوئن، ژوئیه و آگوست، عملکرد مدل نشان داد بیشترین جریان طی ماه ژوئیه در دوره مطالعه شده رخ داده است. در بررسی محمد و همکاران (۲۰۱۹) نوعی مدل ترکیبی برای بررسی دبی جریان ارائه شد که عملکرد نسبی آن با مدل‌های LSTM و GRU و با استفاده از مجموعه داده‌های اطلاعاتی سازمان زمین‌شناسی ایالات متحده USGS مقایسه شد. در این پژوهش داده‌ها شامل ۳۵ سال آبی از ۱۰ حوضه رودخانه MOPEX با حوضه‌های مختلف آب‌وهوایی مورد مطالعه قرار گرفتند. نتایج پژوهش یادشده نشان داد عملکرد مدل ترکیبی تقریباً با GRU در بررسی دبی جریان یکسان بود، اما مدل GRU تا حدودی نتایج قابل قبولی در حوضه‌های مختلف داشت. همچنین، می‌توان گفت که بعضی مدل‌ها فقط برای انواع خاصی از مجموعه داده‌ها به کار گرفته می‌شوند. بخشی استادکالیاه و همکاران (۲۰۲۳) در مطالعه‌ای برای بهبود عملکرد LSTM توسط فیلتر کالمن KF^۱ به منظور پیش‌بینی جریان با شبیه‌سازی براساس سری جریان روزانه ۶۰ساله سد دز مشخص کردند. نتایج پژوهش یادشده نشان داد مدل LSTM-UKFS در پیش‌بینی سیل بسیار مؤثر است، که بیانگر پتانسیل امیدوارکننده یک رویکرد یادگیری عمیق با معماری ساده برای پیش‌بینی سیل‌ها، حتی با وجود سدها در منطقه مطالعه شده بود. اکبری عثمانوندانی و همکاران (۲۰۲۴) در مطالعه‌ای، مقایسه‌ای بین پیاده‌سازی مدل‌های یادگیری ماشین، به‌ویژه روش گروهی مدیریت داده‌ها GMDH، جنگل تصادفی RF و سیستم استنتاج عصبی - فازی تطبیقی ANFIS و روش شبکه بی‌بیزی احتمالی و همچنین، شبکه‌های حافظه کوتاه بلندمدت LSTM انجام دادند. مطالعه آن‌ها مقایسه‌ای بدیع بین دو رویکرد جعبه سیاه ارائه داد که احتمالات را در سه مقیاس زمانی مختلف ماهانه، فصلی و سالانه تجزیه و تحلیل کند. سه رویکرد زمانی برای تخمین میزان جریان ورودی به سد زاینده‌رود، به کار گرفته شد. نتایج به‌دست‌آمده از شبیه‌سازی نشان داد روش GMDH، یک تکنیک شبکه عصبی پیچیده، عملکرد برتر را در هر سه مقیاس زمانی ماهانه، فصلی و سالانه نشان می‌دهد. علاوه بر این، میانگین مربعات خطا MSE برای رویکردهای سالانه، فصلی و ماهانه به ترتیب ۰/۰۷، ۰/۰۹ و ۰/۱۱ بود. نتایج پژوهش یادشده نشان داد جریان ورودی انتقالی از تونل‌های کوه‌رنگ و تونل چشمه لنگان تا حد زیادی بر پیش‌بینی‌ها در هر سه رویکرد تأثیر گذاشته است. سواگاتیکا و همکاران (۲۰۲۴) در مطالعه‌ای، نوعی مدل یادگیری عمیق ترکیبی DL^۲، تبدیل فوریه حافظه طولانی کوتاه‌مدت FT-LSTM، برای بهبود دقت پیش‌بینی سری‌های زمانی تخلیه ماهانه در حوضه رودخانه برهمانی در ایستگاه جناپور^۳ در هندوستان انجام دادند. نتایج پژوهش یادشده نشان داد مدل FT-LSTM از سایر مدل‌ها در تمام دوره‌های تأخیر زمانی از نظر معیارهای خطا بهتر عمل می‌کند. علاوه بر این،

1. Kalman Filter
2. Deep Learning
3. Jenapur

مدل راندمان و مقادیر R^2 بالاتری را از خود نشان داد، که بیانگر تناسب بهتر بین مقادیر رواناب پیش‌بینی شده و واقعی است. مدل FT-LSTM در بهبود دقت پیش‌بینی رواناب ماهانه مؤثر است و راه‌حلی امیدوارکننده برای مدیریت منابع آب و فرایندهای تصمیم‌گیری حوضه رودخانه ارائه می‌دهد. متغیر بودن رژیم بارش و رودخانه‌ها در سال‌های مختلف و احداث آب‌بندها و سدهای مخزنی، با هدف مهار و انتقال آب از دوره‌های ترسالی به دوره‌های خشکسالی صورت گرفته است. مطابق تعاریف صورت‌گرفته در این پژوهش، هدف اصلی طرح کارایی سری زمانی ورودی به سدهای جیرفت و نساء به کمک روش‌های یادگیری عمیق است. مهم‌ترین اهمیتی که برای انجام این پژوهش می‌توان به آن اشاره کرد، دانشی است که به بهره‌بردار داده می‌شود تا بتواند با اطلاعاتی که از میزان ورودی به سد به دست می‌آورد برای رخدادهای آینده برنامه‌ریزی داشته باشد. این پژوهش به منظور پر کردن خلأهای موجود در سایر پژوهش‌ها، به استفاده از روش هوشمند یادگیری عمیق و مدل‌های LSTM و GRU برای امکان‌سنجی و کارایی شبیه‌سازی سری زمانی جریان روزانه مخزن سدهای جیرفت و بم پرداخته شده است.

