



Golestan University



Journal of the Climate Change Research

Scientific Journal of Golestan University
Vol. 7, No. 25, Spring 2026



Evaluation of the integration of LSTM Recurrent Neural Network with deep learning metaheuristic algorithms for flood modeling in the Taleghan watershed

Ramtin Tavoosi Rad¹, Mohammad Ansari ghojghar^{2*}

1. Master Candidate, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. Email: ramtintavosirad@ut.ac.ir
2. Corresponding Author, Assistant Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. Email: ansari.ghojghar@ut.ac.ir

Article Info

Article type:
Research Full Paper

Article history:
Received: 2025-11-24
Accepted: 2026-2-14

Keywords:
Flow forecasting
Water resources
management
Flood warning systems
Novel models

ABSTRACT

Accurate river flow forecasting is a fundamental challenge in water resources management and flood warning system design. In this study, aiming to evaluate the efficiency of new deep learning models in predicting daily maximum flow, four models including LSTM, GRU-LSTM, ConvLSTM and S-LSTM were compared in five hydrometric stations of the Taleghan watershed. After data pre-processing and extraction of time-lag scenarios, the models were evaluated based on RMSE, MAE, NSE, and correlation coefficient indices in the training and test sets. The results showed that the time-memory-based models LSTM and GRU-LSTM provided significantly more accurate performance than the spatiotemporal models and developed versions. The GRU-LSTM model recorded the best accuracy with NSE higher than 0.95 and very low error, but statistical analysis showed that its difference with the LSTM model is not significant, so that the LSTM algorithm offers almost the same level of accuracy with less computational cost. In contrast, ConvLSTM and S-LSTM performed weaker and the greater dispersion of points in the correlation diagrams indicated their limitations in modeling univariate time series. Visual analysis of the correlation diagrams also showed that LSTM and GRU-LSTM had the most matching with the correlation line and were able to reconstruct temporal patterns of flow, especially peaks and troughs. Considering the balance between accuracy, stability and computational cost, the LSTM model is proposed as the final and optimal option for predicting daily maximum flow in the Taleghan watershed.

Cite this article: Tavoosi Rad, R., Ansari ghojghar, M. (2026). Evaluation of the integration of LSTM Recurrent Neural Network with deep learning metaheuristic algorithms for flood modeling in the Taleghan watershed. Journal of the Climate Change research, 7 (25), 47-64.



©The author(s)

Publisher: Golestan University

DOI: [10.30488/ccr.2026.562118.1317](https://doi.org/10.30488/ccr.2026.562118.1317)



نشریه پژوهش‌های تغییرات آب و هوایی



فصلنامه علمی دانشگاه گلستان

سال هفتم / شماره مسلسل بیست و پنجم / بهار ۱۴۰۵ / صفحات: ۶۴-۴۷

ارزیابی تلفیق شبکه عصبی بازگشتی LSTM با الگوریتم‌های فراکاوشی یادگیری عمیق به منظور مدلسازی سیلاب در حوزه آبخیز طالقان

رامتین طاوسی‌راد^۱، محمد انصاری قوجقار^{۲*}

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران،

رایانامه: ramtintavosirad@ut.ac.ir

^۲ (نویسنده مسئول) استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران،

رایانامه: ansari.ghojghar@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی تاریخ دریافت: ۱۴۰۴/۹/۴ تاریخ پذیرش: ۱۴۰۴/۱۱/۲۶ واژه‌های کلیدی: پیش‌بینی دبی مدیریت منابع آب سامانه‌های هشدار سیلاب مدل‌های نوین	پیش‌بینی دقیق دبی رودخانه‌ها یکی از چالش‌های اساسی در مدیریت منابع آب و طراحی سامانه‌های هشدار سیلاب است. در پژوهش حاضر با هدف ارزیابی کارایی مدل‌های نوین یادگیری عمیق در پیش‌بینی دبی بیشینه روزانه، چهار مدل شامل LSTM-GRU، ConvLSTM و S-LSTM در پنج ایستگاه هیدرومتری حوزه آبخیز طالقان مقایسه شدند. پس از پیش‌پردازش داده‌ها و استخراج سناریوهای تأخیر زمانی، مدل‌ها بر اساس شاخص‌های RMSE، MAE، NSE و ضریب همبستگی در مجموعه‌های آموزش و آزمون ارزیابی شدند. نتایج نشان داد که مدل‌های مبتنی بر حافظه زمانی LSTM و GRU-LSTM عملکرد به مراتب دقیق‌تری نسبت به مدل‌های مکانی زمانی و نسخه‌های توسعه داده‌شده ارائه دادند. مدل GRU-LSTM بهترین دقت را با NSE بالاتر از ۰/۹۵ و خطای بسیار پایین ثبت کرد اما نتایج آزمون آماری t-student نشان داد که اختلاف آن با مدل LSTM معنادار نیست؛ به گونه‌ای که الگوریتم LSTM تقریباً همان سطح دقت را با هزینه محاسباتی کمتر ارائه می‌دهد. در مقابل، ConvLSTM و S-LSTM عملکرد ضعیف‌تری داشتند و پراکندگی بیشتر نقاط در نمودارهای همبستگی بیان‌گر محدودیت آن‌ها در مدل‌سازی سری‌های زمانی تک‌متغیره بود. تحلیل بصری نمودارهای همبستگی نیز نشان داد که LSTM و GRU-LSTM بیشترین انطباق را با خط همبستگی داشته و قادر به بازسازی الگوهای زمانی جریان به‌ویژه پیک‌ها و افت‌ها بودند. با توجه به تعادل میان دقت، پایداری و هزینه محاسباتی، مدل LSTM به‌عنوان گزینه نهایی و بهینه برای پیش‌بینی دبی بیشینه روزانه در حوزه آبخیز طالقان پیشنهاد می‌شود.

استناد: طاوسی‌راد، رامتین؛ انصاری قوجقار، محمد (۱۴۰۵). ارزیابی تلفیق شبکه عصبی بازگشتی LSTM با الگوریتم‌های فراکاوشی یادگیری عمیق به منظور مدلسازی سیلاب در حوزه آبخیز طالقان. نشریه پژوهش‌های تغییرات آب و هوایی، ۷ (۲۵)، ۴۷-۶۴.

DOI: [10.30488/ccr.2026.562118.1317](https://doi.org/10.30488/ccr.2026.562118.1317)

ناشر: دانشگاه گلستان

© نویسندگان



مقدمه

پدیده سیلاب یکی از پرتکرارترین و مخرب‌ترین بلایای طبیعی در کشور ایران محسوب می‌گردد که طی سال‌های اخیر با دخالت عوامل انسانی، شدت و فراوانی آن افزایش پیدا کرده است. در چنین شرایطی، پیش‌بینی دقیق وقوع سیلاب به‌عنوان یک ضرورت حیاتی برای مدیریت سامانه‌های منابع آب و کاهش خسارات انسانی و اقتصادی مطرح می‌شود. با این حال برآورد دقیق دبی رودخانه به دلیل پیچیده بودن تجزیه و تحلیل سیلاب و غیر خطی بودن فرآیندهای هیدرولوژیکی مسئله‌ای دشوار است (Hosseinzadeh et al., 2021). کشور ایران در منطقه نیمه‌خشک جهان واقع شده است و بارندگی از لحاظ زمانی و مکانی دارای توزیع یکنواختی نیست. در این شرایط وقوع سیلاب در بیش‌تر نقاط کشور شایع بوده و در همین راستا، برنامه‌ریزی به منظور مهار و بهره‌مندی از این پدیده حدی اقلیمی امری ضروری است (Tavakoli et al., 2024). در کشور ایران، گسترش شهرنشینی و مهاجرت جمعیت بدون برنامه‌ریزی انجام می‌گیرد و در قالب برنامه‌هایی است که ریسک‌های سیل را نادیده گرفته‌اند یا دست پایین برآورد می‌کنند. شناسایی ریسک‌های ناشی از سیلاب و در نظر گرفتن آن برای برنامه‌ریزی کاربری اراضی موجب خواهد شد که رشد شهرها با توجه به نیاز روزافزون آن لزوماً به تشدید ریسک سیلاب منجر نشود (Kazemi et al., 2021). یکی از مهم‌ترین مشکلات در طراحی مهندسی منابع آب، برآورد حداکثر دبی سیلاب است. طراحی در بسیاری از مطالعات هیدرولوژیکی و هیدرولیکی بر اساس حجم و حداکثر دبی سیلاب صورت می‌گیرد. حتی در کشورهای پیشرفته نیز مطالعات کافی برای اندازه‌گیری میزان بارش و سیل رایج‌ترین بلایای طبیعی است که جوامع سراسر جهان را تحت تأثیر قرار می‌دهد. یکی از مهم‌ترین مشکلات در طراحی سازه‌های آبی، مطالعات هیدرولوژیکی و هیدرولیکی برآورد حداکثر حجم و دبی سیلاب است (Bahrami & Khazineh Nezhad, 2019).

