

Modeling streamflow during the snowmelt-dominated period using LSTM and ERA5-LAND reanalysis data (A case study: The snow-covered Bazoft basin)

Ali Fattahi Nafchi¹, Mohammad Reza Sharifi^{*2} and Amin Khorramian³

Extended Abstract

Introduction

Mountain snow reserves are a crucial component of the hydrological cycle in high-altitude basins, supplying a substantial portion of river flow during the warm season. Forecasting discharge during the snowmelt-dominated period is therefore essential for water resource management and flood mitigation, a challenge intensified by climate change impacts on melt timing. While physically-based and conceptual temperature-index models are common, they face limitations due to data scarcity or an inability to capture complex, non-linear melt-runoff processes. Consequently, this study employed a data-driven approach using a Long Short-Term Memory (LSTM) deep learning network to model the non-linear temporal dynamics of snowmelt. Specifically, an LSTM model was developed and evaluated to forecast daily discharge during the snowmelt period in the data-scarce, snow-fed Bazoft Basin, Iran. To address the lack of in-situ data, meteorological time series from the ERA5 reanalysis product were utilized as model inputs. The results demonstrated the LSTM model's effectiveness in learning the long-term dependencies between snowmelt processes and streamflow, offering a robust framework for seasonal runoff prediction in snow-dominated regions to support sustainable water management.

Materials and Methods

This study was conducted in the snow-covered Bazoft Basin, located in the northern Karun River catchment, Iran (31.6°–32.65° N, 49.56°–50.46° E). The basin experiences snow accumulation from December to March, with the snowmelt-dominated period occurring from mid-February to April, during which snowmelt is the primary contributor to streamflow. Daily streamflow data from the Landi hydrometric station were used as the target variable. Due to the scarcity of ground-based meteorological stations in this mountainous region, this study utilized the ERA5-LAND reanalysis dataset from the European Centre for Medium-Range Weather Forecasts (ECMWF). ERA5-LAND provides improved spatial resolution (9 km) compared to ERA5 (31 km) and has been extensively validated in previous studies over Iran, demonstrating high correlation with ground observations, particularly for temperature ($R^2 > 0.95$). The following daily variables were extracted: air temperature (T), precipitation (P), and snow water equivalent (SWE). The Gamma Test (GT), a non-parametric method for identifying the optimal input combination, was employed to select the most relevant input variables. Four different input combinations were evaluated: M1 (Q and SWE), M2 (Q, T, and SWE), M3 (Q, P, and SWE), and M4 (Q, P, T, and SWE). The combination with the minimum Gamma value and V-ratio was selected as the optimal input set. A Long Short-Term Memory (LSTM) neural network was developed to model the non-linear, long-term temporal dependencies inherent in the snowmelt-runoff process. The LSTM architecture includes forget, input, and output gates that regulate information flow, enabling the network to retain relevant information over extended time steps. The model was implemented using the Keras framework. The dataset was randomly divided into training (80%) and testing (20%) subsets. Various hyperparameters were optimized, including the number of hidden layers (1–3), the number of hidden units (10–40), and seven optimization algorithms (Adam, Adamax, SGD, RMSprop, Nadam, Adagrad, and Adadelat). Model performance was evaluated using the Nash-Sutcliffe Efficiency (NSE), Root Mean Square Error (RMSE), and Coefficient of Determination (R^2).

1- Ph D. Student of Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

2- Associate Professor, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

3- Assistant Professor, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

*Corresponding author: msharifi@scu.ac.ir

Received: 2026/02/16

Accepted: 2026/03/14

Results and Discussion

The Gamma Test results identified the optimal input combination for LSTM modeling. Among the four evaluated combinations, M2 (discharge, temperature, and snow water equivalent) exhibited the minimum Gamma value (0.00151) and V-ratio (0.00412), indicating the smoothest input-output relationship with the lowest irreducible noise. Consequently, M2 was selected as the most appropriate input set for subsequent LSTM modeling. Evaluation of LSTM hyperparameters revealed that a single hidden layer architecture outperformed deeper configurations (2-3 layers), achieving the lowest RMSE (0.220) and MAE (0.125). Regarding hidden units, 20 neurons yielded optimal performance. Among seven optimization algorithms compared, Adamax demonstrated superior results with RMSE and MAE values of 0.37 and 0.18, respectively, and was therefore selected as the optimizer for the final model. The LSTM model with M2 inputs (Q, T, SWE) demonstrated exceptional performance in simulating daily streamflow during the snowmelt-dominated period. During the training phase, the model achieved $NSE=0.994$, $R^2=0.991$, and $RMSE=0.08$. In the testing phase, performance remained excellent with $NSE=0.994$, $R^2=0.991$, and $RMSE=0.174$. Visual comparison of observed and simulated hydrographs for the 2021-2022 and 2022-2023 water years showed that the LSTM accurately captured both low-flow conditions and peak discharges during snowmelt events. Scatter plots further confirmed this accuracy, with points closely clustered around the 1:1 line and R^2 values of 0.997, demonstrating that the model effectively reproduced the variance in observed streamflow across the entire flow regime. The superior performance of the LSTM model can be attributed to its inherent capability to capture long-term temporal dependencies through memory cells and gating mechanisms, which is particularly advantageous for snowmelt-runoff processes characterized by lagged responses and memory effects. The inclusion of SWE as an input variable proved crucial, as it directly represents the accumulated snowpack available for melt, while temperature controls the melt energy. Notably, the M2 combination (Q, T, SWE) outperformed combinations including precipitation (M3 and M4), suggesting that during the snowmelt-dominated period, the hydrological signal is primarily governed by snowmelt dynamics rather than concurrent rainfall. Comparison with previous studies demonstrated the competitiveness of the proposed approach. The obtained NSE (0.994) substantially exceeded values reported for traditional temperature-index models ($NSE\sim 0.80$) and was higher than ANN-based snowmelt runoff predictions ($NSE\sim 0.93$). The results were comparable with other LSTM applications in hydrological modeling ($NSE\sim 0.99$). However, this study specifically contributed to the limited literature on LSTM application for snowmelt-dominated period streamflow modeling in data-scarce mountainous regions. The successful integration of ERA5-LAND reanalysis data addresses the critical challenge of data scarcity in mountainous basins. The high accuracy achieved demonstrated that reanalysis products can effectively substitute for ground-based meteorological observations when the latter are unavailable, provided they are appropriately validated for the study region.

Conclusion

This study demonstrated that the LSTM model, forced with ERA5-LAND reanalysis data (temperature and snow water equivalent) together with antecedent discharge, accurately simulated daily streamflow during the snowmelt-dominated period in the data-scarce Bazoft Basin ($NSE=0.994$, $RMSE=0.174$). The optimal performance was achieved with a single hidden layer, 20 hidden units, and the Adamax optimizer. The superior performance of the temperature-SWE-discharge combination over precipitation-inclusive inputs confirmed the dominance of snowmelt processes during the study period. This framework offers an effective solution for seasonal runoff prediction in snow-dominated mountainous regions lacking dense ground-based observations, supporting informed water resource management and planning.

