تحقیقات منابع آب ایران
Iran-Water Resources Research

سال بیست و دوم، شماره ۲، تابستان ۱۴۰۵
Volume 22, No.2, Summer 2026 (IR-WRR)
۱-۱۶

بررسی کارآیی مدل LSTM در پیش‌بینی سیلاب در مناطق خشک (منطقه مورد مطالعه: حوزه فخرآباد یزد)

نسترن وحدتی نسب[۱]، محمد امین اسدی زارچ[۲*]

چکیده

افزایش رخدادهای سیل در چند دهه گذشته در اثر تغییرات آب و هوایی، خسارات جبران‌ناپذیری را در بسیاری از مناطق جهان بر جای گذاشته است. انسان‌ها نیز با اقداماتی نظیر تغییرات کاربری اراضی و جنگل‌زدایی زمینه وقوع سیل را افزایش می‌دهند. پیش‌بینی درست و هشدار به‌موقع وقوع سیل می‌تواند تا حد قابل‌توجهی از خسارات مالی و جانی این پدیده جلوگیری کند. در دهه‌های اخیر محققان برای پیش‌بینی سیل از روش‌های مختلفی از جمله شبکه‌های عصبی مصنوعی استفاده کرده‌اند. این شبکه‌ها چندین زیرمجموعه دارد. حافظه بلندمدت کوتاه‌مدت (LSTM) یک نسخه بهبودیافته از شبکه عصبی بازگشتی (RNN) است. یادگیری وابستگی‌های طولانی‌مدت برای شبکه‌های عصبی بازگشتی سنتی دشوار است. مدل LSTM با معرفی یک سلول حافظه که می‌تواند اطلاعات را برای مدت طولانی نگهداری کند، این مشکل را برطرف می‌کند. در این تحقیق مقادیر دبی متوسط ایستگاه‌های هیدرومتری باغستان و طزرجان و مقادیر بارش ایستگاه ده بالا در حوزه فخرآباد استان یزد در دوره ۱۳۷۰ تا ۱۳۹۸ مورد استفاده قرار گرفته است. در دوره آماری مورد مطالعه مقادیر مجموع بارش و دبی متوسط دارای روند کاهشی ملایم بودند. به‌منظور بررسی کارآیی مدل LSTM در پیش‌بینی دبی، معیارهای ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) بین مقادیر دبی مشاهداتی و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های باغستان و طزرجان در مقیاس روزانه و سری زمانی سه‌ماهه محاسبه شدند. نتایج نشان داد در بین مدل‌های مورد استفاده، مدل LSTM به کار رفته برای پیش‌بینی دبی روزانه ایستگاه طزرجان با R^2 و RMSE به ترتیب ۰/۷۸ و ۰/۴۳ از عملکرد بالاتری برخوردار است.

کلمات کلیدی: الگوریتم LSTM، بارش، دبی، پیش‌بینی، سیلاب.

تاریخ دریافت مقاله: ۱۴۰۳/۱۱/۱۵
تاریخ پذیرش مقاله: ۱۴۰۴/۱۰/۱

۱- دانش‌آموخته کارشناسی ارشد علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد، یزد، ایران.
۲- استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد، یزد، ایران.
*- نویسنده مسئول

Evaluating the LSTM Model Performance in Predicting Floods in Arid Regions (Case study: Fakhrabad Watershed, Yazd, Iran)

N. Vahdati Nasab[1], M. A. Asadi Zarch[2]*

Abstract

The increase in flood events in the past few decades due to climate change has left irreparable damage in many regions of the world. Human activities such as land use changes and deforestation also contribute to the occurrence of floods. Accurate prediction and timely warning of floods can significantly prevent financial and human losses. In recent decades, researchers have used various methods, including artificial neural networks, to predict floods. These networks have several subsets. Long Short-Term Memory (LSTM) is an improved version of Recurrent Neural Networks (RNN). Learning long-term dependencies for traditional recurrent neural networks is difficult. The LSTM model, by introducing a memory cell that can retain information for a long time, overcomes this problem. In this study, the average flow values from the Baghestan and Tezerjan hydrometric stations and the precipitation values from the Deh Bala station in Fakhrabad area of Yazd province is used for the period of 1398-1370 (persian calendar). The precipitation andflow values showed a mild decreasing trend in the study period. To evaluate the performance of the LSTM model in predicting flow, the coefficient of determination (R^2) and RMSE between the observed flow values and the predicted flow by the LSTM model was calculated at the Baghestan and Tezerjan stations on a daily and three-month time scale. The results showed that among the models used, the LSTM model used for predicting the daily stramflow at the Tezerjan station showed the highest performance with R^2 and RMSE values of 0.78 and 0.43, respectively.