مدل‌های پیش‌بینی دبی سیلاب از اهمیت زیادی برای ارزیابی خطر و مدیریت وقایع شدید برخوردار هستند. مدل‌های اصلی پیش‌بینی سیلاب امروز عمدتاً مختص داده‌های دبی جریان سیل بوده و شامل فرضیات ساده شده مختلفی می‌باشند. با توجه به این که اندازه‌گیری مستقیم سرعت جریان و دبی سیلاب در بازه‌های مختلف رودخانه‌ها با مشکلات متعددی مثل خطرات جانی، زمان طولانی برداشت‌های صحرائی و پرهزینه بودن اندازه‌گیری‌ها مواجه است باید از راهکارهای غیرمستقیم برای برآورد دبی سیلابی رودخانه‌ها استفاده شود (Shirazi et al., 2025). ماهیت غیرخطی بودن وقایع حدی اقلیمی مانند سیلاب می‌تواند توسط الگوریتم‌های هوش مصنوعی در کل حوزه آبخیز به‌خوبی پوشش داده شود. با توجه به ابعاد بالای داده‌ها و تعداد زیاد نمونه موردنیاز برای آموزش بهینه یادگیری ماشین، پیچیدگی پردازش داده‌ها به‌طور چشمگیری افزایش پیدا کرده در مقابل دقت و صحت نتایج به‌طور قابل توجهی بهبود می‌یابد. علاوه بر آن توانایی استخراج موثر رویدادهای گذشته بدون نیاز به درک مباحث فیزیکی از دیگر مزایای این مدل‌ها می‌باشد. از محبوب‌ترین مدل‌های ماشینی می‌توان به مدل خطی تعمیم یافته (GLM)^۱، مدل الگوریتم ماشین پشتیبان بردار (SVM)^۲، مدل شبکه عصبی مصنوعی (ANNs)^۳ و... نام برد (Hanifnia & Abghari, 2022). در سال‌های اخیر، روش‌های یادگیری عمیق (DL)^۴ و یادگیری ماشین (ML)^۵ به‌عنوان ابزارهای قدرتمند برای یادگیری الگوهای پیچیده زمانی مورد توجه جدی قرار گرفته‌اند؛ در میان این روش‌ها، رده‌ای از مدل‌های بازگشتی^۶ و کانولوشنی^۷ شامل شبکه عصبی حافظه طولانی کوتاه مدت (LSTM)^۸، گونه‌های سبک‌شده‌ی MiniLSTM و شبکه عصبی واحد بازگشتی گیت‌دار

1. Generalized Linear Model
2. Support Vector Machine
3. Artificial Neural Networks
4. Deep Learning
5. Machine Learning
6. Recursive model
7. Convolutional
8. Long Short-Term Memory

قانع‌کننده‌ای ارائه می‌دهد (Liao et al., 2025). لیو و همکاران (۲۰۲۲)، برای پیش‌بینی بارش با استفاده از داده‌های باد و رادار به عنوان ورودی از مدل ConvLSTM استفاده کردند. نتایج این پژوهش نشان داد ConvLSTM باعث کاهش خطای پیش‌بینی بارش و همچنین بهبود دقت تحلیل رفتار مکانی طوفان‌ها شد.

GRU معماری‌ای فشرده‌تر از LSTM است که با دروازه‌های کمتر، محاسبات و پارامترهای کمتری مصرف می‌کند (Zhang et al., 2023). ژانگ و همکاران (۲۰۲۳)، مدل هیبریدی GRU-LSTM را در مقایسه با نسخه‌های انفرادی مدل‌های مذکور به منظور پیش‌بینی سیلاب مورد مطالعه قرار دادند. نتایج نشان داد که مدل هیبریدی GRU-LSTM باعث کاهش خطای پیش‌بینی به مقدار معناداری شد و پایداری مدل را برای پیش‌بینی پیک جریان بهبود بخشید. همچنین انضاری قوجقار و همکاران (۱۴۰۳) با هدف پیش‌بینی روزهای گرد و غبار از مدل هیبریدی GRU-LSTM استفاده به عمل آوردند و مدل هیبریدی مذکور را با مدل‌های انفرادی RBF^۳ و SVM مقایسه کردند. نتایج این پژوهش ثابت کرد که مدل هیبریدی GRU-LSTM دقت بالاتری به نسبت مدل‌های انفرادی داشت.

Mini LSTM تلاش می‌کند تا با کاهش پارامترها، LSTM‌های کارا و سریع‌الانتشار برای محیط‌های کم‌منبع را بلادرنگ ارائه می‌دهد. این تغییرات ممکن است شامل حذف دروازه‌های غیرضروری، فشرده‌سازی ساختار یا آموزش با استراتژی‌های رشد-حذف باشد. برای پروژه‌هایی که می‌خواهند مدل را در ایستگاه‌های محلی یا روی سخت‌افزار محدود مستقر کنند یا نیاز به پاسخ‌گویی بسیار سریع دارند، نسخه‌های کم‌پارامتر مانند S-LSTM می‌تواند گزینه مناسب‌تری نسبت به LSTM‌های استاندارد باشد؛ همچنین آن‌ها امکان اجرای سریع‌تر آزمایش‌های حساسیت پارامتری را فراهم می‌کنند (Dai et al., 2019).

(GRU)^۱ و ترکیب‌های کانولوشن-زمانی مثل ConvLSTM بسیار کمتر در مطالعه پیش‌بینی سیلاب و جریان رودخانه به کار رفته‌اند و از طرفی نتایج امیدوارکننده‌ای ارائه داده‌اند (Oddo et al., 2024).

LSTM به عنوان یک معماری (RNN)^۲ که برای به‌خاطر سپردن وابستگی‌های بلندمدت طراحی شده است در بسیاری از مطالعات هیدرولوژیک به خوبی نشان داده است که می‌تواند روابط زمانی پیچیده میان بارش، دبی و سطح آب را مدل کند (Lindemann et al., 2021). با این حال، LSTM خالص در پردازش روابط مکانی بین سلول‌های یک پهنه آبخیز ناتوان است مگر آن که ویژگی‌های مکانی به صورت جداگانه مهندسی شوند (Xi et al., 2024). در پژوهش زینعلی و همکاران (۱۴۰۱)، جریان ورودی مخازن سدها با استفاده از مدل LSTM پیش‌بینی گردید. نتایج نشان داد که مدل LSTM توانست خطای پیش‌بینی جریان را نسبت به شبکه‌های عصبی کلاسیک به طور محسوسی کاهش دهد و همچنین دقت پیش‌بینی را بهبود بخشد. همچنین روزینا (۲۰۲۳) به مقایسه مدل‌های LSTM، GRU و S-RNN به منظور پیش‌بینی سیلاب با داده‌های واقعی هیدرولیکی پرداخت. نتایج نشان داد که مدل LSTM بهترین عملکرد را از نظر دقت به منظور پیش‌بینی سیلاب ارائه داد.

ConvLSTM مدل تکامل یافته‌ای است که مکانیزم کانولوشن را در درون ساختار زمانی LSTM وارد می‌کند تا هم‌زمان اطلاعات مکانی و زمانی را یاد گیرد؛ این ویژگی، ConvLSTM را برای مسائلی مانند پیش‌بینی توزیع دوبعدی عمق پهنه سیلاب و شبیه‌سازی تهاجم آب شهری بسیار مناسب ساخته است. نکته عملی این است که ConvLSTM هنگام مقیاس‌پذیری به شبکه‌ها و داده‌های بزرگ، نیاز به حافظه و محاسبات بیشتری دارد اما برای مسائل پهنه‌بندی سیلاب که اطلاعات مکانی با رزولوشن پیکسلی وارد مدل می‌شوند، معمولاً نتایج بسیار

1. Gated Recurrent Unit

2. Recurrent Neural Networks

3. Radial Basis Function


هیدرولوژیکی سفیدرود شناخته می‌شود. محدوده مورد مطالعه بین عرض‌های جغرافیایی $36^{\circ}20'48''$ تا $36^{\circ}50'35''$ شمالی و طول‌های $51^{\circ}11'07''$ شرقی قرار دارد و مساحتی حدود ۱۲۴۳ کیلومتر مربع را در بر می‌گیرد. موقعیت کوهستانی، توپوگرافی پیچیده و تغییرات قابل توجه ارتفاعی باعث شده‌اند که این حوزه نسبت به رخداد سیلاب‌های ناگهانی و فصلی حساس باشد (Ebrahimi et al., 2020).

در این پژوهش با هدف ارزیابی کارایی مدل‌های نوین یادگیری ماشین و یادگیری عمیق در پیش‌بینی سیلاب، چهار الگوریتم LSTM، ConvLSTM، GRU-LSTM و S-LSTM — مورد مقایسه قرار گرفتند. برای این منظور، داده‌های دبی بیشینه روزانه پنج ایستگاه هیدرومتری فعال در محدوده طالقان در بازه زمانی ۳۰ ساله (۱۴۰۰-۱۳۷۱) گردآوری و پس از پیش‌پردازش به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفت. کلیه مراحل مدلسازی و ارزیابی نیز در محیط نرم‌افزار R اجرا شد تا امکان مقایسه دقیق عملکرد مدل‌ها در بازسازی رفتار سیلابی حوضه فراهم شود. در پژوهش حاضر از داده‌های پنج ایستگاه هیدرومتری استفاده گردید که جدول ۱ مشخصات ایستگاه‌ها را نشان می‌دهد.

با وجود توسعه گسترده روش‌های یادگیری ماشین و یادگیری عمیق در پیش‌بینی سیلاب، اغلب پژوهش‌های به انجام رسیده در کشور ایران تنها بر یک ساختار منفرد مانند LSTM یا GRU تمرکز داشته و مقایسه‌ای جامع میان معماری‌های پیشرفته‌تر همچون ConvLSTM، MiniLSTM، GRU-LSTM و LSTM‌ها انجام نداده‌اند. همچنین بخش عمده مطالعات موجود به‌صورت محدود به مقیاس‌های زمانی کوتاه یا داده‌های تک‌منبعی پرداخته و عملکرد مدل‌ها در شرایط اقلیمی متنوع و رخدادهای حدی بررسی نشده است. از این‌رو، خلأ مهمی در درک تفاوت کارایی این معماری‌ها در مدل‌سازی پویایی‌های مکانی زمانی سیلاب وجود دارد. بر این اساس، هدف پژوهش حاضر ارزیابی و مقایسه‌ی سیستماتیک این چهار مدل یادگیری عمیق در پیش‌بینی سیلاب و تبیین نقاط قوت، ضعف و قابلیت کاربرد آن‌ها در سامانه‌های هشدار سریع سیلاب است.