Keywords: ERA5-LAND, LSTM, Streamflow, Snow, SWE

Citation:

Fattahi Nafchi.A., Sharifi.M.R., Khorramian.A., 2026. Modeling streamflow during the snowmelt-dominated period using LSTM and ERA5-LAND reanalysis data (A case study: The snow-covered Bazoft basin).Iranian Water Research Journal, 20(62), pp. 1-14. <https://dx.doi.org/10.22034/iwrj.2026.14932.2634>

Copyright: © Authors, Published by Iranian Water Research Journal. This is an open-access article distributed under the CC-BY 4.0 (license <http://creativecommons.org/licenses/by/4.0/>).



مدل سازی جریان دوره غالب ذوب برف با استفاده از LSTM و داده های باز تحلیل ERA5-LAND (مطالعه موردی: حوضه برفگیر بازفت)

علی فتاحی نافچی^۱، محمدرضا شریفی^{۲*} و امین خرمیان^۳

چکیده

پیش بینی جریان رودخانه در حوضه های برفگیر در دوره غالب ذوب برف، برای مدیریت منابع آب، دارای اهمیت است. مدل های یادگیری ماشین به عنوان مدل های داده محور، به دلیل آموزش روابط بین ورودی ها و خروجی ها، قابلیت زیادی برای شبیه سازی روابط پیچیده و غیر خطی دارند. شبکه های عصبی مصنوعی معمولی، به دلیل عدم ذخیره اطلاعات زمانی عوامل ورودی، قابلیت چندانی در مدل سازی سری زمانی فرایند پیچیده متأثر از ذوب برف را ندارند. رویکرد یادگیری عمیق LSTM، تحت عنوان حافظه بلند ترم های کوچک، برخی محدودیت های مدل های یادگیری ماشین را به واسطه خصوصیت ذخیره سازی اطلاعات زمانی، برطرف نموده است. در تحقیق حاضر، مدل LSTM برای مدل سازی جریان روزانه در دوره غالب ذوب برف و با استفاده از داده های باز تحلیل ERA5-LAND در حوضه آبریز برفی بازفت به کار گرفته شد. بر اساس آزمون گاما، پارامترهای دما، آب معادل برف باز تحلیل شده از پایگاه ECMWF و دبی پیشین به عنوان بهترین ترکیب متغیرهای ورودی به مدل تعیین شدند. نتایج مدل LSTM با یک لایه پنهان و بهینه ساز Adamax، مقادیر NSE و RMSE را در مرحله آزمون به ترتیب ۰/۹۹۴ و ۰/۱۷۴ نشان داد. از این رو می توان نتیجه گرفت که مدل LSTM، به همراه داده های باز تحلیل، به خوبی قادر به شبیه سازی جریان روزانه در دوره غالب ذوب برف است.

واژه های کلیدی: برف، جریان رودخانه، LSTM، ERA5-LAND، SWE

ارجاع: فتاحی نافچی، ع.، شریفی، م. ر.، خرمیان، ا.، ۱۴۰۵. مدل سازی جریان دوره غالب ذوب برف با استفاده از LSTM و داده های باز تحلیل ERA5-LAND (مطالعه موردی: حوضه برفگیر بازفت). مجله پژوهش آب ایران، ۲۰ (۶۲)، صص. ۱-۱۴. <https://dx.doi.org/10.22034/iwrj.2026.14932.2634>

^۱ دانشجوی دکتری دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

^۲ دانشیار، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

^۳ استادیار، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

* نویسنده مسئول: msharifi@scu.ac.ir

تاریخ پذیرش: ۱۴۰۴/۱۲/۲۳

تاریخ دریافت: ۱۴۰۴/۱۱/۲۷

مقدمه

ذخایر برفی کوهستانی یکی از اجزای مهم چرخه هیدرولوژیکی در حوضه‌های مرتفع به شمار می‌روند و تأمین سهم قابل‌توجهی از جریان رودخانه‌ها را در فصل گرم بر عهده دارند. در این حوضه‌ها، بخش عمده جریان رودخانه‌ها در بازه‌ای از سال که ذوب برف غالب است، شکل می‌گیرد؛ از این رو، پیش‌بینی دبی مشاهده‌شده در دوره غالب ذوب برف برای مدیریت بهینه منابع آب، برنامه‌ریزی تخصیص آب و کاهش مخاطرات سیلاب ضروری است (Hamlet et al., 2005; Lundquist et al., 2015). اهمیت این موضوع در شرایط تغییر اقلیم، جابه‌جایی زمان ذوب و افزایش ناپایداری الگوهای دما و بارش بیشتر شده است (Pradhan et al., 2022). مدل‌سازی فرایند برف-رواناب به‌طور رایج در سه گروه اصلی توسعه یافته است: (۱) مدل‌های فیزیکی مبتنی بر معادلات تعادل انرژی، (۲) مدل‌های مفهومی یا شاخص دما و (۳) مدل‌های داده‌محور. مدل‌های فیزیکی اگرچه از پشتوانه فیزیکی قوی برخوردارند، نیازمند داده‌های گسترده و دقیق هستند که در بسیاری از حوضه‌های کوهستانی در دسترس نیست (Havens et al., 2019). مدل‌های مفهومی شاخص دما، به‌دلیل سادگی ساختار، کاربرد فراوانی دارند، اما در توصیف روابط غیرخطی پیچیده میان شرایط حرارتی، انباشت برف و پاسخ جریان رودخانه محدودیت دارند (Petersen et al., 2022). در مقابل، رویکردهای داده‌محور با تکیه بر استخراج الگوهای غیرخطی از داده‌های مشاهداتی، امکان مدل‌سازی سیستم‌های پیچیده با کمترین فرضیات اولیه را فراهم می‌آورند.

مدل‌های یادگیری ماشین به‌عنوان مدل‌های داده‌محور، از طریق آموزش روابط بین ورودی‌ها و خروجی‌ها، قابلیت زیادی برای شبیه‌سازی روابط پیچیده و غیر خطی دارند. یادگیری ماشینی و کاربردهای آن، به ویژه در حوضه‌های مختلف مدل‌سازی منابع آب، در بسیاری از مطالعات گذشته بررسی شده است (Hazbavi and Vafakhai, 2015; Shen, 2018). یادگیری ماشین، روش مبتنی بر شبکه‌های عصبی مصنوعی، بیشتر رواج دارد. این درحالی است که روش‌های دیگری مانند جنگل تصادفی، ماشین بردار پشتیبان و رگرسیون فرآیند گاوسی نیز استفاده می‌شوند (Lee et al., 2023). Callegari et al. (2015) از مدل‌های رگرسیون بردار پشتیبان برای پیش‌بینی ماهانه دبی حاصل از ذوب برف در کوه‌های آلپ ایتالیا استفاده کردند. آنها با استفاده از مساحت پوشش برف (SCA)، دبی پیشین و داده‌های هواشناسی، اقدام به مدل‌سازی دبی حاصل از ذوب برف در رودخانه نمودند. کاربرد مدل‌های SVR در پیش‌بینی دبی رودخانه در حوضه‌های آبریز آلپ توسط

Gregorio et al. (2018) انجام شده است. Uysal et al. (2016) با مدل ANN در حوضه فرات بالایی ترکیه، اقدام به پیش‌بینی روزانه دبی حاصل از ذوب برف کردند. آنها از عوامل سطح پوشش برفی، دبی، دما و بارندگی پیشین، به عنوان ورودی مدل استفاده کردند. مدل کارایی بیش از ۹۳٪ را نشان داد. شبکه‌های عصبی مصنوعی رایج، در عین محبوبیت، به‌دلیل عدم ذخیره اطلاعات زمانی عوامل ورودی، قابلیت چندانی در مدل‌سازی سری زمانی فرایندهای پیچیده هیدرولوژیکی را ندارند (Zhou et al., 2021). عدم قابلیت مزبور، از طریق توسعه روشی تحت عنوان شبکه عصبی بازگشتی، مرتفع شده است (Nagesh et al., 2004).