Keywords: LSTM, Precipitation, Streamflow, Prediction, Flood.

Received: February 3, 2025
Accepted: December 22, 2025

1- M.Sc. Graduate of Watershed Science and Engineering, Faculty of Natural Resources and Desert Studies, Yazd University, Yazd, Iran. Email: nastaran.vahdatinasab@gmail.com
2- Assistant Professor, Faculty of Natural Resources and Desert Studies, Yazd University, Yazd, Iran. Email: amin.asadi@yazd.ac.ir
*- Corresponding Author
Doi: 10.22034/iwrr.2025.504298.2827

This work is licensed under a Creative Commons Attribution 4.0 International License

۱- مقدمه

در طول قرن گذشته، شتاب جهانی شدن و صنعتی شدن منجر به وقوع پدیده تغییر اقلیم شده است که به‌طور قابل‌توجهی شرایط هیدرولوژیکی را تغییر داده است (Kreibich et al., 2022). رواناب یک سیگنال طبیعی و یک سری زمانی غیرخطی پیچیده است که به‌طور هم‌زمان تحت تأثیر عوامل مختلفی قرار می‌گیرد (Ha et al., 2021). سیل حجم زیادی از رواناب است که از بستر اصلی رودخانه بالا می‌آید و زمین‌های اطراف رودخانه را به زیر آب می‌برد (National Research Council, 2009). بر اساس گزارش دفتر کاهش خطر بلایای طبیعی سازمان ملل، ۱۵۰۰۱۶ سیل بین سال‌های ۱۹۹۶ تا ۲۰۱۵ رخ داده است که به‌شدت بر سیستم‌های طبیعی و فعالیت‌های انسانی تأثیر گذاشته است (Ha et al., 2021). پس می‌توان گفت سیل یکی از شایع‌ترین بلایای طبیعی در سراسر جهان است (Giovannettone et al., 2018; Moreno et al., 2020). از سال ۲۰۰۰ تا ۲۰۱۹، سیل ۴۴ درصد از کل حوادث بلایای طبیعی را تشکیل داده است و ۱/۶ میلیارد نفر را تحت تأثیر قرار داده است (Yaghmaei, 2020). افزایش فراوانی رخدادهای سیل ناشی از تغییرات آب و هوایی و توسعه شهری در مناطق مستعد سیل، چالش‌های مهمی را برای استراتژی مدیریت سیل ایجاد کرده است (Teufel et al., 2019; Wang et al., 2022).