روش‌شناسی پژوهش

منطقه مورد مطالعه: شکل ۱ نمایی از موقعیت جغرافیایی حوزه آبخیز طالقان و پراکنش ایستگاه‌های هیدرومتری مورد استفاده در این پژوهش را ارائه می‌دهد. این حوزه در دامنه‌های جنوبی رشته‌کوه البرز و در محدوده شمال‌غربی شهرستان کرج واقع شده و به‌عنوان یکی از زیرحوضه‌های مهم و بالادستی سیستم



شکل ۱: منطقه و ایستگاه‌های مورد مطالعه

جدول ۱: مشخصات ایستگاه‌های مورد مطالعه

شماره ردیف	کد ایستگاه	نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی (درجه دقیقه ثانیه)	عرض جغرافیایی (درجه دقیقه ثانیه)	نام رودخانه میانگین دبی بیشینه روزانه (مترمکعب بر ثانیه)
۱	۱۷۰۵۰	گت ده	۲۳۵۳	۵۱-۰۳-۵۵	۳۶-۱۰-۳۱	شاهرود ۱/۸۵۸
۲	۱۷۸۷۴	دهدر	۲۲۶۸	۵۰-۱۲-۱۹	۳۶-۱۰-۴۰	دهدر ۱/۵۸۶
۳	۱۷۹۶۵	مهران جویستان	۲۰۴۹	۵۰-۵۴-۳۷	۳۶-۱۰-۵۳	شاهرود ۲/۳۲۳
۴	۱۷۹۶۶	جویستان	۱۹۷۹	۵۰-۵۴-۲۸	۳۶-۱۰-۵۴	شاهرود ۷/۶۵۵
۵	۱۷۹۳۴	علیزان جویستان	۱۹۵۳	۵۰-۵۳-۲۹	۳۶-۱۱-۱۷	شاهرود ۱/۸۸۴

همسایگان محلی آن تعیین می‌کند. این کار را می‌توان با استفاده از یک عملگر کانولوشن در انتقال‌های حالت به حالت و ورودی به حالت به دست آورد (شکل ۲). معادلات کلیدی ConvLSTM در روابط ۱ تا ۵ نشان داده شده‌اند که در آن * نشان دهنده عملگر کانولوشن و $\odot$ نشان دهنده ضرب‌های امارد^۲ است (Shi et al., 2015):

(۱)

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i)$$

(۲)

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f)$$

(۳)

$$C_t = f_t \odot C_{t-1} + i_t \odot \tan h(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c)$$

(۴)

$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \odot C_{t-1} + b_o)$$

(۵)

$$H_t = o_t \odot \tan h(C_t)$$

در آن C_t حالت سلول به‌منظور انتقال اطلاعات، i_t گیت ورودی به‌منظور دریافت داده‌های ورودی، f_t گیت فراموشی به‌منظور فشرده‌سازی داده‌ها، o_t گیت خروجی به‌منظور خارج کردن داده‌ها با حالت سلول و H_t تابع پنهان است.

شبکه عصبی حافظه کوتاه و بلند مدت (LSTM):

این مدل نوع خاصی از شبکه عصبی بازگشتی بوده که بجای توابع ساده از توابع پیچیده و ترکیبی به‌منظور تنظیم و تقویت حافظه کوتاه‌مدت استفاده می‌کند و قابلیت یادگیری وابستگی‌های بلندمدت را علاوه بر

مدل ConvLSTM: مدل‌های ConvLSTM با استفاده از یک معماری چند سر (multi-headed) ساخته شدند و از ترکیب دو مدل CNN^۱ و LSTM تشکیل می‌شوند. به طوری که هر ورودی داده‌های فضازمانی به‌عنوان یک سر شبکه عصبی، جداگانه پردازش می‌شود. سپس خروجی هر سر ConvLSTM ادغام شده و با LSTM پایه ترکیب می‌شود تا یک خروجی واحد برای متغیر پاسخ مرحله جریان تولید شود. این ساختار مدل به گونه‌ای طراحی شده است که هر ورودی را به طور موثرتری آموزش دهد و به کمی‌سازی اثرات حاشیه‌ای داده‌های فضا-زمانی بیشتر به عنوان پیش‌بینی‌کننده کمک کند (Oddo et al., 2024). لازم به ذکر است که مدل ConvLSTM اساساً برای داده‌های مکانی-زمانی با ساختار شبکه‌ای طراحی شده است و در این پژوهش، صرفاً با هدف مقایسه عملکرد معماری‌های مختلف یادگیری عمیق، بر روی سری زمانی تک‌متغیره دبی آموزش داده شده است. شبکه ConvLSTM مزایای شبکه‌های CNN و LSTM را با هم ترکیب می‌کند. از طرفی می‌تواند به طور خودکار بازنمایی‌های سلسله مراتبی از داده‌های ورودی را یاد بگیرد و همچنین جزئیات فضایی سطح پایین و الگوهای زمانی سطح بالا را ثبت کند (Zhang et al., 2024).


ConvLSTM حالت آینده یک سلول خاص در شبکه را با استفاده از ورودی‌ها و حالت‌های گذشته

2. Hadamard product

1. Convolutional Neural Networks

زمانی استفاده شود. با توجه به نوع مسئله و ویژگی‌های خاص هر سری زمانی، می‌توان یکی از انواع مدل‌های LSTM را استفاده نمود (Zeinali et al., 2024).

وابستگی‌های کوتاه‌مدت دارد. هدف این نوع شبکه، پردازش داده‌هایی است که نیاز است وابستگی‌های بلندمدت آن‌ها در مدل در نظر گرفته شود. این نوع از شبکه عصبی می‌تواند در پیش‌بینی داده‌های سری



شکل ۲: ساختار شبکه‌های بازگشتی LSTM (Zeinali et al., 2024)

پیش‌بینی انجام گیرد. ساختار مدل پیشنهادی در شکل ۴ نمایش داده شده است. روش پیشنهادی یک ساختار چهارلایه است. این چهار لایه عبارتند از: گیت ورودی، GRU، LSTM و گیت خروجی. در لایه گیت ورودی هر یک از ویژگی‌های ورودی که مربوط به یک پیش‌بینی هستند به ورودی‌های GRU داده می‌شوند. در لایه GRU، ورودی لایه، بردارهایی هستند که از لایه ورودی گرفته شده‌اند. در لایه LSTM و ورودی لایه، بردارهایی هستند که از لایه GRU گرفته شده‌اند (Ansari ghoghhar et al., 2021). ساختار سلول‌های GRU در شکل ۳ و سلول‌های GRU به صورت روابط ۱۲ تا ۱۴ نشان داده شده است:

$$u_t = \sigma(W_u \cdot [X'_t, h_{t-1}]) \quad (12)$$

$$r_t = \sigma(W_r \cdot [X'_t, h_{t-1}]) \quad (13)$$

$$h_t = (1 - u_t) \odot h_{t-1} + u_t \odot \tan h(W \cdot [X'_t, r_t \odot h_{t-1}]) \quad (14)$$

در روابط ۱۲ تا ۱۴ نتیجه گیت بروزرسانی، u_t است، نتیجه گیت بازنشانی، r_t است و W_u ، W_r و W به ترتیب وزن‌های گیت بروزرسانی، گیت بازنشانی و حالت سلول هستند.

معادلات مربوط به هر بلوک حافظه در ساختار LSTM در روابط ۶ تا ۱۱ مشخص شده است:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (6)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (7)$$

$$\tilde{c}_t = \tan h(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (8)$$


$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (9)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (10)$$


$$h_t = o_t * \tan(c_t) \quad (11)$$

که در آن W ماتریس وزن، b بردار بایاس، $\sigma()$ تابع سیگموئید و $\tan h()$ تابع تانژانت هایپربولیک هستند. متغیرهای ورودی x_t و h_{t-1} وارد چهار دروازه به نام‌های دروازه ورودی (i_t)، دروازه خروجی (o_t)، دروازه فراموشی (f_t) و سلول حالت ($\tilde{c}_t$) می‌شوند (Ghaffari Razin et al., 2023).

مدل هیبریدی GRU-LSTM: LSTM نسخه بهبود یافته شبکه‌های بازگشتی است و به تازگی الگوریتم GRU برای بهبود این شبکه‌ها پیشنهاد شده است. در فرآیند ترکیب خروجی، لایه GRU به لایه LSTM ارسال می‌شود و خروجی لایه LSTM پس از ادغام به لایه‌های تمام متصل می‌رسد. خروجی لایه‌های تمام متصل نیز به لایه رگرسیون فرستاده می‌شود تا فرآیند



شکل ۳: ساختار سلول‌های GRU



شکل ۴ ساختار مدل هیبریدی GRU-LSTM (Ansari ghoghhar et al., 2021)

تعداد وزن‌های بازگشتی و ورودی کاهش یابد و مدل برای کاربردهای محیطی و هیدرولوژیکی با محدودیت محاسباتی مناسب باشد. در Slim-LSTM، گیت ورودی و گیت خروجی حذف شده و تنها یک گیت فراموشی ساده‌شده و یک گیت تولید حالت سلولی باقی می‌ماند. این ساده‌سازی موجب کاهش ۵۰ تا ۶۵ درصدی پارامترهای شبکه می‌شود (Akande & Salem, 2019).

در Slim-LSTM تلاش می‌شود با حذف یا ادغام برخی گیت‌ها و یا اشتراک‌گذاری وزن‌ها، تعداد پارامترها کاهش یابد ولی رفتار حافظه‌ای حفظ شود.