از سویی چالش‌های اصلی RNN‌ها، مشکلات گرادین انفجاری و ناپدید شدن هستند. به این صورت که داده‌های پیشین هر چه به جواب مورد نظر نزدیک‌تر باشند، به طور فزاینده‌ای تأثیر تأثیری بسیار بالا و هر چه از جواب مورد نظر دورتر می‌شوند، تأثیر کم‌تری می‌گذارند؛ تا جایی که تأثیر آنها صفر و در واقع ناپدید می‌شود.

رویکرد یادگیری عمیق LSTM، تحت عنوان حافظه بلند ترم های کوچک، محدودیت‌های RNN را برطرف نموده، به‌طوری‌که اطلاعات زمانی داده‌های سری زمانی را برای گام‌های زمانی بلند، ذخیره می‌نماید (Hochreiter and Schmidhuber., 1997). در سال‌های اخیر، کاربرد LSTM در مدل‌سازی هیدرولوژیکی، رشد چشمگیری داشته است. یافته‌های پژوهش‌های متعدد نشان داده‌اند که LSTM در پیش‌بینی جریان رودخانه در حوضه‌های متنوع، عملکردی رقابتی یا برتر نسبت به مدل‌های مفهومی و سایر الگوریتم‌های یادگیری ماشین دارد (Kratzert et al., 2019; Jiang et al., 2021; Wang et al., 2023). با وجود پیشرفت‌های اخیر، بیشتر مطالعات یادگیری عمیق بر پیش‌بینی جریان کلی رودخانه تمرکز دارند و تعداد مطالعاتی که LSTM را به‌طور خاص برای بازنمایی دینامیک دوره غالب ذوب برف به کار برده‌اند، محدود است (Chen et al., 2022).

از سویی دیگر، در بسیاری از حوضه‌های کوهستانی به دلیل صعب‌العبور بودن و تراکم کم ایستگاه‌های هیدرومتری، مشاهدات مستقیم تفکیک‌شده جریان ذوب برف و رواناب ناشی از بارش در دسترس نیست. در چنین شرایطی، دبی ثبت‌شده در ایستگاه‌های هیدرومتری به‌صورت مجموع سهم ذوب برف و سهم بارش مستقیم است. بنابراین، در این پژوهش، اصطلاح «دبی حاصل از ذوب برف» به‌معنای دبی مشاهده‌شده در دوره غالب ذوب برف در حوضه برفگیر بازفت-به‌کار رفته است. بدین معنی که با تحلیل الگوی فصلی دما و بارش، بازه زمانی مشخصی از سال که سهم

زمینه پیش بینی جریان در دوره ذوب برف و با هدف ارائه راهکاری کارآمد برای مدیریت منابع آب در حوضه های برف گیر انجام شده است.

مواد و روش ها

محدوده مورد مطالعه و داده های مورد استفاده


اصولاً مطالعات برف سنجی، در منطقه معرف انجام می شود. منطقه معرف به منطقه ای که حداقل پنج ماه از سال (ماه های آذر تا فروردین) پوشش برف تداوم داشته باشد، اطلاق می شود (Khorram and Sharifi, 2020). از طرفی باید امکان دسترسی به ارتفاعات برف گیر این منطقه نیز میسر باشد. مناطق بسیاری در نواحی زاگرس میانی بالاخص در سرشاخه های حوضه کارون شمالی دارای ویژگی اول هستند ولی به دلیل کوهستانی بودن، دسترسی به تمام نقاط آنها بسیار سخت و در برخی زمان ها غیرممکن است (Reisian and Porhemmat., 2013).

محدوده مورد مطالعه به عنوان محدوده معرف، حوضه بازفت واقع در عرض $31^{\circ}6'$ تا $32^{\circ}6'5$ درجه ی شمالی و طول $49^{\circ}56'$ تا $50^{\circ}46'$ درجه ی شرقی است. شکل ۱، موقعیت محدوده مورد مطالعه را نسبت به سایر حوضه های درجه ۱ و همچنین حوضه کارون، نشان می دهد.

اصلی جریان رودخانه در مقایسه با سهم ناشی از بارش مستقیم، از ذوب برف انباشته شده، تحت عنوان دوره غالب ذوب، انتخاب می شود. از این رو دبی ثبت شده در بازه زمانی مزبور، به عنوان متغیر هدف مدل در نظر گرفته می شود. چنین رویکردی با مطالعات مشابه در مدیریت جریان فصلی در حوضه های کوهستانی مطابقت دارد (Zhou et al., 2024; Adnan et al., 2024).

چالش دیگر در این حوزه، کمبود داده های زمینی است. از این رو از داده های بازتحلیل ERA5 تولید شده توسط European Centre for Medium-Range Weather Forecasts استخراج متغیرهای مورد نیاز مدل استفاده شده است (Hersbach et al., 2020). داده های ERA5 با پوشش مکانی-زمانی پیوسته، امکان بازنمایی شرایط اقلیمی حوضه را بدون وابستگی به تراکم ایستگاه های زمینی فراهم می آورند. در مطالعات اخیر هیدرولوژیکی، شواهد کارایی مطلوبی نشان داده اند (Yang et al., 2025).

با توجه به (۱) وابستگی زمانی بلندمدت فرایند ذوب برف، (۲) اثربخشی مدل های LSTM در بازنمایی دینامیک های غیرخطی سری های زمانی هیدرولوژیکی و (۳) تمرکز بر پیش بینی دبی مشاهده شده در دوره غالب ذوب برف در حوضه برفگیر بازفت، این پژوهش با هدف ارزیابی مدل LSTM در



شکل ۱- موقعیت حوضه ی کارون بزرگ و موقعیت زیرحوضه بازفت در حوضه ی کارون بزرگ

هیدرومتری حوضه بازفت در جدول (۱) آورده شده است. همچنین برای انجام این مطالعه از داده های دما، بارش و آب معادل برف بازتحلیل شده ی ارائه شده در ERA5-LAND از سایت ECMWF استفاده شد.