روش‌شناسی پژوهش

منطقه مورد مطالعه

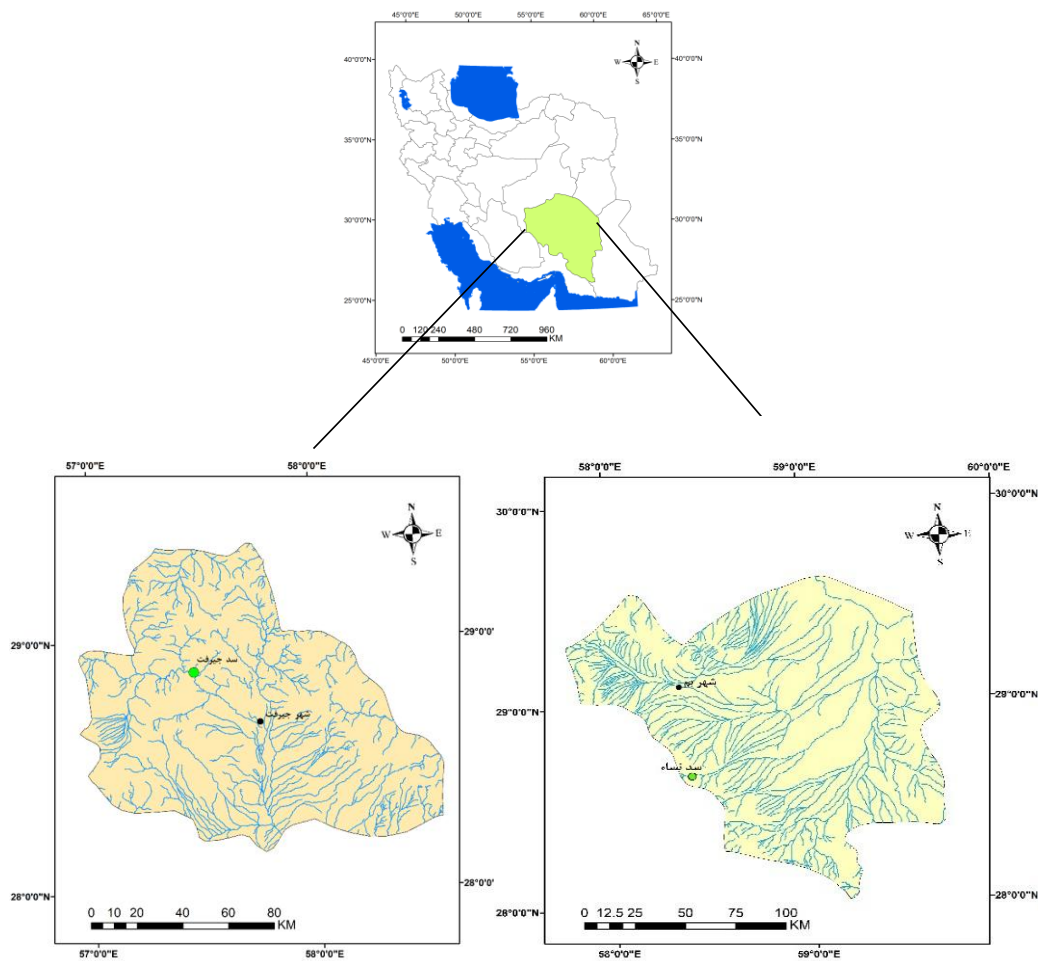
شهرستان جیرفت در جنوب استان کرمان قرار دارد. این شهر در ارتفاع ۷۲۰ متری از سطح دریا است. رودخانه هلیل‌رود به طول حدود ۴۰۰ کیلومتر تنها رود دائمی استان کرمان است که از ارتفاعات شهرستان بافت سرچشمه می‌گیرد و به دریاچه جازموریان می‌ریزد. سد جیرفت، از بزرگ‌ترین سدهای ایران است که روی رودخانه هلیل‌رود احداث شده است. این سد نیروگاه برق‌آبی نیز دارد که اطلاعات آن در جدول ۲ بیان شده است. همچنین، سد مخزنی بم (نساء) نخستین و بزرگ‌ترین سد سنگریزه‌ای با رویه بتنی CFRD در ایران است. این سد در فاصله ۲۸۰ کیلومتری کرمان، ۸۰ کیلومتری جنوب شرقی شهرستان بم و در کنار روستای انجیرک روی رودخانه نساء واقع شده، که دو قسمت، بدنه اصلی با ارتفاع ۱۱۱ متر و قسمت دیگر که یک سرریز است، دارد. اهداف اولیه طرح، تأمین آب کشاورزی مورد نیاز برای ۷ هزار هکتار از اراضی پایین‌دست این سد و تأمین بخشی از آب صنعت و آشامیدنی شهرهای بم و بروات است، به این صورت که ۶ میلیون متر مکعب از آب سد در صنعت، ۳۹ میلیون متر مکعب به منظور تأمین آب آشامیدنی شهرستان‌های شرقی استان کرمان و ۴۲ میلیون متر مکعب آب در بخش کشاورزی و ۲۲ میلیون مترمکعب برای آب محیط زیستی استفاده شود. طبق جدول ۱ کد ایستگاه‌های هیدرومتری مورد استفاده، نراب محل سد ۱۰-۴۴ در سد جیرفت و انجیرک ۲۰۵-۴۵ در سد نساء است و شکل ۱ موقعیت قرارگیری هر دو سد را نشان می‌دهد (سهرابی بیدار و امین‌نژاد ۲۰۱۴).