مدل S-LSTM: مدل S-LSTM که در پژوهش حاضر به‌عنوان نسخه‌ی سبک‌شده LSTM ارائه گردیده است، بر پایه معماری Slim-LSTM طراحی شده است. هدف اصلی این معماری، کاهش تعداد پارامترها، کاهش هزینه محاسباتی و افزایش سرعت آموزش است؛ به‌گونه‌ای که توانایی LSTM در مدل‌سازی وابستگی‌های زمانی بلندمدت حفظ شود. در مدل LSTM استاندارد، چهار گیت شامل ورودی، فراموشی، خروجی و به‌روزرسانی وجود دارد اما در Slim-LSTM، ساختار گیت‌ها فشرده‌سازی شده و وزن‌ها اشتراک‌گذاری و کاهش یافته‌اند. این کار باعث می‌شود

معیارهای ارزیابی مدل: در این پژوهش، به منظور سنجش دقت مدل‌ها و مقایسه عملکرد آن‌ها در پیش‌بینی دبی بیشینه روزانه، از چهار شاخص ارزیابی پرکاربرد در مدل‌سازی هیدرولوژیکی استفاده شد. این شاخص‌ها شامل ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، شاخص کارایی نش ساتکلیف (NSE) و ضریب همبستگی (R) هستند. هر یک از این معیارها جنبه‌ای متفاوت از عملکرد مدل را نشان می‌دهند و در کنار یکدیگر امکان ارزیابی دقیق و چندبعدی مدل‌ها را فراهم می‌کنند.

شاخص RMSE میزان پراکندگی خطا بین مقادیر پیش‌بینی‌شده و مشاهداتی را نشان می‌دهد و نسبت به خطاهای بزرگ حساس‌تر است. مقدار کمتر RMSE بیانگر دقت بیشتر مدل در بازسازی مقدار واقعی دبی است و این معیار با رابطه ۱۹ محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - f_i)^2} \quad (19)$$

در روابط ۱۹ تا ۲۲، f_i مقادیر پیش‌بینی شده در گام زمانی i ام، o_i مقادیر مشاهداتی در گام زمانی i ام، $\bar{f}$ میانگین مقادیر پیش‌بینی شده، n تعداد داده‌ها و $\bar{o}$ میانگین مقادیر مشاهداتی می‌باشد.

MAE متوسط اختلاف مطلق بین داده‌های مشاهده‌ای و پیش‌بینی‌شده را نشان می‌دهد و به‌عنوان معیاری ساده، شفاف و قابل تفسیر برای سنجش میانگین خطای مدل استفاده می‌شود. در این معیار نیز مقدار کمتر نشان‌دهنده عملکرد بهتر مدل است و با رابطه ۲۰ محاسبه می‌شود.

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - f_i| \quad (20)$$

شاخص NSE توانایی مدل در بازتولید تغییرات مقادیر مشاهده‌شده را اندازه‌گیری می‌کند. مقدار این شاخص بین منفی بی‌نهایت تا ۱ متغیر است که مقادیر نزدیک به ۱ عملکرد بسیار مطلوب مدل را نشان می‌دهد. این

یک فرم عمومی و متداول که در مجموعه-Slim LSTM شرح داده است شده به صورت روابط ۱۵ تا ۱۸ نمایش داده شده است:

$$(15)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (16)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (17)$$

$$C_t = f_t \odot C_{t-1} + (1 - f_t) \odot \tilde{C}_t \quad (18)$$

$h_t = \tanh(C_t)$
که در آن f_t گیت فراموشی ساده شده (تنها گیت کنترلی)، i_t حالت کاندیدای ساده، $\tilde{C}_t$ به‌روزرسانی حالت سلولی با معادل‌سازی و h_t خروجی بدون گیت است. در این حالت تعداد ماتریس‌ها کاهش یافته و با یک گیت کنترلی عملیات‌های مورد نظر انجام می‌شود (Salem, 2018).

مدل‌های پیش‌بینی: در پژوهش حاضر به‌منظور پیش‌بینی دبی بیشینه روزانه در حوزه آبخیز طالقان، چهار مدل یادگیری عمیق شامل LSTM، GRU، LSTM و ConvLSTM و S-LSTM ارزیابی شدند. ورودی مدل‌ها مبتنی بر سری زمانی دبی بیشینه روزانه بوده که پس از استخراج مقادیر بیشینه روزانه، برای پیش‌بینی ماه آینده از مقادیر دبی گذشته به‌عنوان متغیرهای تأخیری استفاده شد. برای بررسی نقش حافظه زمانی و طول سری ورودی، چهار سناریوی تأخیری تعریف گردید که هر یک بر اساس یک، دو، سه و چهار فصل گذشته (معادل ۳، ۶، ۹ و ۱۲ ماه قبل) طراحی شده‌اند. در هر ترکیب، مقدار دبی بیشینه ماه آینده (Q_{t+1}) با استفاده از مقادیر دبی بیشینه ثبت‌شده در ماه‌های پیشین تخمین زده می‌شود.

$$\text{ترکیب ۱)} \quad Q_{(t+1)} \hat{=} Q_{(t)} \quad (1)$$

$$\text{ترکیب ۲)} \quad Q_{(t+1)} \hat{=} (Q_{(t)} \cdot Q_{(t-1)}) \quad (2)$$

$$\text{ترکیب ۳)} \quad Q_{(t+1)} \hat{=} (Q_{(t)} \cdot Q_{(t-1)} \cdot Q_{(t-2)}) \quad (3)$$

$$\text{ترکیب ۴)} \quad Q_{(t+1)} \hat{=} (Q_{(t)} \cdot Q_{(t-1)} \cdot Q_{(t-2)} \cdot Q_{(t-3)}) \quad (4)$$

خروجی مدل و داده‌های واقعی است. با کمک رابطه ۲۲ ضریب همبستگی محاسبه می‌شود.


$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (22)$$

نمودار جریانی پژوهش حاضر در شکل ۵ نمایش داده شده است.

شاخص یکی از معتبرترین معیارها در مدل‌سازی هیدرولوژیک است و با رابطه ۲۱ نشان داده شده است:

$$NS = 1 - \frac{\sum_{i=1}^n (o_i - f_i)^2}{\sum_{i=1}^n (\bar{o} - o_i)^2} \quad (21)$$

ضریب همبستگی رابطه خطی بین مقادیر پیش‌بینی شده و مشاهده شده را نشان می‌دهد. مقدار این شاخص بین ۱- تا ۱ قرار دارد و مقادیر نزدیک به ۱ بیان‌گر همبستگی مثبت قوی و مطابقت بالا میان



شکل ۵: فلوچارت مراحل انجام پژوهش

بحث و نتایج

نتایج به دست آمده از اجرای چهار مدل یادگیری عمیق شامل LSTM، GRU-LSTM، ConvLSTM و S-LSTM در پنج ایستگاه هیدرومتری حوزه آبخیز طالقان نشان داد که رفتار مدل‌ها در تمامی سناریوهای تأخیر زمانی (۳، ۶، ۹ و ۱۲ ماهه) از الگوی نسبتاً ثابتی پیروی می‌کند. تحلیل شاخص‌های ارزیابی شامل NSE، RMSE، MAE و R در مجموعه‌های آموزش و آزمون نشان داد که مدل‌های مبتنی بر حافظه زمانی کلاسیک LSTM و GRU-LSTM در مدل‌سازی روندهای زمانی جریان پایدارتر و دقیق‌تر عمل می‌کنند. همچنین این نوع مدل‌ها قابلیت بیش‌تری در شبیه‌سازی دبی بیشینه روزانه داشته و در استخراج الگوهای سری زمانی موفق‌تر از دو مدل دیگر عمل کرده‌اند.

در میان این مدل‌ها، GRU-LSTM بهترین عملکرد را به ثبت رساند. این مدل در اغلب ایستگاه‌ها مقادیر NSE بالاتر از ۰/۹۶، مقادیر RMSE بسیار پایین و ضرایب همبستگی بیش از ۰/۹۵ را در مجموعه آزمون ثبت کرد. این برتری عمدتاً ناشی از ترکیب مزایای دو معماری GRU و LSTM است؛ با ساختاری سبک‌تر توانسته گرادیان را بهتر پایدار کند و LSTM نیز وابستگی‌های بلندمدت سری زمانی جریان را با دقت بیشتری بازسازی کرده است. با این حال، اختلاف عددی GRU-LSTM با LSTM بسیار ناچیز بود و آزمون اختلاف میانگین‌ها نشان می‌دهد که این تفاوت از نظر آماری معنادار نیست. بنابراین، هرچند GRU-LSTM بهترین عملکرد را دارد اما مزیت آن نسبت به LSTM به اندازه‌ای نیست که هزینه محاسباتی بیشتر آن را توجیه کند. در مقابل، مدل LSTM عملکردی کاملاً قابل رقابت با GRU-LSTM داشت. مقادیر NSE در بیش‌تر ایستگاه‌ها در بازه ۰/۹۴ تا ۰/۹۶ قرار گرفت و RMSE تنها چند صدم بیش‌تر از مدل هیبریدی بود. این موضوع با پژوهش‌های علمی انجام شده در این حوزه هم‌راستا است؛ برای نمونه، مطالعه وانگ و همکاران (۲۰۲۳) نشان داد که LSTM در پیش‌بینی جریان

ماهانه در بسیاری از حوضه‌ها عملکردی برابر یا حتی بهتر از مدل‌های ترکیبی GRU-LSTM ثبت کرده و پیچیدگی بیش‌تر همواره تضمین‌کننده افزایش دقت نیست. همچنین مطالعه ژانگ و همکاران (۲۰۲۳) نشان داد که بهینه‌سازی ساده ساختار LSTM می‌تواند آن را به سطح مدل‌های هیبریدی برساند و استفاده از GRU-LSTM تنها در برخی حوضه‌ها بهبود بسیار جزئی دارد.