بازه زمانی آذر تا فروردین شامل چرخه کامل انباشت و ذوب برف در حوضه بازفت است. از نیمه بهمن به بعد، با کاهش SWE و افزایش دما، فرایند ذوب فعال شده و سهم آن در تولید جریان افزایش می یابد. داده های مشاهده ای ایستگاه

دمای هوا (T)، بارش (P)، دبی پیشین (Q) و آب معادل برف (SWE) به صورت روزانه به عنوان ورودی مدل استفاده شد. سری زمانی داده‌ها به دو قسمت آموزش و اعتبار سنجی تقسیم

گردید. داده‌ها در دوره زمانی ۱۳۹۳-۱۴۰۲ انتخاب شدند. ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد دیگر، برای اعتبارسنجی، در نظر گرفته شد.

جدول ۱- نام و مشخصات ایستگاه مورد استفاده

ایستگاه	رودخانه و نوع	کد	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)
لندی	بازفت - هیدرومتری	۲۱-۵۲۸	۵۰-۱۸-۲۲	۳۱-۴۹-۴۲	۱۰۴۰

پایگاه داده ERA5-LAND

پایگاه ECMWF در سال ۱۹۷۵ به عنوان یکی از بزرگترین آرشیوهای داده‌های هواشناسی، تأسیس شد. نسخه پنجم پیش‌بینی‌های عددی آب و هوا با عنوان ERA5 ارائه شده است. سری مزبور شامل بسیاری از خصوصیات برفی از جمله SWE است (Casson et al, 2018). ERA5-Land یک پخش مجدد از مؤلفه زمین در تجزیه و تحلیل مجدد آب و هوا ERA5، به شمار می‌آید. وضوح مکانی ERA5-Land با مقدار ۹ کیلومتر، در مقایسه با وضوح ERA5 با ۳۱ کیلومتر، بسیار بیشتر است (Balsamo et al., 2015; Hersbach et al., 2020; Lorenz & Lorenz, 2020). شایان ذکر است که دقت داده‌های ERA5-Land در مطالعات متعدد جهانی و منطقه‌ای ارزیابی شده است (Akyurek et al., 2023).

(Muñoz-Sabater et al., 2021) نشان دادند که این پایگاه داده در شبیه‌سازی چرخه هیدرولوژی نسبت به نسخه قبلی (ERA5) بهبود قابل توجهی داشته است. همچنین در محدوده ایران، مطالعات بیانگر همبستگی بالای داده‌های بارش و دمای این پایگاه با ایستگاه‌های زمینی، به‌ویژه در نواحی کوهستانی که فاقد ایستگاه هستند، می‌باشد (Khosravi et al., 2021). همچنین، مطالعه (Nouri et al., 2023) نشان داد که برای پارامتر دما، ضریب تعیین (R^2) این داده‌ها در غرب ایران بالای ۰/۹۵ است. همچنین داده‌های بازتحلیل به دلیل پیوستگی زمانی و عدم وجود داده‌های پرت (Outliers) ناشی از خطای انسانی، ورودی پایدارتری برای آموزش شبکه عصبی فراهم می‌کنند (Adib et al., 2024). از این‌رو، با تکیه بر این مستندات، از داده‌های مذکور به عنوان ورودی مدل استفاده شده است. شایان ذکر است که برای دستیابی به مقادیر برخی متغیرها نظیر آب معادل برف، صرفاً بر اساس نتیجه تحقیقات گذشته و به صورت مستقیم از پایگاه‌های داده نظیر GLDAS، استفاده شده است (Afsharipour et al., 2024).

آزمون گاما

تست گاما یک روش غیرپارامتری برای انتخاب سری متغیرهای ورودی به مدل است. متغیرهای ورودی براساس مقدار گاما و نسبت V انتخاب می‌شوند. گاما، بیانگر میزان عدم قطعیت غیرقابل حذف و نسبت V، بیانگر رابطه‌ی ورودی-خروجی است؛ به گونه‌ای که نسبت اخیر، میزان تغییرات خروجی را تحت تأثیر تغییرات ورودی مشخص می‌کند. براساس این روش، سری متغیرهای ورودی، با کمترین مقدار گاما و نسبت V، به عنوان بهترین ترکیب برای ورودی مدل در نظر گرفته می‌شود (Stefánsson et al., 1997). در مطالعه حاضر ۴ ترکیب ورودی مختلف از متغیرهای دما، بارش، پتانسیل ذوب برف و دبی پیشین در نظر گرفته شد. بهترین ترکیب ورودی با استفاده از WinGammaTM دانشگاه ولز، انگلستان تعیین شد.

مدل LSTM

برای مدل‌سازی پدیده‌هایی با همبستگی‌های بلندمدت ناشی از تغییراتی مانند تغییرات فصلی، استفاده از روش LSTM توصیه شده است (Guo et al., 2023). مدل‌سازی جریان در دوره غالب ذوب برف، به عنوان پدیده‌ای تابع تغییرات فصلی، با روش مزبور مفید است. مدل LSTM اغلب برای پیش‌بینی جریان‌های ماهانه یا سالانه بر اساس طیف وسیعی از متغیرهای ورودی استفاده می‌شود. مدل LSTM می‌تواند وابستگی‌های بلندمدت را از داده‌های متوالی، با استفاده از سلول‌های حافظه متصل به طور مکرر برای ذخیره و پردازش اطلاعات متوالی بکار بگیرد (Hochreiter and Schmidhuber, 1997). ورودی‌های مدل روزانه LSTM در هر گام زمانی، شامل بارش، دما، دبی و ویژگی‌های ثابت هر پیکسل شامل ارتفاع، عرض جغرافیایی، شیب و جهت شیب هستند (Ouyang et al., 2021; Tian et al., 2001). در تحقیق حاضر، SWE به عنوان یکی از ویژگی‌های مهم برف انباشته که تحت تأثیر مشخصات برف و تابش خورشیدی می‌باشد، با تاخیر یک روزه، به عنوان یکی از ویژگی‌های ورودی به

¹ ECMWF Reanalysis 5

در مراحل بعدی، خروجی هر زمان h_t می تواند به عنوان ورودی برای زمان بعدی استفاده شود تا ارتباط زمانی حفظ شود. در مرحله ی نهایی در زمان n خروجی نهایی شبکه ی LSTM یعنی h_n ممکن است به یک لایه متراکم یا یک نورون خروجی واحد متصل شود. تا پیش بینی نهایی انجام گیرد، که در آن جریان نهایی (q) محاسبه می شود (Hochreiter and Schmidhuber, 1997). معادلات مربوط به سلول LSTM در زیر ارائه شده است.

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

$$\text{Input gate: } i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$\text{Potential update vector: } \tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (3)$$

$$\text{Cell state: } c_t = f_t \times c_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

$$\text{Output gate: } O_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$\text{Hidden state: } h_t = \tanh(c_t) \times o_t \quad (6)$$

$$\text{Output layer: } q = W_d h_n + b_d \quad (7)$$

$$\text{Sigmoid function: } \delta(x) = 1/(1+e^{-x}) \quad (8)$$

$$\text{Tanh function: } \tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (9)$$


که در آنها f , i , $\tilde{C}$ و O به ترتیب بردارهایی هستند که نشان دهنده گیت های فراموشی، ورودی و خروجی هستند، C_t و $\tilde{C}_t$ بردارهایی برای حالت های سلول و مقادیر کاندید هستند. δ تابع سیگموئیدی، x_t بردار ورودی در زمان t ، W و U به ترتیب ماتریس وزن برای حالت ورودی و پنهان و b عبارت بایاس است. یک سلول LSTM کلاسیک در شکل ۲ نشان داده شده است.