علاوه بر شدت بارش و توزیع مکانی بارش، شرایط طبیعی موجود در هر منطقه نظیر خاک و پوشش حوضه، مساحت حوضه، شیب حوضه و طول رودخانه نیز بر ایجاد سیل اثر دارند. همچنین، بعضی از تغییرات مصنوعی شامل تغییر کاربری اراضی، جنگل‌زدایی، تغییرات در عملیات کشاورزی، شهرسازی، مخازن و تغییرات کانال ریسک سیلاب را تا حدی تغییر می‌دهد (Kumar et al., 2024). افزایش روزافزون غلظت گازهای گلخانه‌ای به‌ویژه گاز دی‌اکسیدکربن در جو زمینه را برای تشدید پدیده تغییر اقلیم فراهم کرده است (Filonchyk et al., 2024). این پدیده باعث تغییراتی در شرایط بارش، میزان رواناب، سرعت باد، تابش خورشیدی رسیده به سطح زمین و دمای هوا می‌شود. پدیده تغییر اقلیم در بسیاری از مناطق زمینه را برای افزایش رویدادهای حدی مانند سیل و خشکسالی فراهم ساخته است. بنابراین سامانه‌های دقیق و کارآمد برای پیش‌بینی دبی جریان خروجی حوزه جهت صدور هشدارهای به‌موقع برای وقوع سیلاب‌ها ضروری است (Moore et al., 2005). تجزیه و تحلیل سری‌های زمانی یک حوزه حیاتی در زمینه‌های متفاوت انجام می‌گیرد که در آن پیش‌بینی دقیق مقادیر آینده ضروری است (Eghtesad and Mohammadi, 2023). تاکنون روش‌های مختلفی برای تجزیه‌وتحلیل و پیش‌بینی سری زمانی دبی جریان خروجی در مناطق مختلف استفاده شده است که به‌طور کلی به دو دسته طبقه‌بندی می‌شوند: مدل‌های مبتنی بر فرآیند و مدل‌های مبتنی بر داده (Filipova et al., 2022). مدل‌های مبتنی بر فرآیند، مکانیسم‌های تبدیل بارندگی به رواناب را در نظر می‌گیرند و پدیده‌های هیدرولوژیکی پیچیده را تا حد معینی تعمیم می‌دهند و بنابراین نقش غالبی در پیش‌بینی زمان سیل دارند (Beylich et al., 2021). این مدل‌ها با جمع‌آوری اطلاعات مکانی و هیدرولوژیکی حوضه رودخانه، تغییرپذیری و انتقال عناصر مانند کمیت و کیفیت آب را در یک منطقه شبیه‌سازی می‌کنند تا پیش‌بینی جریان رودخانه را به دست آورند (Ha et al., 2021). با این حال، فرآیند تبدیل بارندگی- رواناب با ویژگی‌های غیرخطی و غیر ثابت همراه است و شبیه‌سازی جامع فرآیند پیچیده هیدرولوژیکی برای مدل‌های مبتنی بر فرآیند دشوار است (Ciu et al., 2022). همچنین، این مدل‌ها در بسیاری از مناطق به دلیل عدم دسترسی به داده‌های باکیفیت، کاربرد محدودی دارند. محدودیت دیگر این است که مدل‌های هیدرولوژیکی فعلی مبتنی بر مکانیسم‌های فیزیکی اگرچه می‌توانند پیش‌بینی‌های دقیقی از جریان ارائه دهند، اما دوره پیش‌بینی مؤثر تنها حدود ۱ ماه قبل است که برای تصمیم‌گیری بسیار کوتاه است (Ha et al., 2021).

مدل‌های سری زمانی سنتی نیز که از دیرباز سنگ بنای پیش‌بینی سری‌های زمانی بوده‌اند، زمانی که با الگوهای پیچیده یا بی‌نظمی در سری‌های زمانی مواجه می‌شوند، ممکن است با مشکل مواجه شوند (Eghtesad and Mohammadi, 2023). مدل مبتنی بر داده LSTM1 از مهارت خود در استخراج روابط ذاتی در داده‌های بزرگ برای شبیه‌سازی مؤثر سیستم‌های پیچیده با ویژگی‌های غیرخطی و غیر ثابت بهره می‌برد (Ciu et al., 2022). این شبکه‌ها برای پیش‌بینی سری‌های زمانی، یکی از بهترین شبکه‌های عمیق موجود هستند. شبکه‌های LSTM به‌ویژه برای پیش‌بینی سیل به دلیل توانایی آن‌ها در گرفتن وابستگی‌های بلندمدت در داده‌های سری زمانی مناسب هستند. این قابلیت برای پیش‌بینی دقیق سیل‌ها بر اساس الگوهای هواشناسی و هیدرولوژیکی تاریخی بسیار مهم است؛ زیرا به مدل اجازه می‌دهد از رویدادهای قبلی استفاده کند و در طول زمان پیش‌بینی‌ها را بهبود بخشد (Cheng et al., 2020). مطالعات عملکرد بهتر شبکه‌های LSTM را در پیش‌بینی سیل نشان داده‌اند، از طرفی داده‌های هواشناسی از نوع یک سری زمانی هستند پس به‌خوبی می‌توان از شبکه مذکور برای پیش‌بینی آن بهره برد.