در گروه دوم مدل‌ها یعنی ConvLSTM و S-LSTM، الگوی رفتاری متفاوتی دیده شد. عملکرد ConvLSTM که به‌طور ویژه برای یادگیری الگوهای فضایی زمانی طراحی شده است تنها کمی بهتر از S-LSTM بود. این شباهت در عملکرد نشان می‌دهد که کیفیت داده‌های موجود و ماهیت سری زمانی دبی بیشینه روزانه فاقد اطلاعات مکانی کافی بوده که مزیت اصلی ConvLSTM در یادگیری وابستگی‌های مکانی را فعال کند. از آنجا که ورودی‌های داده در این پژوهش تک‌منبعی و عمدتاً زمانی بوده‌اند، مدل ConvLSTM نمی‌تواند آن گونه که برای داده‌های رادار بارش یا نقشه‌های سیلاب عمل می‌کند، مزیت واقعی خود را بروز دهد. پژوهش لیو و همکاران (۲۰۲۲) نیز نشان می‌دهد که مدل ترکیبی ConvLSTM زمانی قادر به ارائه عملکرد قابل قبول و اثبات برتری به نسبت سایر مدل‌ها می‌باشد که داده‌های ورودی مانند داده‌های رادار بارش دارای ساختار پیکسلی و فضایی باشند. از سوی دیگر، مدل S-LSTM در پژوهش حاضر، نسخه سبک LSTM اگرچه ساده‌تر و دارای پارامترهای کمتر است اما عملکردی قابل قبول ارائه داد. کمترین مقدار NSE مربوط به S-LSTM در محدوده ۰/۶۶ تا ۰/۶۹ قرار داشت که گرچه کمتر از دو مدل اصلی است اما نشان می‌دهد که نسخه‌های سبک‌شده نیز برای تحلیل جریان‌های بیشینه روزانه توانایی پایه‌ای را حفظ می‌کنند. اختلاف عملکرد ConvLSTM و S-LSTM نیز بسیار ناچیز است که مجدداً تأکید می‌کند ورودی‌های بدون بُعد مکانی، ConvLSTM را از پتانسیل اصلی خود محروم می‌کند.

در تحلیل کلی، تفاوت عملکرد میان گروه اول LSTM و GRU-LSTM و گروه دوم ConvLSTM و S-LSTM کاملاً معنادار و واضح بود اما تفاوت عملکرد در داخل هر گروه بسیار ناچیز است. مدل‌های گروه اول با قدرت، روابط طولی جریان را پوشش می‌دهند در حالی که مدل‌های گروه دوم برای داده‌های کاملاً زمانی مناسب نیستند. تفاوت قابل توجه در NSE، RMSE، MAE و R نشان می‌دهد که برای پیش‌بینی دبی بیشینه روزانه، یادگیری زمانی مهم‌ترین عنصر است و اطلاعات مکانی نقش کمتری دارند.

از نظر تصمیم‌گیری کاربردی، انتخاب مدل نهایی باید علاوه بر دقت، بر اساس پایداری، زمان آموزش، پیچیدگی شبکه، حجم پارامترها و قابلیت اجرا در محیط‌های عملیاتی انجام شود. همچنین نشان

می‌دهد که افزایش پیچیدگی مدل در تمامی حالات منجر به بهبود معنادار پیش‌بینی‌ها نشده و انتخاب مدل تنها بر مبنای دقت آن باعث خسارات قابل توجهی می‌گردد. از آنجا که مدل GRU-LSTM تنها اندکی بهتر از LSTM است اما چندین برابر سنگین‌تر بوده و زمان آموزش آن نیز بیشتر است، استفاده از LSTM به عنوان مدل نهایی پژوهش یک انتخاب کاملاً منطقی، کارآمد و سازگار با شرایط واقعی سامانه‌های هشدار سیلاب است. مدل LSTM در عین سادگی، پایداری عددی، سرعت آموزش و قابلیت تعمیم قابل توجهی دارد و برای مدل‌سازی جریان روزانه به‌ویژه در حوضه‌هایی مانند طالقان که وابستگی‌های بلندمدت نقش بیش‌تری دارند، گزینه‌ای بهینه محسوب می‌شود.

جدول ۲ - نتایج آماری داده‌های ورودی جهت مدل سازی و پیش‌بینی سیلاب با مدل ConvLSTM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
جوسان (۱۷۹۶۶)	۴	۰/۷۸۵	۱/۶۰۳	۱/۴۴۴	۰/۷۷۱	۰/۷۵۴	۱/۶۱۱	۱/۴۵۳	۰/۷۴۳
	۳	۰/۷۸۱	۱/۶۰۷	۱/۴۴۷	۰/۷۶۷	۰/۷۵۱	۱/۶۱۴	۱/۴۵۹	۰/۷۳۹
	۲	۰/۷۷۶	۱/۶۱۱	۱/۴۵۱	۰/۷۶۳	۰/۷۴۶	۱/۶۱۷	۱/۴۶۱	۰/۷۳۳
	۱	۰/۷۷۳	۱/۶۱۳	۱/۴۵۵	۰/۷۵۹	۰/۷۴۱	۱/۶۲۱	۱/۴۶۴	۰/۷۲۹
مهران جوسان (۱۷۹۶۵)	۴	۰/۷۸۴	۰/۵۶۹	۰/۵۴۸	۰/۷۶۹	۰/۷۵۳	۰/۵۷۱	۰/۵۵۱	۰/۷۴۲
	۳	۰/۷۸۱	۰/۵۷۳	۰/۵۵۱	۰/۷۶۶	۰/۷۴۹	۰/۵۷۸	۰/۵۵۳	۰/۷۳۸
	۲	۰/۷۷۵	۰/۵۷۸	۰/۵۵۴	۰/۷۶۲	۰/۷۴۵	۰/۵۸۲	۰/۵۶۱	۰/۷۳۲
	۱	۰/۷۷۲	۰/۵۸۱	۰/۵۵۹	۰/۷۵۸	۰/۷۳۹	۰/۵۸۶	۰/۵۶۴	۰/۷۲۸
علیزان جوسان (۱۷۹۳۴)	۴	۰/۷۸۴	۰/۴۲۳	۰/۴۰۳	۰/۷۶۸	۰/۷۵۲	۰/۴۲۷	۰/۴۰۹	۰/۷۴۱
	۳	۰/۷۷۹	۰/۴۲۵	۰/۴۰۷	۰/۷۶۵	۰/۷۴۸	۰/۴۳۱	۰/۴۱۲	۰/۷۳۷
	۲	۰/۷۷۴	۰/۴۳۱	۰/۴۱۱	۰/۷۶۱	۰/۷۴۴	۰/۴۳۲	۰/۴۱۴	۰/۷۳۱
	۱	۰/۷۷۱	۰/۴۳۷	۰/۴۱۶	۰/۷۵۷	۰/۷۳۸	۰/۴۳۹	۰/۴۱۸	۰/۷۲۷
گت ده (۱۷۰۵۰)	۴	۰/۷۸۳	۰/۴۴۲	۰/۴۱۷	۰/۷۶۶	۰/۷۵۱	۰/۴۴۳	۰/۴۲۱	۰/۷۴۱
	۳	۰/۷۷۷	۰/۴۴۴	۰/۴۱۸	۰/۷۶۴	۰/۷۴۷	۰/۴۴۶	۰/۴۲۴	۰/۷۳۶
	۲	۰/۷۷۳	۰/۴۴۷	۰/۴۲۳	۰/۷۵۹	۰/۷۴۳	۰/۴۴۹	۰/۴۲۸	۰/۷۲۹
	۱	۰/۷۶۹	۰/۴۵۱	۰/۴۲۵	۰/۷۵۶	۰/۷۳۷	۰/۴۵۳	۰/۴۲۹	۰/۷۲۶
دهدر (۱۷۸۷۴)	۴	۰/۷۸۱	۰/۳۸۵	۰/۳۷۳	۰/۷۶۵	۰/۷۴۹	۰/۳۹۱	۰/۳۸۴	۰/۷۳۹
	۳	۰/۷۷۶	۰/۳۸۶	۰/۳۷۵	۰/۷۶۳	۰/۷۴۶	۰/۳۹۴	۰/۳۸۵	۰/۷۳۵
	۲	۰/۷۷۲	۰/۳۸۸	۰/۳۷۵	۰/۷۵۸	۰/۷۴۲	۰/۴۰۲	۰/۳۸۶	۰/۷۲۸
	۱	۰/۷۶۸	۰/۳۹۱	۰/۳۷۹	۰/۷۵۵	۰/۷۳۶	۰/۴۰۷	۰/۳۹۱	۰/۷۲۴