مدل LSTM در نظر گرفته شد. در پژوهش حاضر، جداسازی صریح مؤلفه های تشکیل دهنده هیدروگراف (شامل رواناب بارش، ذوب برف و جریان پایه) انجام نشده است. منظور از جریان دوره غالب ذوب برف، دبی مشاهده شده در ماه هایی است که بر اساس رژیم هیدرولوژیکی حوضه بازفت (آذر تا فروردین) و همبستگی بالا با SWE و دما، سهم ذوب برف مؤلفه غالب تولید جریان محسوب می شود.

کد نویسی LSTM

اطلاعات ورودی که باید به صورت سلول وارد شوند توسط دروازه ی ورودی کنترل می شوند. این دروازه تعیین می کند چه میزان از اطلاعات جدید باید وارد حافظه سلول شود. سپس، در شرایطی که چند لایه میانی وجود داشته باشد، خروجی هر لایه به عنوان ورودی برای لایه ی بعدی عمل می کند. بدین ترتیب شبکه می تواند الگوهای پیچیده تر را یاد بگیرد.

در داخل سلول، برداری تولید می شود که موظف به بروزرسانی حافظه ی سلول است. این بردار از طریق تابع فعال سازی $\tanh$ ساخته شده و می تواند اطلاعات جدیدی به حالت سلول اضافه کند. در این مرحله دروازه ی فراموشی نیز عمل می کند تا مشخص شود چه بخش هایی از حالت قبلی سلول باید حذف شوند. بنابراین حافظه ی جدید ترکیبی از حالت قبلی (با وزن فراموشی) و اطلاعات جدید (با وزن ورودی) همان گونه که در معادله (۴) آمده است تشکیل می شود. سپس، دروازه خروجی تصمیم می گیرد که چه بخشی از اطلاعات حافظه باید به عنوان خروجی ظاهر شود. خروجی نهایی سلول در لحظه ی t با استفاده از رابطه (۶) محاسبه می شود.



شکل ۲- یک سلول LSTM معمولی، که در آن δ نشان دهنده تابع سیگموئیدی، $\tanh$ نشان دهنده تانژانت هیپربولیک، f نشان دهنده دروازه فراموشی، i نشان دهنده دروازه ورودی، o نشان دهنده دروازه خروجی، h حالت پنهان، c نشان دهنده حالت سلول و x بردار ورودی در گام زمانی t است

ملاک‌های ارزیابی

به‌منظور ارزیابی عملکرد مدل، از ملاک‌های نش-ساتکلیف NSE، جذر میانگین مربعات خطا RMSE، ضریب همبستگی پیرسون r و میانگین قدر مطلق خطا MAE که به‌ترتیب در روابط ۱۰ تا ۱۳ آورده شده‌اند، استفاده می‌گردد (Marasini and Pokhler., 2024; Hodson., 2022).

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{sim,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs,i})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (Q_{obs,i} - Q_{sim,i})^2} \quad (11)$$

$$r = \frac{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})(Q_{sim,i} - \bar{Q}_{sim})}{\sqrt{\sum_{i=1}^n (Q_{obs,i} - \bar{Q}_{obs})^2} \sqrt{\sum_{i=1}^n (Q_{sim,i} - \bar{Q}_{sim})^2}} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{obs,i} - Q_{sim,i}| \quad (13)$$

که در آنها، $Q_{obs,i}$ مقادیر مشاهده‌شده، $Q_{sim,i}$ مقادیر شبیه‌سازی شده یا پیش‌بینی شده، Q_{obs} میانگین مقادیر مشاهده شده، Q_{sim} میانگین مقادیر شبیه‌سازی شده و n تعداد داده‌ها است.

ضریب نش-ساتکلیف و r ، به‌ترتیب بین ۱ تا منفی بی‌نهایت و ۱- تا ۱ متغیر هستند. هر چه مقدار r به ۱ و RMSE به صفر نزدیکتر باشد، کارکرد مدل بهتر است.

نتایج و بحث

تحلیل حساسیت متغیرهای ورودی

نتایج آزمون GT برای ترکیب‌های مختلف متغیرهای ورودی در جدول ۲ آورده شده است. ترکیب ورودی M2، شامل متغیرهای دبی، دما و آب معادل برف، با مقادیر حداقلی گاما و نسبت V به‌ترتیب ۰/۰۰۱۵۱ و ۰/۰۰۴۱۲ نسبت به مقادیر متناظر در سه ترکیب M1، M3 و M4، به‌عنوان گزینه مناسب ترکیب ورودی به مدل LSTM، انتخاب شدند. کاهش هر دو مقدار بدین معناست که سیستم، رفتار کاملاً هموار داشته و به خوبی با ورودی‌های M2 تطبیق داده می‌شود.

جدول ۳، عملکرد ترکیب‌های M1، M2، M3 و M4 را به‌واسطه سه معیار NSE، R^2 و RMSE نشان می‌دهد. همانگونه که ملاحظه می‌شود ترکیب M2 شامل متغیرهای دبی، دما (T) و آب معادل برف (SWE) با کسب مقادیر معیارهای NSE، R^2 و RMSE، به‌ترتیب ۰/۹۹۴، ۰/۹۸۰ و ۰/۱۷۴، بهترین ترکیب را در مقایسه با ترکیب‌های دیگر، نشان می‌دهد.

جدول ۲- ترکیب‌های ورودی برای مدل به روش GT

نسبت V	Gamma	ترکیب ورودی‌ها	نام ترکیب
۰/۰۰۹۷۱	۰/۰۰۳۰۲	Q, SWE	M1
۰/۰۰۴۱۲	۰/۰۰۱۵۱	Q, T, SWE	M2
۰/۰۰۸۸۶	۰/۰۰۲۱۵	Q, P, SWE	M3
۰/۰۰۷۱۹	۰/۰۰۲۰۱	Q, P, T, SWE	M4


جدول ۳- عملکرد مدل LSTM در ترکیب‌های ورودی مختلف

ترکیب ورودی	NSE	R^2	RMSE
M1	۰/۹۹۳	۰/۹۷۶	۰/۲۹۱
M2	۰/۹۹۴	۰/۹۸۰	۰/۱۷۴
M3	۰/۹۹۱	۰/۹۷۴	۰/۲۵۳
M4	۰/۹۹۳	۰/۹۷۶	۰/۲۰۸

سه ویژگی مزبور در شکل ۳ نمایش داده شده است. نتایج عملکرد مدل LSTM به ازای تعداد مختلف لایه‌ها شامل ۱، ۲ و ۳ لایه، در نمودار شکل ۳-الف مقایسه شده است. همانگونه که ملاحظه می‌شود، مدل LSTM با یک لایه، با مقادیر RMSE و MAE به‌ترتیب ۰/۲۲۰ و ۰/۱۲۵، بهترین نتیجه را دارد. همچنین در نمودار ۳-ب، بهترین تعداد واحدهای پنهان، ۲۰ واحد، به‌دست آمده است.