Zhang et al. (2022) به بررسی کارآیی مدل LSTM در پیش‌بینی سیل در ۳۵ حوزه در کشور چین پرداختند. نتایج نشان داد اگرچه مدل عملکرد قابل قبولی در پیش‌بینی دبی خروجی حوزه ارائه کرده است، اما هر چه منطقه خشک‌تر باشد، عملکرد مدل ضعیف‌تر است. Xiang and Demir (2020) یک ساختار توسعه‌یافته از مدل LSTM را برای پیش‌بینی سیل در حوزه آبخیز در آیووا، ایالات متحده، با مقایسه مدل‌های رایج یادگیری ماشین، مانند رگرسیون خطی، اعمال کرد. آن‌ها تأیید کردند که مدل پیشنهادی می‌تواند دقت پیش‌بینی‌های کوتاه‌مدت سیل را بهبود بخشد. Ha et al. (2021) سه مدل DNN2 از جمله Conv LSTM3 را بر روی حوضه رودخانه یانگ تسه بر اساس نوسانات ال نینو جنوبی و داده‌های سیل ماهانه اعمال کردند. آن‌ها دریافتند که شبکه عصبی Conv LSTM می‌تواند پایداری ساختار شبکه را بهبود بخشد و بهترین نتایج پیش‌بینی را ارائه کرد.

Liang et al. (2018) با استفاده از شبکه‌های LSTM و ماشین بردار پشتیبان تحقیقی با داده‌های روزانه ۷ عامل، پیش‌بینی سطح آب دریاچه دونگتینگ چین صورت گرفت. برتری LSTM به ماشین بردار توسط مقادیر خطای جذر میانگین مربعات و ضریب تعیین مشخص شد. Hu et al. (2018) در چین برای شبیه‌سازی بارش رواناب از داده‌های ۱۵ ایستگاه در طول ۴۲ سال استفاده کردند. نتیجه این تحقیق نشان داد که هر دو مدل شبکه عصبی مصنوعی و LSTM برای مدل‌سازی بارش و رواناب مناسب هستند، ولی دقت و پایداری شبکه LSTM بیشتر است. بر اساس مرور منابع انجام گرفته، مطالعه مستقلی که کارآیی مدل LSTM در پیش‌بینی دبی در مناطق خشک را مورد مطالعه قرار دهد، یافت نشد. در این مطالعه کارآمدی مدل LSTM در پیش‌بینی دبی جریان خروجی در حوزه خشک فخرآباد یزد در دو دوره کوتاه‌مدت و بلندمدت مورد مطالعه قرار گرفت. همچنین، روند تغییرات دبی و بارش نیز در منطقه مطالعه مورد بررسی قرار گرفت.

۲- مواد و روش‌ها

۲-۱- معرفی منطقه مورد مطالعه

استان یزد که در مرکز ایران قرار دارد، جز خشک‌ترین مناطق کشور است و با کمبود شدید منابع آبی مواجه است (Sharghi et al., 2010). بنابراین، پیش‌بینی سیلاب‌ها در این استان جهت مدیریت بهینه منابع آب و برنامه‌ریزی جهت کاهش خسارت احتمالی ناشی از وقوع سیل از اهمیت زیادی برخوردار است. مطابق شکل ۱ مختصات جغرافیایی حوزه فخرآباد یزد به شرح طول جغرافیایی ۵۴ درجـه و ۲ دقیقه تا ۵۴ درجه و ۱۵ دقیقه شرقی و عرض ۳۱ درجه و ۳۱ دقیقه تا ۳۱ درجه و ۴۱ دقیقه شمالی است. رژیم حرارتی منطقه از نوع مدیترانه‌ای با زمستان‌های سرد در فصول سرد و تابستان‌هایی گرم و خشک است (Sharaki and Mohseni, 2010). خروجی این حوزه دشت ابراهیم‌آباد مهریز نام دارد که آب ناشی از بارندگی و ذوب برف این حوزه توسط رودهای فصلی به این دشت سرازیر می‌شود. روستاهای ده بالا، طزرجان و فخرآباد در این حوزه قرار دارند. متوسط ارتفاع در این حوزه ۲۷۲۰ متر و شیب متوسط در این حوزه ۱۸ درصد است. متوسط بارش سالانه حوزه تقریباً ۲۰۵ میلی‌متر است. توزیع بارش‌ها در بخش‌های مختلف این حوزه بسیار متفاوت است؛ زیرا در این حوزه قله شیرکوه با ارتفاع ۴۰۷۵ متر از سطح دریا وجود دارد و همچنین، ارتفاع خروجی حوزه ۱۸۰۰ متر بالاتر از سطح دریا است. به‌عنوان مثال، بارش‌ها در ده بالا بیشتر به‌صورت برف و متوسط بارش ۲۰ ساله این زیر حوزه حدود ۳۰۰ میلی‌متر است. در حالت کلی اغلب بارش از نوع باران و متوسط بارش سالانه حدود ۱۰۰ میلی‌متر است. به‌طور کلی، ۲۴ درصد از کل ریزش‌های جوی در این حوزه به شکل برف است (Mazaheri, 2006). در این حوزه سه ایستگاه مورد بررسی قرار گرفتند. دو ایستگاه هیدرومتری شامل ایستگاه‌های طزرجان و باغستان (فخرآباد) و ایستگاه باران‌سنجی ده بالا که در شکل ۱ قابل رؤیت هستند.