جدول ۱. پارامترهای آماری داده‌های ورودی سدهای جیرفت و نساء (شرکت آب منطقه‌ای کرمان)

سد نساء		سد جیرفت	
پارامتر	مقدار	پارامتر	مقدار
متوسط دبی	MCM۰/۳۴	متوسط دبی	MCM۰/۵۱
خطای استاندارد	۰/۰۱۲	خطای استاندارد	۰/۰۱۸
میانه	۰/۱۲	میانه	۰/۱۴
انحراف معیار	۰/۷۹	انحراف معیار	۱/۷۹
کمترین آورد	MCM۰	کمترین آورد	MCM۰
بیشترین آورد	MCM۱۲/۳۳	بیشترین آورد	MCM۵۳/۲۵
مجموع آورد ورودی	MCM۱۴۶۳/۹	مجموع آورد ورودی	MCM۴۵۹۴/۴
مجموع داده‌ها	۴۳۰۰	مجموع داده‌ها	۹۰۰۰

جدول ۲. مشخصات پایه سدهای جیرفت و نساء (شرکت آب منطقه‌ای کرمان)

مشخصات سد نساء		مشخصات سد جیرفت	
نساء	نام سد	جیرفت	نام سد
سنگریزه‌ای با رویه بتنی	نوع سد	بتنی دو قوسی	نوع سد
۱۱۱ متر	ارتفاع از پی	۱۳۳ متر	ارتفاع از پی
۵۹۰ متر	طول تاج	۱۲۸ متر	ارتفاع سد از بستر رودخانه
۳۹۰ متر	عرض سد از پی	۲۵۰ متر	طول تاج
۱۰ متر	عرض سد در تاج	۱۷ متر	عرض سد از پی
۱۶۸ میلیون متر مکعب	حجم کل مخزن	۵ متر	عرض سد در تاج
۱۲۱ میلیون متر مکعب	حجم مفید مخزن	۳۳۶ میلیون متر مکعب	حجم کل مخزن
۴۷ میلیون متر مکعب	حجم مرده مخزن	۳۱۶ میلیون متر مکعب	حجم مفید مخزن
۳۴.۵ کیلومتر مربع	مساحت مخزن	۲۰ میلیون متر مکعب	حجم مرده مخزن
		۱۰۴۰ هکتار	مساحت دریاچه
		۸۴۵۰ کیلومتر مربع	مساحت حوضه آبریز
		۱۱۸۸.۵ متر از سطح دریا	رقوم تاج سد
		۷۶ میلیون متر مکعب	حجم رسوب تا سال ۱۳۸۵



شکل ۱. موقعیت حوضه سدهای جیرفت و نساء

توابع LSTM

توابع LSTM به صورت معادلات زیر بیان می‌شوند. فعال‌سازی در مرحله t ، براساس چهار نوع دروازه محاسبه می‌شود که دروازه اطلاعات، دروازه فراموشی، دروازه خروجی و دروازه سلول شناخته می‌شود، فنگ و یوان (۲۰۱۹).

ورودی دروازه اطلاعات (در مرحله t) با رابطه ۱ محاسبه می‌شود:

$$i_t = \sigma(x_t W_i + h_{t-1} U_i + b_i) \quad (1)$$

که در آن σ تابع غیرخطی مثال تابع سیگموئید است. W_i و U_i ماتریس‌هایی هستند که می‌توانند به ترتیب h_{t-1} را با x_t و h_t به یکدیگر پیوند دهد. همین‌طور، می‌توان ورودی دروازه فراموشی و ورودی دروازه خروجی را به کمک فرمول ۲ محاسبه کرد:

$$f_t = \sigma(x_t W_f + h_{t-1} U_f + b_f) \quad (2)$$

$$o_t = \sigma(x_t W_o + h_{t-1} U_o + b_o)$$

ورودی دروازه سلولی به صورت رابطه ۳ محاسبه می‌شود:


$$C_t = (f_t C_{t-1} + i_t \tilde{C}_t) \quad (3)$$

که در آن C_{t-1} اطلاعات وضعیت سلول از مرحله قبل و \tilde{C}_t به صورت رابطه ۴ محاسبه می‌شود:

$$\tilde{C}_t = \tanh(x_t W_c + h_{t-1} U_c + b_c) \quad (4)$$

که در آن \tanh تابع مماس مضرب^۱ است. در آخر، فعال‌سازی در مرحله t به صورت رابطه ۵ محاسبه می‌شود و در شکل ۲ تمامی این روند ترسیم شده است (حاجی‌زاده طحان و همکاران، ۲۰۲۰).

$$h_t = \tanh(C_t) * o_t \quad (5)$$



شکل ۲. ساختار توابع مدل LSTM (Chadha et al, 2020)