مشخصات مدل LSTM

یکی از مشخصات مدل LSTM، اندازه دسته است که در تحقیق حاضر بنا به توضیحات و توصیه (Bengio (2012)، ۳۲ درنظر گرفته شد. سه مشخصه دیگر مربوط به مدل LSTM شامل تعداد لایه، تعداد واحدهای پنهان و الگوریتم بهینه‌ساز مدل، در شکل ۳ نمایش داده شده است. مقادیر RMSE و MAE برای



شکل ۳- عملکرد مدل LSTM بر اساس RMSE و MAE در (الف) تعداد لایه‌های LSTM؛ (ب) تعداد واحدهای پنهان و (ج) بهینه‌سازها

برابر با ۰/۳۷ و MAE برابر با ۰/۱۸، بهترین نتیجه را نشان داد. از این‌رو در مدل‌سازی جریان رودخانه با روش LSTM و به ازای ترکیب سه عامل ورودی دبی، دما و آب معادل برف (ترکیب M2)، از بهینه‌ساز Adamax استفاده شد.

همانگونه که در بخش مواد و روش‌ها ذکر شد، در مرحله پردازش داده‌ها و انتخاب نوع مدل LSTM، عملکرد هفت بهینه‌ساز، با استفاده از مقادیر پیش‌فرض ارائه شده از سوی Chollet (2019)، با هم مقایسه شد. شکل ۳-ج، نتایج مقایسه بهینه‌سازها را نشان می‌دهد. بهینه‌ساز Adamax با RMSE

شبیه‌سازی

جدول ۴، نتایج ارزیابی مدل LSTM را با متغیرهای ورودی دبی، دما و آب معادل برف (M2) در دو مرحله آموزش و آزمون نشان می‌دهد. همانگونه که ملاحظه می‌شود مدل با کسب مقدار ضریب تعیین ۰/۹۹۱ در مرحله آموزش، توانسته برآوردهایی از مقادیر جریان انجام



دهد به‌طوری‌که واریانس مقادیر مدل شده، ۹۹ درصد واریانس مقادیر مشاهده‌ای است. همچنین خطای مدل‌سازی، برابر با ۰/۰۸ در مرحله آموزش، است. مقادیر ملاک‌های ارزیابی ضریب تعیین و جذر میانگین مربعات خطا در مرحله آزمون به ترتیب ۰/۹۹۱ و ۰/۱۷۴، بیانگر کارایی LSTM در مدل‌سازی دبی حاصل از ذوب، است.

جدول ۴- ارزیابی عملکرد مدل LSTM در دو مرحله آموزش و آزمون

آموزش			آزمون		
R ²	MAE	RMSE	R ²	MAE	RMSE
۰/۹۹۱	۰/۰۴	۰/۰۸	۰/۹۹۱	۰/۱۰۸	۰/۱۷۴

نشان داده شده است. همانگونه که مشاهده می‌شود مدل مورد استفاده شده، جریان در دوره غالب ذوب برف را هم در مقادیر کم و هم در مواقع حداکثری، به‌خوبی برآورد نموده است.

مقادیر دبی روزانه مربوط به ماه‌های آذر تا فروردین مشاهده‌شده و شبیه‌سازی‌شده در مرحله آزمون برای دو سال آبی ۱۴۰۲-۱۴۰۱ و ۱۴۰۳-۱۴۰۲، به‌ترتیب در شکل‌های ۴-الف و ۴-ب





شکل ۴- مقایسه دبی روزانه ماه‌های آذر تا فروردین و مقادیر شبیه‌سازی‌شده در مرحله آزمون

(الف) سال آبی ۱۴۰۱-۱۴۰۲ و (ب) سال آبی ۱۴۰۲-۱۴۰۳

تعیین (۰/۹۹۶۸)، واریانس مقادیر برآورد شده با واریانس مقادیر مشاهده‌ای، تطابق بسیار خوبی دارند. به عبارت دیگر مقادیر برآورد شده جریان‌های کم، متوسط و همچنین زیاد توسط LSTM به خوبی با مقادیر متناظر در داده‌های مشاهده‌ای همخوانی دارند.

پراکندگی مقادیر مشاهده‌ای و برآورد شده دبی روزانه مربوط به ماه‌های آذر تا فروردین در مرحله آزمون، در دوسال آبی ۱۴۰۲-۱۴۰۱ و ۱۴۰۳-۱۴۰۲، به ترتیب در شکل ۵-الف و ۵-ب، نشان داده شده است. همانگونه که ملاحظه می‌شود، با توجه به تمرکز نقاط پیرامون خط ۴۵ درجه و همچنین با توجه به مقدار ضریب



شکل ۵- نمودار پراکندگی دبی روزانه مربوط به ماه‌های آذر تا فروردین مشاهده‌ای و برآورد شده در مرحله آزمون (الف) ۱۴۰۱-۱۴۰۲ و (ب) ۱۴۰۲-۱۴۰۳

نتیجه‌گیری

نتایج این تحقیق نشان داد مدل LSTM قادر است رفتار جریان روزانه در دوره غالب ذوب برف در حوضه بازفت را با دقت بالا شبیه‌سازی نماید ($NSE=0.994$). تأکید می‌شود که این مطالعه به دنبال تفکیک فیزیکی مؤلفه‌های هیدروگراف نبوده، بلکه مدل‌سازی پاسخ جریان در رژیم برفی حوضه، مدنظر بوده است. این در حالی است که (Pradhananga et al (2014)، با مدل درجه روز، به مقدار NSE برابر با ۸۰ درصد دست یافتند. همچنین (Uysal et al. (2016) برای پیش‌بینی جریان روزانه در ترکیه با مدل ANN به NSE تا ۹۳٪ دست پیدا نمودند. (Le et al. (2019) مدل LSTM برای مدل‌سازی بارش-رواناب، NSE را برابر با ۹۹/۲٪ بدست آوردند. همچنین Adib et al (2024)، با استفاده از تبدیل موجک و LSTM، مقدار ضریب NSE را برای جریان ورودی ماهانه به مخزن سد دز ۹۹٪ به‌دست آوردند.

از طرفی نتایج نشان داد، انتخاب تعداد لایه پنهان در عملکرد مدل LSTM سبب افزایش کارایی مدل می‌شود. این در حالی است که محققین قبلی تعداد لایه‌های مختلفی از LSTM را استفاده نمودند. به‌طوری‌که (Kratzert et al. (2018) از LSTM دو لایه و (Le et al. و Kratzert et al., (2019) از تک لایه استفاده کردند.