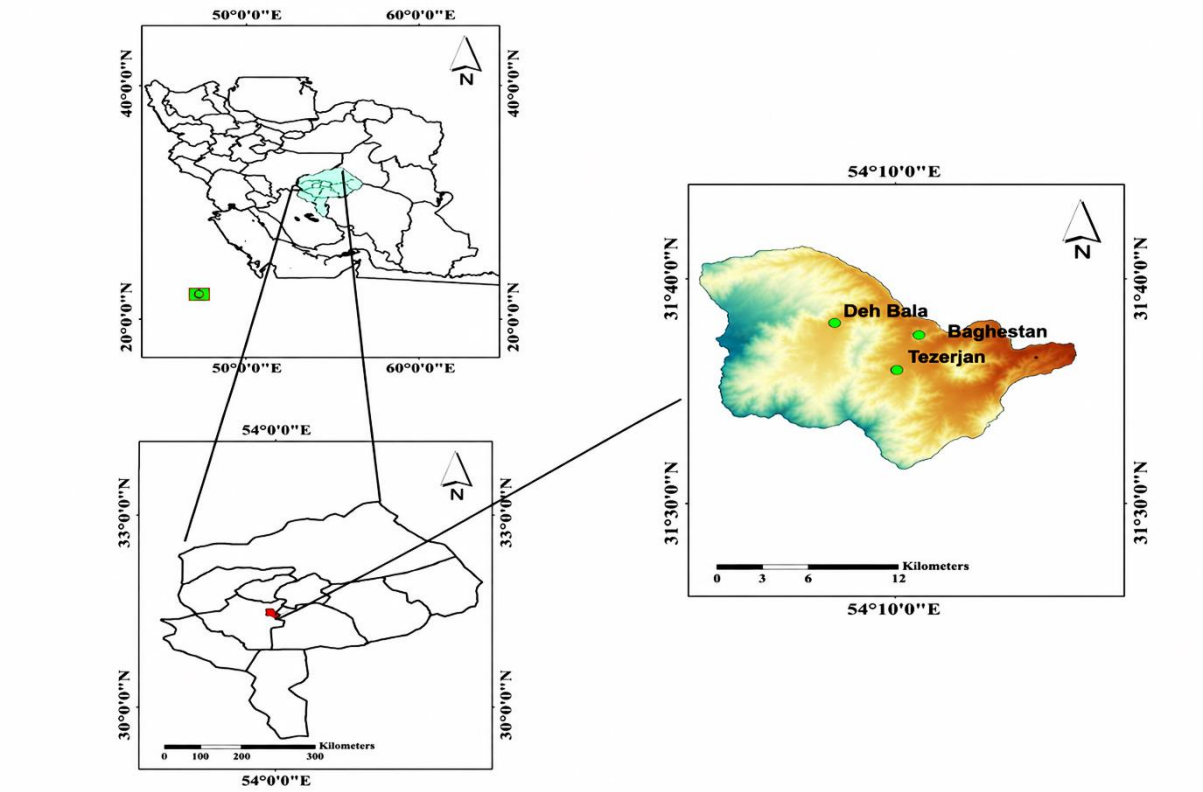

Fig. 1- Geographic location of Fakhrabad watershed in Yazd province, Iran

شکل ۱- موقعیت جغرافیایی حوزه آبخیز فخرآباد در استان یزد و ایران

۲-۲- شبکه LSTM

این شبکه نسخه‌ای از شبکه‌های عصبی بازگشتی است. اکثریت شبکه‌های عصبی قادر به استفاده از تمام داده‌های موجود خود نیستند و فقط از آخرین اطلاعات خود برای ساخت خروجی استفاده می‌کنند. برای برطرف کردن این مشکل شبکه‌های عصبی بازگشتی معرفی شدند. شبکه‌های عصبی بازگشتی در واقع سامانه‌های پویایی در خلل گام‌های زمانی یک فرایند (با طبقه‌بندی) حفظ می‌کنند. این قابلیت به دلیل ارتباطات حلقوی است که در میان نورون‌های سطوح بالا با نورون‌های لایه‌های پایین‌تر وجود دارد (Moalem and Pouyan, 2018). شبکه عصبی بازگشتی، از نظر تئوری باید قادر به یادگیری دنباله‌هایی با هر سطح پیچیدگی باشد؛ اما در عمل این شبکه‌ها در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته به مدت طولانی ضعیف است. ضمن آنکه این ویژگی، توانایی این شبکه را در مدل‌سازی ساختارهای بلندمدت تضعیف می‌کند، این فراموشی باعث می‌شود تا این نوع از شبکه‌ها، در زمان تولید دنباله در معرض ناپایداری قرار گیرند (Ziyadi et al., 2022).

در حقیقت هدف از طراحی شبکه LSTM، حل مشکل به یادسپاری وابستگی‌های بلندمدت در RNN[4] بود. RNNها، ساختاری بسیار مشابه با شبکه‌های چندلایه پرسپترون (MLP[5]) دارند، با این تفاوت که نورون‌های لایه مخفی علاوه بر یال‌های رو به جلو، یک یال هم به‌صورت بازگشتی