جدول ۳: نتایج آماری داده‌های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل S-LSTM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
جوسان (۱۷۹۶۶)	۴	۰/۶۸۲	۱/۵۸۶	۱/۷۲۳	۰/۷۱۳	۰/۶۷۴	۱/۵۹۵	۱/۷۳۱	۰/۶۹۵
	۳	۰/۶۷۳	۱/۵۹۱	۱/۷۲۴	۰/۷۰۹	۰/۶۶۹	۱/۶۰۲	۱/۷۳۲	۰/۶۹۱
	۲	۰/۶۶۹	۱/۵۹۳	۱/۷۲۷	۰/۷۰۳	۰/۶۶۳	۱/۶۰۴	۱/۷۳۴	۰/۶۸۸
	۱	۰/۶۶۴	۱/۵۹۴	۱/۷۳۱	۰/۷۰۱	۰/۶۶۱	۱/۶۰۷	۱/۷۳۸	۰/۶۸۳
مهران جوسان (۱۷۹۶۵)	۴	۰/۶۸۱	۰/۵۹۳	۰/۶۱۴	۰/۷۱۲	۰/۶۷۳	۰/۶۰۲	۰/۶۲۳	۰/۶۹۴
	۳	۰/۶۷۲	۰/۵۹۴	۰/۶۱۷	۰/۷۰۸	۰/۶۶۸	۰/۶۰۴	۰/۶۲۷	۰/۶۹۱
	۲	۰/۶۶۸	۰/۶۰۱	۰/۶۲۱	۰/۷۰۲	۰/۶۶۲	۰/۶۰۵	۰/۶۳۱	۰/۶۸۷
	۱	۰/۶۶۳	۰/۶۰۳	۰/۶۲۵	۰/۶۹۹	۰/۶۵۹	۰/۶۱۲	۰/۶۳۳	۰/۶۸۱
علیزان جوسان (۱۷۹۳۴)	۴	۰/۶۷۸	۰/۵۰۲	۰/۵۳۸	۰/۷۱۱	۰/۶۷۲	۰/۵۱۱	۰/۵۳۴	۰/۶۹۳
	۳	۰/۶۷۱	۰/۵۰۳	۰/۵۳۱	۰/۷۰۷	۰/۶۶۷	۰/۵۱۴	۰/۵۳۸	۰/۶۸۹
	۲	۰/۶۶۶	۰/۵۰۹	۰/۵۳۱	۰/۷۰۲	۰/۶۶۱	۰/۵۱۷	۰/۵۴۱	۰/۶۸۷
	۱	۰/۶۶۱	۰/۵۱۱	۰/۵۳۴	۰/۶۹۸	۰/۶۵۸	۰/۵۱۷	۰/۵۴۴	۰/۶۷۷
گت ده (۱۷۰۵۰)	۴	۰/۶۷۴	۰/۵۱۲	۰/۵۴۱	۰/۷۰۹	۰/۶۷۱	۰/۵۲۱	۰/۵۵۱	۰/۶۹۱
	۳	۰/۶۷۱	۰/۵۱۴	۰/۵۴۲	۰/۷۰۶	۰/۶۶۶	۰/۵۲۴	۰/۵۵۲	۰/۶۸۸
	۲	۰/۶۶۳	۰/۵۱۷	۰/۵۴۴	۰/۷۰۱	۰/۶۵۹	۰/۵۲۵	۰/۵۵۸	۰/۶۸۵
	۱	۰/۶۵۸	۰/۵۲۱	۰/۵۴۸	۰/۶۹۵	۰/۶۵۷	۰/۵۲۸	۰/۵۶۳	۰/۶۷۴
دهدر (۱۷۸۷۴)	۴	۰/۳۹۴	۰/۴۰۳	۰/۷۰۸	۰/۷۰۸	۰/۳۹۹	۰/۳۹۹	۰/۴۲۲	۰/۷۰۵
	۳	۰/۳۹۹	۰/۴۲۲	۰/۷۰۵	۰/۶۹۹	۰/۳۹۹	۰/۴۰۲	۰/۴۳۱	۰/۶۸۲
	۲	۰/۴۰۲	۰/۴۲۴	۰/۶۹۹	۰/۶۹۳	۰/۴۰۴	۰/۴۳۲	۰/۴۳۲	۰/۶۷۴
	۱	۰/۴۰۴	۰/۴۲۸	۰/۶۹۳	۰/۶۸۶	۰/۴۰۴	۰/۴۱۳	۰/۴۳۲	۰/۶۷۴

جدول ۴: نتایج آماری داده‌های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل GRU-LSTM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
جوسان (۱۷۹۶۶)	۴	۰/۹۶۴	۰/۳۰۶	۰/۳۲۳	۰/۹۸۷	۰/۹۵۸	۰/۳۱۳	۰/۳۲۶	۰/۹۷۶
	۳	۰/۹۶۱	۰/۳۰۹	۰/۳۲۵	۰/۹۸۴	۰/۹۵۴	۰/۳۱۵	۰/۳۲۷	۰/۹۷۳
	۲	۰/۹۵۷	۰/۳۱۲	۰/۳۲۶	۰/۹۸۱	۰/۹۴۹	۰/۳۱۷	۰/۳۲۹	۰/۹۶۹
	۱	۰/۹۵۳	۰/۳۱۴	۰/۳۲۷	۰/۹۷۹	۰/۹۴۴	۰/۳۲۱	۰/۳۳۱	۰/۹۶۳
مهران جوسان (۱۷۹۶۵)	۴	۰/۹۶۳	۰/۰۸۲	۰/۱۰۴	۰/۹۸۶	۰/۹۵۷	۰/۰۹۱	۰/۱۱۲	۰/۹۷۵
	۳	۰/۹۵۹	۰/۰۸۴	۰/۱۰۵	۰/۹۸۳	۰/۹۵۲	۰/۰۹۱	۰/۱۱۳	۰/۹۷۲
	۲	۰/۹۵۶	۰/۰۸۶	۰/۱۰۷	۰/۹۸۱	۰/۹۴۸	۰/۰۹۳	۰/۱۱۵	۰/۹۶۸
	۱	۰/۹۵۲	۰/۰۸۹	۰/۱۰۸	۰/۹۷۸	۰/۹۴۳	۰/۰۹۵	۰/۱۱۶	۰/۹۶۱
علیزان جوسان (۱۷۹۳۴)	۴	۰/۹۶۳	۰/۰۶۳	۰/۰۷۷	۰/۹۸۶	۰/۹۵۶	۰/۰۶۷	۰/۰۸۱	۰/۹۷۴
	۳	۰/۹۵۸	۰/۰۶۴	۰/۰۷۸	۰/۹۸۲	۰/۹۵۱	۰/۰۶۸	۰/۰۸۳	۰/۹۷۱
	۲	۰/۹۵۵	۰/۰۶۵	۰/۰۷۹	۰/۹۷۹	۰/۹۴۷	۰/۰۶۹	۰/۰۸۴	۰/۹۶۶
	۱	۰/۹۵۱	۰/۰۶۷	۰/۰۸۱	۰/۹۷۶	۰/۹۴۲	۰/۰۷۱	۰/۰۸۵	۰/۹۶۱
گت ده (۱۷۰۵۰)	۴	۰/۹۶۲	۰/۰۶۹	۰/۰۸۳	۰/۹۸۵	۰/۹۵۵	۰/۰۷۰۳	۰/۰۸۶	۰/۹۷۲
	۳	۰/۹۵۶	۰/۰۷۱	۰/۰۸۵	۰/۹۸۱	۰/۹۴۹	۰/۰۷۴	۰/۰۸۷	۰/۹۶۹
	۲	۰/۹۵۴	۰/۰۷۲	۰/۰۸۶	۰/۹۷۷	۰/۹۴۶	۰/۰۷۵	۰/۰۸۹	۰/۹۶۵
	۱	۰/۹۴۹	۰/۰۷۴	۰/۰۸۹	۰/۹۷۴	۰/۹۴۱	۰/۰۷۷	۰/۰۹۳	۰/۹۵۹
دهدر (۱۷۸۷۴)	۴	۰/۹۶۱	۰/۰۳۸	۰/۰۵۳	۰/۹۸۳	۰/۹۵۴	۰/۰۴۱	۰/۰۵۷	۰/۹۷۱
	۳	۰/۹۵۵	۰/۰۳۹	۰/۰۵۵	۰/۹۸۱	۰/۹۴۸	۰/۰۴۲	۰/۰۵۹	۰/۹۶۸
	۲	۰/۹۵۳	۰/۰۴۱	۰/۰۵۷	۰/۹۷۶	۰/۹۴۵	۰/۰۴۳	۰/۰۶۱	۰/۹۶۴
	۱	۰/۹۴۸	۰/۰۴۳	۰/۰۵۹	۰/۹۷۳	۰/۹۳۹	۰/۰۴۵	۰/۰۶۳	۰/۹۵۸