از دیگر عوامل مؤثر در عملکرد LSTM، انتخاب الگوریتم بهینه در اجرای مدل است. در حالی‌که محققینی نظیر Le et al (2019)، (Fan et al (2020) و (KC et al (2019)، به‌ترتیب از الگوریتم‌های بهینه‌ساز SGD، Adam و Nadam، در مدل‌سازی LSTM، استفاده کرده‌اند، در مطالعه حاضر، از مقایسه هفت الگوریتم بهینه‌ساز، بهینه‌ساز Admax بهترین نتیجه را در مدل LSTM به‌دست داد.

برتری ترکیب شامل SWE و دما نسبت به ترکیب‌های دارای بارش، نشان داد در دوره تحلیل‌شده، سیگنال هیدرولوژیکی حوضه عمدتاً تحت تأثیر فرآیند ذوب برف قرار دارد. بنابراین استفاده از داده‌های بازتحلیل ERA5-LAND در کنار مدل LSTM می‌تواند راهکاری کارآمد برای پیش‌بینی جریان در حوضه‌های کوهستانی فاقد داده کافی باشد.

تقدیر و تشکر

بدین‌وسیله نویسندگان مقاله از سازمان هواشناسی به‌دلیل در اختیار گذاشتن داده‌های مورد نیاز تحقیق و همچنین از حمایت دانشگاه شهید چمران اهواز از طریق پژوهانه شماره

SCU.WH1403.26878 مراتب قدردانی و سپاس خود را اعلام می‌دارند.

تضاد منافع نویسندگان

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

دسترسی به داده‌ها

داده‌های استفاده‌شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

نویسنده اول: انجام تحلیل‌های نرم‌افزاری/آماري و نگارش نسخه اولیه مقاله

نویسنده دوم: مفهوم‌سازی، ویرایش و بازنگری مقاله

نویسنده سوم: مشاوره و بررسی متن مقاله

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر عملی رعایت نموده‌اند و این موضوع مورد تایید همه آنها می‌باشد.

منابع

- 1- Afsharipour, F., Sharifi M. R. and Motamedi, A., 2024. Evaluation of SZIsnow and SMRI indices performance in monitoring hydrological drought in snow-fed basins using GLDAS database. *Iranian Wter Research*, 18(3), pp. 97-107. [In Persian]. <https://doi.org/10.22034/IWRJ.2024.14819.2613>
- 2- Adib, A., Pourghasemzadeh, M. and Lotfirad, M., 2024. RNN-based monthly inflow prediction for Dez Dam in Iran considering the effect of wavelet pre-processing and uncertainty analysis. *Hydrology*, 11, 155. <https://doi.org/10.3390/hydrology11090155>
3. Adnan, M., Liu, S., Saifullah, M., Iqbal, M., Saddique, Q., Ul Hussan, W. and Latif, Y., 2024. Estimation of changes in runoff and its sources in response to future climate change in a critical zone of the Karakoram mountainous region, Pakistan in the near and far future, *Geomatics, Natural Hazards and Risk*, 15(1), <https://doi.org/10.1080/19475705.2023.2291330>.
4. Akyurek, Z., Kuter, S., Karaman, Ç.H. & Akpınar, B., 2023. Understanding the snow cover climatology over Turkey from ERA5-Land reanalysis data and MODIS snow cover frequency product. *Geosciences*, 13(10), 311. <https://doi.org/10.3390/geosciences13100311>
5. Balsamo, G., Albergel, C., Beljaars, A., Bousssetta, S., Brun, E., Cloke, H., et al., 2015. *ERA-Interim/Land: A global land surface reanalysis data set. Hydrology and*

17. Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A. et al., 2020. The ERA5 global reanalysis, *Quarterly Journal of the Royal Meteorological Society*, 146(730), pp. 1999–2049. <https://doi.org/10.1002/qj.3803>.
18. Hochreiter, S. and Schmidhuber, J., 1997. Long short-term memory. *Neural Computation*, 9, pp. 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
19. Hodson, T.O., 2022. Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15, pp. 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
20. Jiang, P., 2021. A transfer Learning-Based LSTM strategy for imputing Large-Scale consecutive missing data and its application in a water quality prediction system', *Journal of Hydrology*, 602, p. 126573. <https://doi.org/10.1016/j.jhydrol.2021.126573>
21. Khorram, M., Sharifi, M. R., 2020. Performance evaluation of the SRM model under the influence of different melting months (Case study: Doab Samsami Watershed). *Iranian Water Research Journal*, 14 (1), pp. 109–117. [In Persian].
22. Khosravi, A., Kutev, V., Diop, L., and Alizadeh, M. R., 2021. Evaluation of ERA5-Land reanalysis precipitation data over Iran. *Theoretical and Applied Climatology*, 146, pp. 929–945. [In Persian].
23. 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, pp. 6005–6022. <https://doi.org/10.5194/hess-22-6005-2018>.
24. Kratzert, F., Klotz, D., Brenner, C., Schulz, K., and Herrnegger, M., 2019. Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, 23(12), pp. 5089–5110. <https://doi.org/10.5194/hess-23-5089-2019>
25. Le, X.-H., Ho, H. V., Lee, G., and Jung, S., 2019. Application of long short-term memory (LSTM) neural network for flood forecasting. *Water*, 11(7), 1387. <https://doi.org/10.3390/w11071387>.
26. Lee, J., Park, K., and Kim, S., 2023. Comparison and evaluation of machine-learning-based spatial downscaling approaches on satellite-derived precipitation data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-1/W1-2023, pp. 919–926. <https://doi.org/10.5194/isprs-annals-X-1-W1-2023-919-2023>.
27. Lundquist, J. D., Hughes, M., Henn, B., Gutmann, E. D., Livneh, B., Dozier, J., and Neiman, P., 2015. Measurements to assess daily gridded datasets across the Sierra Nevada, California. *Journal of Hydrometeorology*, 16(4), pp. 1773–1792. <https://doi.org/10.1175/JHM-D-14-0194.1>
28. Marasini, U. and Pokhrel, M., 2024. Comparative analysis of rainfall–runoff simulation using a long short-term memory (LSTM) deep learning model and a conceptual hydrological model (HEC-HMS): a case study. *Discover Civil Engineering*. <https://doi.org/10.1007/s44290-024-00084-w>
- Earth System Sciences*, 19(1), pp. 389–407. <https://doi.org/10.5194/hess-19-389-2015>
6. Bengio, Y., 2012. Practical recommendations for gradient-based training of deep architectures. In G. Montavon, G. B. Orr, & K.-R. Müller (Eds.), *Neural networks: Tricks of the trade* (2nd ed., Lecture Notes in Computer Science, Vol. 7700, pp. 437–478. Springer. https://doi.org/10.1007/978-3-642-35289-8_26
7. Callegari, M., Mazzoli, P., de Gregorio, L., Notarnicola, C., Pasoli, L., Petitta, M., & Pistocchi, A., 2015. Seasonal river discharge forecasting using support vector regression: A case study in the Italian Alps. *Water*, 7(6), pp. 2494–2515. <https://doi.org/10.3390/w7062494>
8. Casson, D.R., Werner, M., Weerts, A. and Solomatin, D., 2018. Global re-analysis datasets to improve hydrological assessment and snow water equivalent estimation in a sub-Arctic watershed. *Hydrology and Earth System Sciences*, 22, pp. 4685–4697. <https://doi.org/10.5194/hess-22-4685>
9. Chen, X., Huang, J., Wang, S., Zhou, G., Gao, H., Liu, M., Yuan, Y., Zheng, L., Li, Q. and Qi, H., 2022. A New Rainfall-Runoff Model Using Improved LSTM with Attentive Long and Short Lag-Time, *Water*, 14(5), 697. <https://doi.org/10.3390/w14050697>.
10. Chollet, F., and others, 2019. Keras [Computer software]. <https://keras.io>
11. Fan, H., Jiang, M., Xu, L., Zhu, H., Cheng, J., and Jiang, J., 2020. Comparison of long short-term memory networks and the hydrological model in runoff simulation. *Water*, 12(1), Article 175. <https://doi.org/10.3390/w12010175>
12. Gregorio, L., Callegari, M., Mazzoli, P., Bagli, S., Broccoli, D., Pistocchi, A., and Notarnicola, C., 2018. Operational river discharge forecasting with support vector regression technique applied to Alpine catchments. *Water Resources Management*, 32(1), 229–242. <https://doi.org/10.1007/s11269-017-1814-x>
13. Guo, Z., Zhang, Q.-Q., Li, N., Zhai, Y.-Q., Teng, W.-T., Liu, S.-S., and Ying, G.G., 2023. Runoff time series prediction based on hybrid models of two-stage signal decomposition methods and LSTM for the Pearl River in China. *Hydrology Research*, 54(12), pp. 1505–1521. <https://doi.org/10.2166/nh.2023.069>
14. Hamlet, A.F., Mote, P.W., Clark, M.P. and Lettenmaier, D.P., 2005. Effects of temperature and precipitation variability on snowpack trends in the western United States. *Journal of Climate*, 18(21), pp. 4545–4561. <https://doi.org/10.1175/JCLI3538.1>
15. Havens, S., Marks, D., Fitzgerald, K., Masarik, M., Flores, A.N., Kormos, P. and Hedrick, A., 2019. Approximating Input Data to a Snowmelt Model Using Weather Research and Forecasting Model Outputs In Lieu Of Meteorological Measurements. *Journal of Hydrometeorology*, 20 (5), pp. 847–862. <https://doi.org/10.1175/JHM-D-18-0146.1>
16. Hazbavi, Z. and Vafakhai, M., 2015. Snowmelt models and methods of snowmelt modeling. *Extension and Development of Watershed Management*, 3(10). [In Persian].