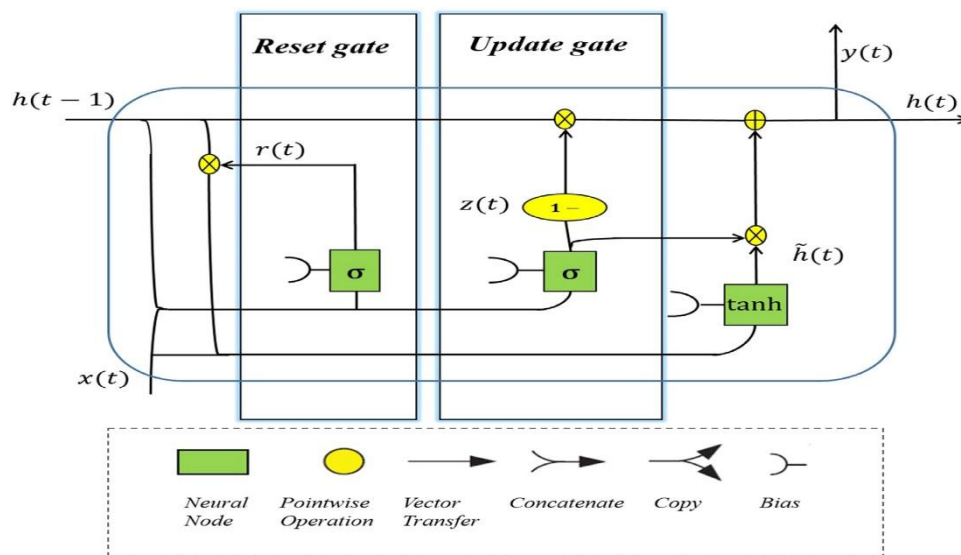
توابع GRU

واحدهای بازگشتی دروازه‌ای یک مکانیسم دروازه‌ای در شبکه‌های عصبی بازگشتی هستند که در سال ۲۰۱۴ توسط کیونگ‌هیون چو و همکارانش ارائه شد. GRU مانند LSTM با یک دروازه فراموشی عمل می‌کند، اما پارامترهای کمتری نسبت به LSTM دارد. GRU در مقایسه با LSTM ساختار داخلی ساده‌تری دارد و بنابراین آموزش آن آسان‌تر است، زیرا برای ارتقای حالت‌های داخلی محاسبات کمتری لازم است (چونگ و همکاران، ۲۰۱۴). طبق شکل ۳ این لایه به دو دروازه تنظیم مجدد و به‌روزرسانی به جای سه گیت در سلول LSTM عمل می‌کند. دروازه تنظیم مجدد و به‌روزرسانی عملکردی مشابه با دروازه فراموشی یک

دروازه ورودی در سلول LSTM دارند، اما تفاوت در نحوه استفاده از خروجی این دروازه‌ها در داخل سلول GRU است. اساساً یک سلول GRU دو دروازه فراموشی و ورودی سلول LSTM را در یک دروازه به‌روزرسانی انفرادی ترکیب کرده، سپس این دروازه به طور مستقل میزان اطلاعاتی را که باید از یک حالت پنهان قبلی به حالت پنهان بعدی منتقل شود، تعیین می‌کند. دروازه به‌روزرسانی میزان نگهداری اطلاعات را از لحظه قبلی در وضعیت فعلی کنترل می‌کند، در حالی که دروازه تنظیم مجدد تعیین می‌کند که آیا وضعیت فعلی باید با اطلاعات قبلی ترکیب شود یا خیر. در نتیجه، GRU، LSTM را با حذف پارامترهای خاص ساده می‌کند، اما همچنان بسیاری از ویژگی‌های اساسی خود را حفظ می‌کند. همچنین، معادلات بردارها با استفاده از رابطه ۶ محاسبه می‌شوند (چو و همکاران، ۲۰۱۴).

$$\begin{aligned} Z_t &= \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t &= \sigma(W_r x_t + U_r h_{t-1} + b_r) \\ \tilde{h}_t &= \tanh(W x_t + U(r_t h_{t-1})) + b_h \\ h_t &= (1 - z)h_{t-1} + z\tilde{h}_t \end{aligned} \tag{۶}$$

که در این روابط x_t بردار ورودی، h_t بردار خروجی، \tilde{h}_t بردار فعال‌سازی، Z_t بردار به‌روزرسانی، r_t بردار تنظیم مجدد، σ نشان‌دهنده تابع سیگموئید، W, W_r, W_z ماتریس‌های وزن برای بردار ورودی، U, U_r, U_z ماتریس‌های وزن مرحله زمانی قبلی و b, b_z, b_r و بایاس هستند (انصاری قوجقار و همکاران، ۲۰۲۱).



شکل ۳. ساختار توابع مدل GRU (Chadha et al, 2020)

معیارهای ارزیابی

تابع خطا یکی از پارامترهایی است که همواره برای پردازش یک مدل به آن نیاز است. برای ارزیابی عملکرد کارایی شبیه‌سازی سری زمانی ورودی به سد، محاسبه معیارهای ارزیابی عملکرد ضروری است. برای دستیابی به مدل مطلوب سری زمانی، شاخص‌های خطاسنجی مبتنی بر پارامترهای آماری مورد ارزیابی قرار گرفت. در این مطالعه برای ارزیابی دقت مدل‌های برازشی، معیارهای ارزیابی ریشه میانگین مربعات خطا RMSE، میانگین خطای مطلق MAE و ضریب تبیین R^2 محاسبه شد. این ضرایب با استفاده از روابط ۷ تا ۹ محاسبه می‌شوند (حسینی‌خواه و همکاران، ۲۰۱۳).

$$MAE = \frac{\sum_{i=1}^n |\bar{y}_i - x_i|}{n} \quad 0 \leq MAE < \infty \tag{۷}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{y}_i)^2}{n}} \quad 0 \leq RMSE < \infty \quad (8)$$

$$R^2 = \frac{|\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})|^2}{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2} \quad 0 \leq R^2 < 1 \quad (9)$$

که در این روابط x_i و y_i به ترتیب مقدار اندازه‌گیری شده و مقادیر شبیه‌سازی شده نتایج حاصل از مدل‌هاست. مقدار آماره ریشه میانگین مربعات خطا همواره مثبت بوده و بهترین حالت عملکرد زمانی است که مقدار به صفر نزدیک شود (حسینی‌خواه و همکاران، ۲۰۱۳).