جدول ۴ - نتایج آماری داده‌های ورودی جهت مدل سازی و پیش بینی سیلاب با مدل LSTM

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
جوسستان (۱۷۹۶۶)	۴	۰/۹۷۳	۰/۳۳۸	۰/۳۱۵	۰/۹۵۱	۰/۹۴۳	۰/۳۲۱	۰/۳۴۱	۰/۹۴۳
	۳	۰/۹۷۱	۰/۳۳۹	۰/۳۱۷	۰/۹۴۶	۰/۹۴۳	۰/۳۲۲	۰/۳۴۳	۰/۹۴۳
	۲	۰/۹۶۸	۰/۳۴۱	۰/۳۱۹	۰/۹۴۳	۰/۹۴۳	۰/۳۲۴	۰/۳۴۵	۰/۹۴۳
	۱	۰/۹۶۵	۰/۳۴۳	۰/۳۲۱	۰/۹۳۸	۰/۹۳۱	۰/۳۲۵	۰/۳۴۶	۰/۹۳۱
مهران جوسستان (۱۷۹۶۵)	۴	۰/۹۷۲	۰/۱۱۳	۰/۰۹۲	۰/۹۵۱	۰/۹۴۳	۰/۰۹۷	۰/۱۱۷	۰/۹۴۳
	۳	۰/۹۷۱	۰/۱۱۴	۰/۰۹۴	۰/۹۴۵	۰/۹۳۷	۰/۰۹۹	۰/۱۱۹	۰/۹۳۷
	۲	۰/۹۶۷	۰/۱۱۶	۰/۰۹۴	۰/۹۴۲	۰/۹۳۳	۰/۰۹۹	۰/۱۲۲	۰/۹۳۳
	۱	۰/۹۶۴	۰/۱۱۹	۰/۰۹۵	۰/۹۳۸	۰/۹۲۹	۰/۱۰۳	۰/۱۲۴	۰/۹۲۹
علیزان جوسستان (۱۷۹۳۴)	۴	۰/۹۷۱	۰/۰۸۳	۰/۰۶۸	۰/۹۴۹	۰/۹۴۲	۰/۰۷۳	۰/۰۸۹	۰/۹۴۲
	۳	۰/۹۶۹	۰/۰۸۴	۰/۰۶۹	۰/۹۴۴	۰/۹۳۶	۰/۰۷۷	۰/۰۹۱	۰/۹۳۶
	۲	۰/۹۶۶	۰/۰۸۴	۰/۰۷۲	۰/۹۴۱	۰/۹۳۲	۰/۰۷۹	۰/۰۹۱	۰/۹۳۲
	۱	۰/۹۶۲	۰/۰۸۷	۰/۰۷۴	۰/۹۳۷	۰/۹۲۸	۰/۰۸۱	۰/۰۹۳	۰/۹۲۸
گت ده (۱۷۰۵۰)	۴	۰/۹۷۱	۰/۰۸۹	۰/۰۷۵	۰/۹۴۸	۰/۹۴۱	۰/۰۸۴	۰/۰۹۴	۰/۹۴۱
	۳	۰/۹۶۸	۰/۰۹۱	۰/۰۷۶	۰/۹۴۳	۰/۹۳۵	۰/۰۸۵	۰/۰۹۴	۰/۹۳۵
	۲	۰/۹۶۵	۰/۰۹۱	۰/۰۷۷	۰/۹۳۹	۰/۹۳۱	۰/۰۸۷	۰/۰۹۷	۰/۹۳۱
	۱	۰/۹۶۱	۰/۰۹۳	۰/۰۷۹	۰/۹۳۶	۰/۹۲۷	۰/۰۹۳	۰/۱۰۱	۰/۹۲۷
دهدر (۱۷۸۷۴)	۴	۰/۹۶۹	۰/۰۵۷	۰/۰۴۱	۰/۹۴۷	۰/۹۳۹	۰/۰۴۴	۰/۰۶۱	۰/۹۳۹
	۳	۰/۹۶۷	۰/۰۵۹	۰/۰۴۳	۰/۹۴۲	۰/۹۳۴	۰/۰۴۵	۰/۰۶۳	۰/۹۳۴
	۲	۰/۹۶۴	۰/۰۶۱	۰/۰۴۵	۰/۹۳۸	۰/۹۲۹	۰/۰۴۷	۰/۰۶۵	۰/۹۲۹
	۱	۰/۹۵۹	۰/۰۶۳	۰/۰۴۷	۰/۹۳۵	۰/۹۲۶	۰/۰۴۹	۰/۰۶۷	۰/۹۲۶

بالای ۰/۹۵ و NSE نزدیک به یک که در جداول ۲ تا ۵ مشخص شده بود، هم‌سو است. تفاوت LSTM با GRU-LSTM در نمودار بسیار ناچیز است؛ به حدی که تشخیص برتری یکی بر دیگری بدون تکیه به شاخص‌های عددی تقریباً ممکن نیست. این شباهت، همان موضوع مهم نتایج را تأیید می‌کند. اختلاف عملکرد GRU-LSTM و LSTM معنادار نیست و هر دو به‌طور تقریبی یک رفتار دینامیکی مشابه ارائه داده‌اند. در مقابل، نمودارهای ConvLSTM و S-LSTM پراکنش گسترده‌تری را نشان می‌دهند؛ به‌طوری که نقاط در اطراف خط نیمساز قرار دارند اما میزان انحراف آن‌ها بیشتر است. این موضوع خصوصاً در محدوده دبی‌های بالا چشم‌گیرتر بوده و نشان می‌دهد مدل‌ها در بازسازی پیک‌ها دقت کمتری نسبت به دو مدل اصلی داشته‌اند. با این حال، فاصله ConvLSTM و S-LSTM از یکدیگر بسیار کم است. این موضوع نشان می‌دهد که هر دو مدل به دلیل ماهیت داده‌های کاملاً زمانی، نتوانسته‌اند مزیت


بررسی اشکال همبستگی بین مقادیر پیش‌بینی‌شده و مشاهداتی نشان می‌دهد که الگوی عملکرد مدل‌ها نه تنها با شاخص‌های عددی جدول‌ها هم‌خوان است، بلکه تصویری بسیار روشن از پایداری و قابلیت تعمیم آن‌ها ارائه می‌دهد. همان‌گونه که در نمودارهای خطی مشاهده می‌شود، مدل GRU-LSTM و LSTM بالاترین انطباق خطی را با خط نیمساز دارند؛ به‌طوری که نقاط پراکنش در هر دو مدل به‌صورت خوشه‌های منظم و چسبیده پیرامون خط همبستگی قرار گرفته‌اند. این موضوع نشان می‌دهد که مدل‌ها قادر بوده‌اند رفتار ماهانه جریان را با دقت بالا تقلید کنند و نوسانات سری زمانی به‌ویژه در بازه‌های اوج و افت را به‌خوبی بازسازی نمایند.

در مدل GRU-LSTM، تراکم نقاط در مجاورت خط نیمساز، شکل کاملاً فشرده و یکنواختی ایجاد کرده است که نشان می‌دهد این مدل نه تنها نوسانات را دنبال کرده بلکه خطای آن نیز حداقل بوده است. این الگوی بصری دقیقاً با مقادیر بالای ضریب همبستگی

یعنی ConvLSTM و S-LSTM توده‌هایی پراکنده‌تر با دامنه خطای بزرگ‌تر نمایش می‌دهند. این اختلاف بصری، تقویت‌کننده نتیجه پیش‌بینی‌های به انجام رسیده است. مدل‌های مبتنی بر حافظه زمانی بهترین گزینه برای سری زمانی روزانه جریان هستند؛ در حالی که مدل‌های مکانی مانند ConvLSTM تنها در شرایطی با داده‌های مکانی غنی می‌توانند مزیت خود را نشان دهند.

معماری خود را به‌طور کامل بروز دهند و عملاً عملکردی نزدیک به یکدیگر داشته‌اند. همین نکته با خطای RMSE نسبتاً مشابه و ضرایب همبستگی حدود ۰/۸۰ تا ۰/۸۵ در جداول نتایج نیز مطابقت دارد.

نکته مهمی که در تمامی اشکال همبستگی مشاهده می‌شود این است که گروه اول مدل‌ها LSTM و GRU-LSTM توده نقاطی فشرده، هم‌راستا و نزدیک به خط نیمساز ایجاد کرده‌اند در حالی که گروه دوم



شکل ۶: نمودار همبستگی ایستگاه‌های مورد مطالعه

زمانی کلاسیک LSTM و GRU-LSTM به‌طور قابل توجهی عملکرد بهتری در پیش‌بینی دبی بیشینه روزانه نسبت به مدل‌های مکانی زمانی و مدل‌های سبک ConvLSTM و S-LSTM ارائه داده‌اند. در میان این مدل‌ها، GRU-LSTM دقیق‌ترین و پایدارترین نتایج را ثبت کرد و مقادیر NSE، RMSE و ضرایب همبستگی آن در تمامی ایستگاه‌ها در سطح بسیار مطلوبی قرار داشت. با این حال، تحلیل‌های آماری و مقایسه مستقیم مقدار خطاها نشان داد که برتری

نتیجه‌گیری

یافته‌های پژوهش حاضر به‌روشنی نشان داد که بهره‌گیری از معماری‌های مختلف یادگیری عمیق در پیش‌بینی جریان بیشینه روزانه حوزه آبخیز طالقان به نتایج متفاوتی منجر می‌شود و عملکرد مدل‌ها وابستگی مستقیمی به ماهیت داده‌ها، ساختار سری زمانی و میزان پیچیدگی معماری دارد. نتایج ارزیابی چهار مدل LSTM، GRU-LSTM، ConvLSTM و S-LSTM نشان داد که مدل‌های مبتنی بر حافظه

طالقان معرفی می‌شود. این نتیجه علاوه بر همخوانی با مطالعات معتبر جهانی، نشان‌دهنده این نکته مهم است که انتخاب مدل پیچیده‌تر لزوماً به معنای دستیابی به عملکرد بهتر نیست و تحلیل ویژگی‌های داده و شرایط مسئله نقش تعیین‌کننده‌تری در انتخاب معماری مناسب دارد.

نتایج این پژوهش نشان داد که مدل‌های یادگیری عمیق به‌ویژه LSTM قادرند جریان‌های بیشینه را با دقت بسیار بالا و هزینه کمتر از مدل‌های هیبریدی پیش‌بینی کنند. به همین دلیل پیشنهاد می‌شود خروجی این مدل‌ها در چارچوب سامانه‌های هشدار سریع سیلاب ادغام شده و به‌صورت ماهانه یا فصلی به‌روزرسانی شوند. این اقدام می‌تواند زمان واکنش مدیریت بحران را افزایش داده و از خسارات احتمالی جلوگیری کند. همچنین پیشنهاد می‌شود در پژوهش‌های آینده، برای افزایش پتانسیل مدل ConvLSTM از داده‌های با پایه مکانی مانند داده‌های رادار بارش و تصاویر ماهواره‌ای بارش و رطوبت خاک استفاده شده و وابستگی‌های زمانی مکانی با دقت بیش‌تری مورد بررسی قرار گیرند. با وجود عملکرد بسیار مطلوب مدل‌های LSTM و GRU-LSTM در چارچوب داده‌های تک‌متغیره، افزودن متغیرهای فیزیکی مؤثر بر فرآیند سیلاب از جمله بارش، دما و تبخیر می‌تواند در پژوهش‌های آینده موجب بهبود قدرت تعمیم مدل‌ها و بازتاب دقیق‌تر فرآیندهای هیدرولوژیکی پیچیده و غیرخطی شود. توسعه مدل‌ها در قالب چارچوب‌های چندمتغیره، به‌عنوان یکی از مسیرهای اصلی تحقیقات آتی پیشنهاد می‌شود.