41. Wang, W., Cheng, Q., Chau, K., Hu, H., Zang, H., and Xu, D., 2023. An innovative hybrid model for hourly runoff forecasting based on the decomposition-least square support vector regression and whale optimization algorithm. *Journal of Hydrology*, 618, Article 129460. <https://doi.org/10.1016/j.jhydrol.2022.129460>
42. Yang, Y., Feng, D., Beck, H.E., Hu, W., Ather, A., Sengupta, A., Delle Monache, L., Hartman, R., Lin, P., Shen, C. and Pan, M., 2025. Global Daily Discharge Estimation Based on Grid Long Short-Term Memory (LSTM) Model and River Routing. *Water Resources Research*, 61, e2024WR039764. <https://doi.org/10.1029/2024WR039764>.
43. Zhou, G., Cui, M., Wan, J. and Zhang, S., 2021. A Review on Snowmelt Models: Progress and Prospect. *Sustainability*, 13(20), 11485. <https://doi.org/10.3390/su132011485>.
44. Zhou, G., Zhao, Q., Zhang, S., Zhang, D. and Li, C., 2024. Rolling forecast of snowmelt floods in data-scarce mountainous regions using weather forecast products to drive distributed energy balance hydrological model. *Journal of Hydrology*, 637, 131384. <https://doi.org/10.1016/j.jhydrol.2024.131384>.
29. Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G. et al., 2021. ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9), 4349–4383. <https://doi.org/10.5194/essd-13-4349-2021>
30. Nagesh, D., Srinivasa Raju, K., and Sathish, T., 2004. River flow forecasting using recurrent neural networks. *Water Resources Management*, 18, pp. 143–161. <https://doi.org/10.1023/B:WARM.0000039360.45081.4a>.
31. Nouri, M., Homaee, M., Pereira, L. S., and Bybordi, M., 2023. Water management dilemma in the agricultural sector of Iran: A review focusing on water governance. *Agricultural Water Management*, 288, 108480. <https://doi.org/10.1016/j.agwat.2023.108480>
32. Ouyang, W., Lawson, K., Feng, D., Ye, L., Zhang, C., and Shen, C., 2021. Continental-scale streamflow modeling of basins with reservoirs: Towards a coherent deep-learning-based strategy. *Journal of Hydrology*, 599, <https://doi.org/10.1016/j.jhydrol.2021.126455>
33. Pradhan, P., Seydewitz, T., Zhou, B., Lüdeke, M. K. B., and Kropp, J. P., 2022. Climate extremes are becoming more frequent, co-occurring, and persistent in Europe. *Anthropocene Science*, 1, pp. 264–277. <https://doi.org/10.1007/s44177-022-00035-9>
34. Petersen, L., Molotch, N. P., Jepsen, S. M., and Hay, L. E., 2022. Evaluating temperature-index models for snowmelt runoff forecasting in a changing climate. *Water Resources Research*, 58(4), e2021WR031234. <https://doi.org/10.1029/2021WR031234>
35. Pradhananga, N. S., Kayastha, R. B., Bhattarai, B. C., and Adhikary, S., 2014. Estimation of discharge from Langtang River basin, Nepal, using a glacio-hydrological model. *Annals of Glaciology*, 55(66), pp. 223–230. <https://doi.org/10.3189/2014AoG66A119>
36. Reisian, R. and Porhemmat, J., 2013. Determination of degree-day factor and snowmelt for a part of the Middle Zagros, case study: Cheri Pass. *Journal of Watershed Engineering and Management*, 6(2), pp. 165–174. [In Persian].
37. Shen, C., 2018. A trans-disciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, 54(11), pp. 8558–8593. <https://doi.org/10.1029/2018WR022643>.
38. Stefánsson, A., Končar, N., and Jones, A. J., 1997. A note on the gamma test. *Neural Computing & Applications*, 5, pp. 131–133. <https://doi.org/10.1007/BF01413866>.
39. Tian, Y. Q., Davies-Colley, R. J., Gong, P., and Thorrold, B. W. (2001). Estimating solar radiation on slopes of arbitrary aspect. *Agricultural and Forest Meteorology*, 109, pp. 67–74. [https://doi.org/10.1016/S0168-1923\(01\)00262-8](https://doi.org/10.1016/S0168-1923(01)00262-8)
40. Uysal, G., Sensoy, A., and Sorman, A. A., 2016. Improving daily streamflow forecasts in mountainous Upper Euphrates basin by multi-layer perceptron model with satellite snow products. *Journal of Hydrology*, 543, pp. 630–650. <https://doi.org/10.1016/j.jhydrol.2016.10.006>