تابع هدف

براساس فرایند صورت‌گرفته اجرای مدل، ساختار مدل به این صورت است که ورودی به مدل دبی ورودی به سد بوده و خروجی آن سری زمانی است. همچنین، تابع هدف در این پژوهش به صورت معادله ۱۰ بیان می‌شود.

$$F = \varphi(Q_t \dots Q_{t-m}) \quad m = \text{تأخیر روزانه} \quad (10)$$

که در آن F تابع هدف، φ تابع وابسته و Q_t آورد روزانه به سد و m تأخیر زمانی آورد است. دوره زمانی مدل‌سازی در این پژوهش ۲۵ سال است که شامل دوره‌های اقلیمی خشک، تر و نرمال می‌شود.

بررسی آماری داده‌ها


بررسی و همگن‌سازی داده‌ها از نظر داده مفقود نیز مورد بررسی قرار گرفته است که با توجه همکاری با شرکت آب منطقه‌ای و در خروجی بانک اطلاعاتی سدها داده مفقودی از زمان آغاز ثبت داده‌ها وجود نداشت. در شروع فرایند مدل‌سازی، ابتدا داده‌های مورد نیاز را به کمک رابطه ۱۱ نرمال‌سازی می‌کنند که داده‌ها در بازه صفر و یک قرار می‌گیرند. سپس، مدل برای آموزش اجرا می‌شود. همچنین، با توجه به نحوه اجرای کد ذکر این موضوع الزامی است که در هر دو مدل برای اجرا، در هر دور ۱۰ درصد از داده‌ها به عنوان داده‌های صحت‌سنجی در مدل‌ها اعمال می‌شود و سپس خروجی مدل به دست می‌آید.

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad 0 \leq X_n \leq 1 \quad (11)$$

که در آن X_n داده‌های نرمال‌شده، X داده‌های اولیه، X_{\max} بیشترین آورد و X_{\min} کمترین آورد است.

یافته‌های پژوهش


سری زمانی آورد ورودی به سد جیرفت طی ۲۵ سال (۱۳۷۷-۱۴۰۲) و سری زمانی آورد ورودی به سد نساء طی ۱۲ سال (۱۳۹۰-۱۴۰۲) در شکل ۴ آورده شده است، که مطابق تعاریف صورت‌گرفته دارای تغییرات نامنظم در طول سری هستند. تعداد یک سوم داده‌ها از سال (۱۳۹۳-۱۴۰۲) به عنوان داده‌آزمون و باقی (۱۳۷۷-۱۳۹۳) برای آموزش مدل در سد جیرفت و تعداد یک سوم داده‌ها از سال (۱۳۹۸-۱۴۰۲) به عنوان داده‌آزمون و باقی (۱۳۹۰-۱۳۹۸) برای آموزش مدل در سد نساء مورد استفاده قرار گرفت.



شکل ۴. سری زمانی ورودی به سد نساء (راست) و سد جیرفت

نتایج حاصل از اجرای مدل LSTM

عملکرد نتایج هر دو مدل باید با توجه به پارامترهای بیش‌برازش^۱ و کم‌برازش^۲ مورد بررسی قرار گیرد. این پارامترها دو رویدادی هستند که احتمال رخداد آن‌ها وجود دارد و اگر این اتفاق رخ دهد، به این معناست که مدل به‌درستی آموزش ندیده و درست آزمون نگرفته و در نتیجه، مدل به‌خوبی اجرا نشده است. طبق تعریف، اگر آموزش بهتر از آزمون عمل کند به نحوی که آزمون همگرا با آموزش نشود، حالت بیش‌برازش اتفاق افتاده است و در حالت دیگر، اگر آزمون بهتر از آموزش عمل کند، رخداد کم‌برازش پیش می‌آید. هدف اصلی هر مدل یادگیری عمیق تعمیم صحیح مجموعه داده‌ها است. از این‌رو، بیش‌برازش و کم‌برازش دو عبارتی هستند که باید برای عملکرد مدل و تعمیم صحیح بررسی شوند. با توجه به توضیحات، مدل زمانی در بهترین حالت خود قرار دارد که به نقطه همگرایی^۳ رسیده باشد. طبق شکل ۵ مدل اجرا شده روی سد جیرفت پس از سعی و خطای متعدد در دوره ۱۲۹ و طبق شکل ۷ مدل اجرا شده روی سد نساء پس از سعی و خطای متعدد در دوره ۹۲ به نقطه همگرایی رسیده و هیچ‌گونه مشکلی از نظر بیش‌برازش و کم‌برازش ندارند و مدل به‌خوبی اجرا شده است. منظور از دوره در این قسمت به معنای تعداد دفعاتی است که مدل اجرا شده تا در نهایت به نقطه همگرایی برسد و هدف از زمان بیان شده مقصود، زمان برای هر دور جداگانه مدل است.



شکل ۵. نمودار صحت‌سنجی مدل LSTM در سد نساء (سمت راست) و سد جیرفت (سمت چپ)

نتایج حاصل از دقت پیش‌بینی‌های انجام‌شده توسط مدل برازش شده و آموزش مدل و مقادیر پیش‌بینی‌شده توسط مدل در جدول ۳ ارائه شده است. نتایج حاصل از خروجی سد جیرفت نشان داد معیارهای ارزیابی مقادیر RMSE، برای آموزش و آزمون

1. Overfitting
2. Under fitting
3. Convergence

مدل به ترتیب ۰/۷۲ و ۰/۷۸ و مقادیر MAE به ترتیب ۰/۱۰ و ۰/۱۲ در مدل LSTM است. همچنین با توجه به معیار RMSE، روش پیشنهادی چه در مجموعه داده‌های آزمون و چه در داده‌های آموزش، عملکرد خوبی داشته است. همچنین، براساس دو معیار دیگر MAE و R^2 روش پیشنهادی توانسته است به انتظارات پاسخ قابل قبولی ارائه دهد. براساس نتایج حاصل از خروجی مدل LSTM، مدل برای ۵۰۰ مرتبه تکرار خروجی، در مرتبه ۱۲۹ به توقف زودهنگام^۱ رسیده و در حالت همگرا قرار گرفته و زمان برای هر دوره^۲ اجرای مدل ۱۴۹/۷۳ ثانیه بوده است. همچنین، نتایج حاصل از خروجی سد نساء نیز نشان داد معیارهای ارزیابی مقادیر RMSE، برای آموزش و آزمون مدل به ترتیب ۰/۱۱ و ۰/۱۰ و مقادیر MAE به ترتیب ۰/۰۵ و ۰/۰۴ در مدل LSTM است.