و با احتساب یک زمان تأخیر، از خودشان به خودشان دارند. چنین ساختاری به یادسپاری وابستگی‌های کوتاه‌مدت را تضمین می‌کند، لیکن امکان یادگیری را ندارد. برای رفع این مشکل وابستگی‌های مربوط به گذشته‌های دور نورون‌های مخفی با یک بلاک حافظه با ساختار پیچیده‌تری، جایگزین شد و منجر به ظهور شبکه‌های LSTM شد (Tabibian, 2022). در واقع در مدل LSTM، خروجی شبکه به‌عنوان یک ورودی درنظر گرفته می‌شود و دوباره به شبکه بازمی‌گردد. این اقدام در سیستم مانع از حذف اطلاعات قبلی می‌شود و اطلاعات را به دور بعد منتقل می‌کند. همچنین، در شبکه‌های عصبی بازگشتی می‌توانیم دو نوع اطلاعات گذشته دور و گذشته نزدیک را در نظر بگیریم. این شبکه عصبی در تجزیه‌وتحلیل داده‌های سری زمانی عملکرد بهتری را نسبت به شبکه عصبی بازگشتی ساده نشان داده است (Abdi et al., 2021).

شبکه‌های بازگشتی سنتی از دو مشکل اختفا و انفجار گرادیان رنج می‌برند. در هر مرحله از آموزش یک شبکه عصبی بازگشتی تعداد زیادی ضرب انجام می‌پذیرد. وجود مجموعه بزرگی از وزن‌های بزرگتر از یک و انجام ضرب‌های یاد شده، شبکه را به سمت اوزان بسیار بزرگ یا همان انفجار گرادیان هدایت می‌کند. در نتیجه این پدیده، حرکت کل شبکه به سمت نقاط مطلوب از کنترل خارج می‌شود و شبکه با گام‌های بسیار بزرگ در اطراف نقاط جواب نوسان می‌کند (Moalem and Pouyan, 2018). LSTM برخی از مشکلات RNN، مانند اختفا و انفجار گرادیان و حفظ نشدن اطلاعات در فواصل طولانی را با افزودن مکانیزم دروازه‌ای حل می‌کند (Ciu et al., 2022).