GRU-LSTM نسبت به LSTM از نظر آماری معنادار نیست؛ به‌طوری‌که LSTM تقریباً همان دقت را با هزینه محاسباتی کمتر، زمان آموزش کوتاه‌تر و ساختار ساده‌تر ارائه کرده است. سرعت، سادگی و قابلیت پیاده‌سازی اهمیت ویژه‌ای در کاربردهای عملیاتی و سامانه‌های هشدار سیلاب دارد. در مقابل، عملکرد S-LSTM و ConvLSTM در سطح پایین‌تری قرار گرفت و هرچند در برخی ایستگاه‌ها نتایج نسبتاً قابل‌قبولی ارائه کردند اما پراکندگی بیشتر خطاها و فاصله قابل‌توجه از خط نیمساز در نمودارهای همبستگی نشان داد که این مدل‌ها نتوانسته‌اند الگوهای زمانی جریان را مانند دو مدل اصلی بازسازی کنند. این وضعیت تأیید می‌کند که برای داده‌های تک‌متغیره و فاقد مؤلفه‌های مکانی مانند سری زمانی دبی بیشینه روزانه، مدل‌های مکانی زمانی همچون ConvLSTM مزیت قابل‌توجهی ندارند و مدل‌های سبک‌شده LSTM نیز تنها در شرایط محدودیت محاسباتی، قابل‌اتکاء هستند. نتایج بصری نمودارهای همبستگی نیز این الگوی رفتاری را تقویت کرد؛ به‌گونه‌ای که توده نقاط مربوط به LSTM و GRU-LSTM بیشترین تراکم را پیرامون خط نیمساز نشان دادند در حالی که دو مدل دیگر انحرافات بالاتری را ثبت کردند. این هم‌خوانی کامل بین شاخص‌های عددی و تحلیل بصری تأکید می‌کند که LSTM و GRU-LSTM مناسب‌ترین ساختارهای یادگیری برای این نوع داده‌ها هستند. بنابراین با توجه به تعادل میان دقت، هزینه محاسباتی، پایداری آموزشی و کارایی عملیاتی، مدل LSTM به عنوان بهترین گزینه نهایی برای پیش‌بینی دبی بیشینه روزانه در حوزه آبخیز

منابع

۱. انصاری قوجقار، م.، عراقی نژاد، ش.، بذرافشان، ج.، زهرایی، ب. و پارسی، ا. (۱۴۰۳). ارزیابی کارایی مدل هیبریدی-GRU-LSTM در پیش‌بینی طوفان‌های گرد و غبار (مطالعه موردی: استان خوزستان)، مجله تحقیقات منابع آب ایران، 17(1)، 16-32. magiran.com/p2291298
۲. بهرامی، ع. و خزینه‌نژاد، ح. (۱۳۹۹). پیش‌بینی دبی جریان سیلاب با مدل بیان ژن و برآورد هیدروگراف آن با استفاده از دو مدل گری و گاما (مطالعه موردی: حوضه آبخیز قره سو کرمانشاه). نشریه هواشناسی و علوم جو، ۳(۳)، ۲۷۵-۲۹۳.
۳. توکلی، م.، امیراحمدی، ا. و گلی مختاری، ل. (۱۴۰۳). ارزیابی، پیش‌بینی و تحلیل منطقه‌ای سیلاب با استفاده از مدل‌های داده‌کاوی در حوضه آبریز فریزی. فصل‌نامه تحقیقات جغرافیایی، ۳۹ (۲): ۱۶۱-۱۶۸. DOI: 10.58209/geores.39.2.161

۴. حسین زاده ف، عبادی ح، و کیانی ع. (۱۴۰۱). ادغام داده‌های سنجش‌ازدوری و هواشناسی جهت پیش بینی زمانی سیلاب با استفاده از الگوریتم یادگیری عمیق. مهندسی فناوری اطلاعات مکانی، ۱۰ (۲): ۳۸-۱۹. DOI:10.52547/jgit.10.2.19
۵. حنیفی نیا، عبدالعزیز و عبقری، هیراد. (۱۴۰۴). پیش‌بینی مناطق مستعد سیل با استفاده از مدل‌های یادگیری ماشین خطی تعمیم یافته و بیشینه آن‌تروپی. مخاطرات محیط طبیعی، ۱۴ (۴۳)، ۱۹-۳۴. doi: 10.22111/jneh.2024.47730.2021
۶. زینعلی، م.، بزرگ حداد، ا.، یاسی، م. و علیزاده، ح. (۱۴۰۳). ارزیابی کارایی مدل LSTM در پیش بینی جریان روزانه ورودی به مخازن سدها، مجله تحقیقات آب و خاک ایران، ۵۵ (۱۰)، ۱۸۶۳-۱۸۸۳. magiran.com/p2813028
۷. غفاری رزین، س.ر.، وثوقی، ب. و هوشنگی، ن. (۱۴۰۲). ارزیابی کارایی مدل شبکه عصبی حافظه کوتاه مدت طولانی در پیش‌بینی سری زمانی یونوسفر و مقایسه آن با مدل‌های GRNN، GIM و NEQUICK. اطلاعات جغرافیایی، ۳۲ (۱۲۶). DOI:10.22131/SEPEHR.2023.547749.2839
۸. کاظمی، ح.، منصوری، ن. و جوزی، س.ع. (۱۴۰۰). پهنه‌بندی خطر سیلاب در شهر نوشهر با استفاده از مدل‌های یادگیری ماشین. مسکن و محیط روستا، ۴۰ (۱۷۶)، ۷۱-۸۶. DOI: 10.22034/40.176.71
9. Akandeh, A., & Salem, F.M. (2019). Slim LSTM NETWORKS: LSTM 6 and LSTM C6. *2019 IEEE 62nd International Midwest Symposium on Circuits and Systems (MWSCAS)*, 630-633.
10. Al-Qaderi, M. K., & Rad, A. B. (2018). A Multi-Modal Person Recognition System for Social Robots. *Applied Sciences*, 8(3), 387. <https://doi.org/10.3390/app8030387>
11. C.Oddo, P., D.Bolten, J., V.Kumar, S. & Cleary, B. (2024). Deep Convolutional LSTM for improved flash flood prediction. *Water*, 6. <https://doi.org/10.3389/frwa.2024.1346104>
12. Ebrahimi, A., Roozbahani, A. & Bani habib, M.A. (2018). Groundwater Level Prediction Using Dynamic Bayesian Networks Based on Sensitivity Analysis (Case Study: Birjand Plain). *Iranian Water*, 12(2), 91-100
13. Lindemann, B., Muller, T., Vietz, H., Jazdi, N. & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. 14th CIRP Conference on Intelligent Computation in Manufacturing Engineering, CIRP ICME '20. 650-655. <https://doi.org/10.1016/j.procir.2021.03.088>
14. Liao, Y., Wang, Z., Yu, H., Gao, W., Zeng, Z., Li, X., & Lai, C. (2025). Accelerating urban flood inundation simulation under spatio-temporally varying rainstorms using ConvLSTM deep learning model. *Water Resources Research*, 61, e2025WR040433. <https://doi.org/10.1029/2025WR040433>
15. Liu, W., Wang, Y., Zhong, D., Xie, S., & Xu, J. (2022). ConvLSTM Network-Based Rainfall Nowcasting Method with Combined Reflectance and Radar-Retrieved Wind Field as Inputs. *Atmosphere*, 13(3), 411. <https://doi.org/10.3390/atmos13030411>
16. Lingling Xi and Dandan Gong 2024 *J. Phys.: Conf. Ser.* 2731 012038. DOI 10.1088/1742-6596/2731/1/012038
17. M. Fathi, S. (2018). SLIM LSTMs. <https://doi.org/10.48550/arXiv.1812.11391>
18. Rugina, A.M. (2023). The Use of Recurrent Neural Networks (S-RNN, LSTM, GRU) For Flood Forecasting Based on Data Extracted from Classical Hydraulic Modeling. *Modelling in Civil Environmental Engineering*, 18(3). DOI: <https://doi.org/10.2478/mmce-2023-0011>
19. Shirazi, F., Zahiri, A., Piri, J. & Dehghani, A.A. (2025). Development a new hydraulic method for prediction of river flood discharge. *Journal of Watershed Management Research*, 14(28), 110-123. doi.org/10.61186/jwmr.14.28.110. (In Persian).
20. Shi, X., Chen, Z., Wang, H., Yeong, D.T., Wong, W.K. & Woo, W.C. (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. <https://doi.org/10.48550/arXiv.1506.04214>
21. Wang, Y., Wang, W., Zang, H., & Xu, D. (2023). Is the LSTM Model Better than RNN for Flood Forecasting Tasks? A Case Study of HuaYuankou Station and LouDe Station in the Lower Yellow River Basin. *Water*, 15(22), 3928. <https://doi.org/10.3390/w15223928>
22. X. Dai, H. Yin and N. K. Jha. (2019). Grow and Prune Compact, Fast, and Accurate LSTMs. in *IEEE Transactions on Computers*, 69(3), 441-452. doi: 10.1109/TC.2019.2954495.

23. Zhang, Y., Zhou, Z., Van Griensven Thé, J., Yang, S.X., & Gharabaghi, B. (2023). Flood Forecasting Using Hybrid LSTM and GRU Models with Lag Time Preprocessing. *Water*. DOI:10.3390/w15223982
24. Zhang, Y., Liu, Y., Kong, Y., & Hu, P. (2024). An Improved Method for Retrieving Subsurface Temperature Using the ConvLSTM Model in the Western Pacific Ocean. *Journal of Marine Science and Engineering*, 12(4), 620. <https://doi.org/10.3390/jmse12040620>