توقف زودهنگام نوعی روش منظم‌سازی برای جلوگیری از بیش‌برازش در یادگیری ماشین به روش‌های ترتیبی همچون گرادین کاهشی است. روش‌های ترتیبی، مدل را مرحله به مرحله به روزرسانی می‌کنند تا پس از هر مرحله، عملکرد بهتری روی داده‌های آموزش داشته باشد. اما از جایی به بعد، بهبود عملکرد روی داده‌های آموزش به معنای کاهش دقت روی داده‌های آزمایش خواهد بود که رخداد بیش‌برازش است. توقف زودهنگام سعی دارد با متوقف کردن یادگیری در نقطه بهینه، خطای تعمیم را به حداقل برساند. توقف زودهنگام با متوقف کردن آموزش مدل قبل از اینکه بهینه شود، از یادگیری بیش از حد جلوگیری می‌کند. این کار با نظارت بر عملکرد مدل در داده‌های آزمون طی آموزش انجام می‌شود. اگر عملکرد مدل در داده‌های آزمون شروع به کاهش کند، آموزش متوقف می‌شود. این عمل تضمین می‌کند که مدل بهینه نشده و احتمال یادگیری بیش از حد کمتر است. توقف زودهنگام نوعی قدرتمند برای بهبود عملکرد مدل‌های یادگیری ماشین است.


جدول ۳. مقادیر پارامترهای آماری در مدل LSTM

پارامتر آماری	آموزش	آزمون	آموزش	آزمون
RMSE (MCM)	۰/۷۲	۰/۷۸	سد نساء	سد جیرفت
R^2	۰/۸۷	۰/۸۲	۰/۱۱	۰/۸۵
MAE (MCM)	۰/۱۰	۰/۱۲	۰/۰۵	۰/۰۴
Simulation time	ثانیه ۱۴۹/۷۳	ثانیه ۱۶۹/۹۴		

نتایج حاصل از اجرای مدل GRU

عملکرد نتایج مدل GRU نیز باید با توجه به پارامترهای بیش‌برازش و کم‌برازش مورد بررسی قرار گیرد. همان‌طور که گفته شد، این پارامترها دو رویدادی هستند که احتمال رخداد آن‌ها وجود دارد و اگر این اتفاق رخ دهد، به این معناست که مدل به درستی آموزش ندیده و درست آزمون نگرفته و در نتیجه، مدل به خوبی اجرا نشده است. با توجه به توضیحات، مدل زمانی در بهترین حالت خود قرار دارد که به نقطه همگرایی رسیده باشد. طبق شکل ۶ مدل اجرا شده در سد جیرفت پس از سعی و خطای متعدد در دوره ۹۴ به نقطه همگرایی رسیده و در سد نساء نیز در دوره ۷۳ به نقطه همگرایی رسید.

4. Early Stopping
5. Epochs



شکل ۶. نمودار صحت‌سنجی مدل GRU در سد نساء (سمت راست) و سد جیرفت (سمت چپ)

نتایج حاصل از دقت پیش‌بینی‌های انجام‌شده توسط مدل برازش شده و آموزش مدل و مقادیر پیش‌بینی‌شده هر دو سد در مدل GRU در جدول ۴ ارائه شده است. با توجه به معیارهای ارزیابی، مقادیر RMSE برای آموزش و آزمون مدل به ترتیب ۰/۹۴ و ۱/۰۲ و مقادیر MAE به ترتیب ۰/۱۵ و ۰/۲۰ است و با توجه به معیارهای ارزیابی، مقادیر RMSE برای آموزش و آزمون مدل به ترتیب ۰/۱۰ و ۰/۰۹ و مقادیر MAE به ترتیب ۰/۰۴ و ۰/۰۳ است. همچنین، با توجه به معیار RMSE، روش GRU نیز چه در مجموعه داده‌های آزمون و چه در داده‌های آموزش، عملکرد خوبی برای هر دو سد داشته است. همچنین، براساس دو معیار دیگر MAE و R^2 روش پیشنهادی توانسته است به انتظارات پاسخ قابل قبولی ارائه دهد. براساس نتایج حاصل از خروجی مدل GRU، مدل برای ۵۰۰ مرتبه تکرار خروجی برای هر دو سد، برای سد جیرفت در مرتبه ۹۴ به توقف زودهنگام رسیده و در حالت همگرا قرار گرفته و برای سد نساء در مرتبه ۷۳ به توقف زودهنگام رسیده و در حالت همگرا قرار گرفته است.

جدول ۴. مقادیر پارامترهای آماری در مدل GRU

پارامتر آماری	آموزش	آزمون	آموزش	آزمون
RMSE (MCM)	۰/۹۴	۱/۰۲	سد نساء	سد جیرفت
R^2	۰/۷۶	۰/۷۰	۰/۱۰	۰/۸۶
MAE (MCM)	۰/۱۵	۰/۲۰	۰/۰۹	۰/۸۰
Simulation time	ثانیه ۱۰۶/۲۳۵	ثانیه ۲۲۶/۰۲	۰/۰۳	۰/۰۴

مقایسه نتایج حاصل از بررسی پژوهش با نتایج پژوهش مؤمنه (۲۰۲۲) که به مدل‌سازی جریان برای حوضه آبریز رودخانه گاماسیاب، واقع در غرب ایران پرداخته است نشان داد مدل LSTM عملکرد بهتری نسبت به سایر مدل‌ها در پیش‌بینی آورد جریان ارائه می‌کند. همچنین، با مقایسه نتایج پژوهش حاضر با پژوهش انوری (۲۰۱۸) که با استفاده از داده‌های هیدرولوژیکی حوضه هلیل‌رود به پیش‌بینی تجمعی جریان با مدل‌های شبکه عصبی مصنوعی ANN پرداخته است، مشخص شد شاخص‌های RMSE، R^2 و MAE برای ارزیابی عملکرد مدل‌های ANN و یادگیری عمیق در پیش‌بینی جریان روند دقت اجرای مدل را به‌خوبی نمایش می‌دهند.

نتیجه‌گیری و بحث

ماهیت انجام این پژوهش در دانستن اهمیت کارایی شبیه‌سازی سری زمانی جریان روزانه ورودی به سدهای جیرفت و نساء است. در نهایت با مقایسه نتایج معیارهای ارزیابی دو مدل، زمان سپری‌شده برای هر دوره اجرای مدل‌ها و محدوده همگرایی برای دو مدل نشان‌دهنده نتایج مطلوب مدل LSTM نسبت به مدل GRU در سد نساء و برای سد جیرفت و برای سد نساء نسبت به مدل LSTM بود. از این‌رو، می‌توان نتیجه گرفت که در بررسی‌های با دوره زمانی بلندمدت روش LSTM و دوره زمانی کوتاه‌مدت روش GRU کارایی بهتری در اجرا دارند. بهره‌برداری از مخزن سد از مهم‌ترین مباحثی است که می‌توان به آن اشاره

کرد و اهمیت پرداختن به موضوع را بیش از پیش جلوه می‌دهد؛ به صورتی که با توجه به شرایط اقلیمی کنونی و به وجود آمدن خشکسالی و ترسالی‌های شدید با داشتن برنامه‌ای مدون و بهره‌گیری از ابزارهای هوشمند به منظور مقابله با مخاطرات گوناگون وجود داشته باشد. در صورت اقدام به پیش‌بینی، این‌گونه نقش خود را ایفا می‌کنند که با اطلاع از سیلاب‌های آینده برنامه‌ریزی‌هایی صورت گیرد که در چه زمانی دریاچه‌های سد باز و بسته شود و برای انجام تعمیرات در نقاط مختلف سد برنامه‌زمان‌بندی مشخص شود. از نکات مهم دیگر اینکه با مطلع بودن از سیلاب‌های مخرب که باز کردن دریاچه‌های سد را ملزم می‌کند، اقدام به تخلیه سیلاب کرده تا از خرابی‌های احتمالی پشت سد جلوگیری شود و باقی‌مقادیری که به پایین‌دست رها می‌شود، موجب آسیب و خسارت به اراضی کشاورزی و مسکونی و تأسیسات آب شرب نشود. برای این موضوع باید پایین‌دست سد را مدیریت کرد تا براساس دانشی که کسب می‌شود موجب شود استحکامات پایین‌دست را ایجاد و یا به‌روز کرده و در مباحث گوناگون مدیریتی مانند گابیون‌بندی، تسهیل‌گری، آموزش و غیره اطلاعات به‌روز داده شود تا آمادگی مقابله با سیلاب‌های آینده وجود داشته باشد. در پایان، مطابق نتایج حاصل از پژوهش می‌توان بیان کرد سری‌های زمانی یکی از گزینه‌های مناسب برای شبیه‌سازی جریان روزانه به سدها هستند، زیرا با مشاهده روند اتفاقات و پیشامدهای گذشته ورودی به عنوان تجربیات حاصل، امکان پیش‌بینی، درک و اصلاح خطاهای موجود بهتر صورت می‌گیرد. به تعریفی دیگر، زمانی که با مجموعه‌ای از داده‌ها که با هم در ارتباط هستند بررسی انجام می‌شود، نتایج بیشتر نزدیک به واقعیت هستند تا زمانی که از تک‌رخدادها استفاده شود. همچنین، خروجی مدل‌ها نشان داد از روش‌های نوین مانند یادگیری عمیق که به‌خوبی توان شبیه‌سازی سری‌های زمانی که ماهیت غیرقطعی دارند بهره برد و موجب دقت بیشتر در روند محاسبات و صرف کردن زمان کمتر نسبت به روش‌های کلاسیک هستند. در انتها مطابق نتایج حاصل می‌توان گفت که مدل‌های یادگیری عمیق می‌توانند نقش مهمی در پیش‌بینی سری‌های زمانی داده‌های منابع آب سطحی داشته باشند.

قدردانی

مقاله حاضر منتج از پژوهشی با عنوان «پیش‌بینی سری زمانی ورودی به سدهای استان کرمان در شرایط مختلف اقلیمی و هیدرولوژی» است. از شرکت آب منطقه‌ای کرمان و معاونت برنامه‌ریزی به پاس حمایت‌ها تشکر و قدردانی می‌شود.

منابع

- 1 Ahmadi, P., Arefi, H., & Kardan, N. (2020). Modeling the discharge of Karun River Using a New Method Based on the Joint LSTM and GRU Neural Networks. *Journal of Ecohydrology*, 7(3), 619-633. (In Persian)
- 2 Ansari Qujqar, M., Iraquejad, Sh., Bazarafshan, J., Zahraei, B., & Parsi, E. (2021). Evaluating the effectiveness of GRU-LSTM hybrid model in forecasting dust storms (case study: Khuzestan province). *Iran Water Resources Research*, 17(1), 16-32. (In Persian)
- 3 Akbari Osmavandani, S., Sharafati, A., & Moghaddam, H. K. (2024). Assessing the effectiveness of artificial intelligence models in predicting Zayanderud dam inflow at different time scales. *Acta Geophysica*, 72(5), 3511-3527. (In Persian)
- 4 Anvari, S. (2018). Probabilistic Forecasts of Streamflow Scenarios Using ESP Approach (Case study: Halil River). *Journal of Irrigation Sciences and Engineering*, 41(3), 75-87. (In Persian)
- 5 Baharlu, R. (2009). Forecasting time series with long-term dependencies using NARX recurrent neural network. *The 12th Electrical Engineering Student Conference*, (In Persian)
- 6 Bakhshi Ostadkalayeh, F., Moradi, S., Asadi, A., Moghaddam Nia, A., & Taheri, S. (2023). Performance improvement of LSTM-based deep learning model for streamflow forecasting using Kalman filtering. *Water Resources Management*, 37(8), 3111-3127. (In Persian)
- 7 Chadha, G. S., Panambilly, A., Schwung, A., & Ding, S. X. (2020). Bidirectional deep recurrent neural networks for process fault classification. *ISA transactions*, 106, 330-342.
- 8 Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv*, 1412-3555.
- 9 Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation: Encoder-decoder approaches. *arXiv preprint arXiv*, 1259-1409.
- 10 Damle, C., & Yalcin, A. (2007). Flood prediction using time series data mining. *Journal of Hydrology*, 333(2-4), 305-316.
- 11 Day, G. N. (1985). Extended streamflow forecasting using NWSRFS. *Journal of Water Resources Planning and Management*, 111(2), 157-170.
- 12 Fang, X., & Yuan, Z. (2019). Performance enhancing techniques for deep learning models in time series forecasting. *Engineering Applications of Artificial Intelligence*, 85, 533-542.
- 13 Fathi, P., Mohammadi, Y., & Homai, M. (2009). Intelligent modeling of monthly time series of input to Vahdat Dam in Sanandaj. *Water and Soil (Agricultural Sciences and Industries)*, 23(1), 209-220 (In Persian)
- 14 Frank, R. J., Davey, N., & Hunt, S. P. (2001). Time series prediction and neural networks. *Journal of intelligent and robotic systems*, 31(1), 91-103.
- 15 Ghose, D. K. (2018). Measuring discharge using back-propagation neural network: a case study on Brahmani river basin. *Intelligent Engineering Informatics: Proceedings of the 6th International Conference on FICTA*, 591-598.
- 16 Hajizadeh Tahan, M., Ghasemzadeh, M., & Rezaeian, M. (2020). An evolutionary attention-based deep long short-term memory for time series prediction. *Computational Intelligence in Electrical Engineering*, 11(4), 15-28. (In Persian)
- 17 Hosseinikhah, M., Zainiwand, H., Haqizadeh, A., & Tahmasabipour, N. (2013). Validation of temperature and precipitation values of general circulation models in Kermanshah Ravansar and West Islamabad stations. *Ecohydrology*, 1(3), 195-206 (In Persian)

- 18 Khalili, R., & Moridi, A. (2023). A Review of Artificial Intelligence Applications in Modeling and Removal Processes of Pollutants Soluble in Water and Wastewater. *Iran-Water Resources Research*, 19(1), 136-166. (In Persian)
- 19 Momeneh, S. (2022). Performance comparison of artificial intelligence models with IHACRES model in streamflow modeling of the Gamasiab River catchment. *Water and Soil Management and Modelling*, 2(3), 1-16. (In Persian)
- 20 Muhammad, A. U., Li, X., & Feng, J. (2019). Using LSTM GRU and hybrid models for streamflow forecasting. In *International Conference on Machine Learning and Intelligent Communications*, 510-524.
- 21 Management and Planning Organization of Iran. (2005). Regional balance between water resources and uses in catchment basins current and future status of water resources. *Office of Water Affairs Agriculture and Natural Resources Studies of Comprehensive Climate Adaptation Program*. (In Persian)
- 22 Samadi M. and Fathabadi A. (2019). Application of time series, ANN, and SVM models in forecasting the Gorgan Dam inflow rate. *J. Environ. Water Eng*, 4(4), 299-309. (In Persian)
- 23 Shafa'i Bejestan, M. (1999). Hydraulic precipitation. *Publications of Shahid Chamran University of Ahvaz* 496. (In Persian)
- 24 SohrabiBidar, A., & Aminnejad, M. (2015). Investigating the displacements of Jiroft concrete dam foundations using dam extensometers. *Iran Engineering Geology Association Journal*, 7(3-4), 95-102 (In Persian)
- 25 Swagatika, S., Paul, J. C., Sahoo, B. B., Gupta, S. K., & Singh, P. K. (2024). Improving the forecasting accuracy of monthly runoff time series of the Brahmani River in India using a hybrid deep learning model. *Journal of Water and Climate Change*, 15(1), 139-156.
- 26 Valipour, M., Banihabib, M. E., & Behbahani, S. M. R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of hydrology*, 476, 433-441.
- 27 Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), 294-306.
- 28 Zaytar, M. A., & El Amrani, C. (2016). Sequence to sequence weather forecasting with long short-term memory recurrent neural networks. *International Journal of Computer Applications*, 143(11), 7-11.
- 29 Zhang, B., & Govindaraju, R. S. (2000). Prediction of watershed runoff using Bayesian concepts and modular neural networks. *Water Resources Research*, 36(3), 753-762.