در مجموع سه دروازه در LSTMها معرفی شده‌اند: دروازه ورودی، دروازه فراموشی و دروازه خروجی. علاوه بر آن، سلول‌های حافظه

$$f[t] = \sigma[W_f \bullet x[t] + U_f \bullet h[t-1] + b_f] \quad (۱)$$

$$[t] = \sigma[W_i \bullet x[t] + U_i \bullet h[t-1] + b_i] \quad (۲)$$

$$c[t] = \tanh[W_g \bullet x[t] + U_g \bullet h[t-1] + b_g] \quad (۳)$$

$$o[t] = \sigma[W_o \bullet x[t] + U_o \bullet h[t-1] + b_o] \quad (۴)$$

$$c[t] = f[t] \times c[t-1] + i[t] \times c[t] \quad (۵)$$

$$h[t] = o[t] \times \tanh(c[t]) \quad (۶)$$

که در این روابط f[t]، i[t]، c[t]، o[t] و h[t] به ترتیب نشان‌دهنده دروازه فراموشی، دروازه ورودی، وضعیت سلول، دروازه خروجی و حالت پنهان در هر گام زمانی هستند. W، U و b وزن‌ها و بایاس شبکه عصبی هستند. σ (تابع سیگموئید) و tanh دو تابع فعال‌سازی هستند. همچنین، x[t] ورودی‌ها هستند.

سلول LSTM دارای سه دروازه است که وضعیت سلول و حالت پنهان خود را حفظ و تنظیم می‌کند (شکل ۲)، از جمله یک دروازه فراموشی (رابطه ۱)، یک دروازه ورودی (رابطه ۲)، و یک دروازه خروجی (رابطه ۴). هر دروازه دارای یک تابع سیگموئید است که غیرخطی بودن ترکیب خطی ورودی‌ها (x[t]) و حالت پنهان از گام زمین قبلی (h[t-1]) را اضافه می‌کند. روابط ۳ و ۵ نشان می‌دهد که چه مقدار ورودی و آخرین حالت پنهان به وضعیت سلول (c[t]) کمک می‌کند. در نهایت، خروجی (h[t]) گام زمانی فعلی از دروازه خروجی و وضعیت سلول نشان داده شده در رابطه ۶ محاسبه می‌شود. حالت سلول و حالت پنهان سپس به گام زمانی بعدی منتقل می‌شوند (Zhang et al., 2022).

وجود دارند که شکلی مشابه حالت پنهان دارند. یک سلول حافظه فقط یک نسخه از یک حالت پنهان است که به‌صورت سفارشی برای ثبت اطلاعات اضافی طراحی شده است (Atmaja et al., 2022). در این مطالعه جهت بهینه‌سازی یادگیری شبکه عصبی و پیدا کردن وزن‌های مناسب از الگوریتم Adam استفاده شده است. این الگوریتم با ترکیب الگوریتم‌های بهینه‌ساز Momentum و RMSProp[6] هم از حرکت زیگزاگی جلوگیری می‌کند، هم شدت جهت حرکت را کنترل می‌نماید و همچنین، احتمال پیداکردن نقطه بهینه سراسری در مقابل نقطه بهینه محلی را نیز بالا می‌برد (Kingma and Ba, 2015). معادلات ۱ تا ۶ روابط ریاضی اصلی مدل LSTM را در هر گام زمانی ارائه می‌دهد:

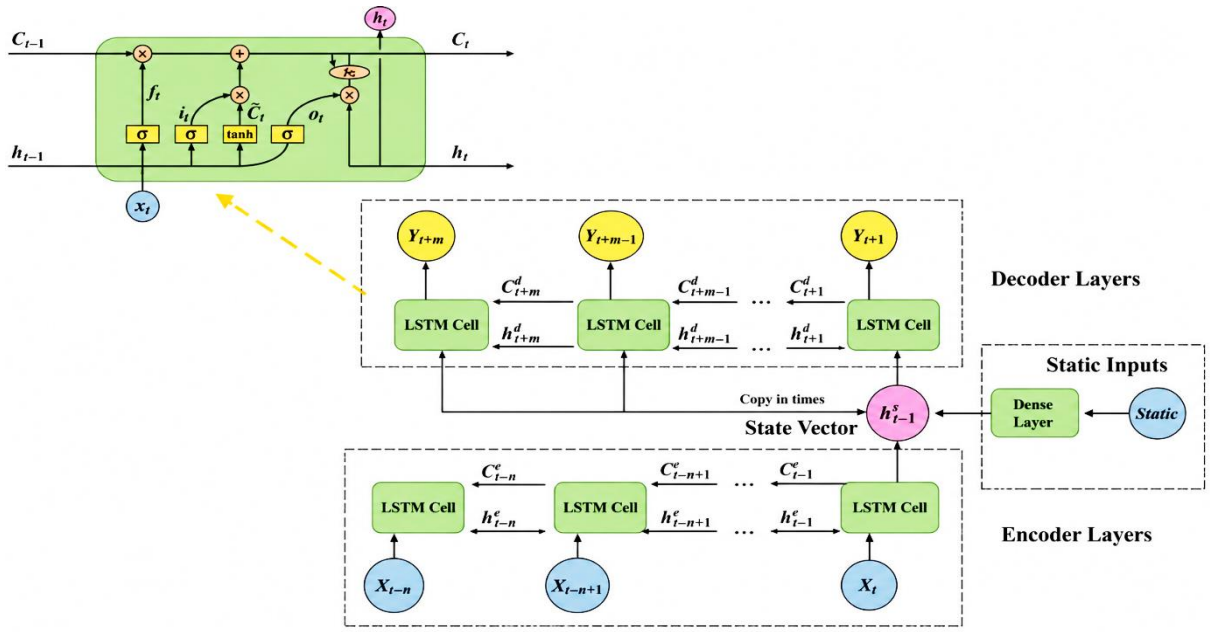

Fig. 2 - LSTM Cell Configuration: σ and tanh represent the sigmoid and tanh activation functions, respectively. X represents the input. C and h represent the cell state and hidden state at the current time step (Zhang et al., 2022).

شکل ۲- پیکربندی سلول LSTM: σ و tanh به ترتیب نشان‌دهنده توابع فعال‌سازی سیگموئید و tanh هستند. X نشان‌دهنده ورودی است. C و h نیز به ترتیب حالت سلول و حالت پنهان در گام زمانی فعلی هستند (Zhang et al., 2022).

۲-۳- معیارهای اندازه‌گیری خطا

در پیش‌بینی سری‌های زمانی با استفاده از یادگیری عمیق، انتخاب یک تابع زیان مناسب برای هدایت فرآیند آموزش و بهینه‌سازی عملکرد مدل، حیاتی است. یکی از توابع زیان رایج مورد استفاده برای بررسی عملکرد مدل‌های پیش‌بینی سری‌های زمانی، میانگین مطلق خطا (MAE[7]) است که اختلاف بین مقادیر پیش‌بینی شده و مشاهدات را در طول توالی سری‌های زمانی اندازه‌گیری می‌کند. هدف این تابع زیان به حداقل رساندن خطای بین مقادیر پیش‌بینی شده و واقعی است و یادگیری کارآمد الگوها و روندهای اساسی را برای مدل تسهیل می‌کند (Elharrouss et al., 2025). بنابراین MAE، میانگین قدرمطلق تفاضل بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. MAE طبق رابطه زیر محاسبه می‌شود (Terven et al., 2025):

$$\mathrm{MAE} = \sum_{i=1}^{N} \left| x_{est,i} - x_{meas,i} \right| / N \qquad (۷)$$

RMSE[8] یک معیار رایج برای ارزیابی دقت مدل‌های رگرسیون است که با محاسبه جذر میانگین مربع خطاها، میزان انحراف پیش‌بینی‌ها از مقدارهای واقعی اندازه‌گیری می‌شود.

$$\mathrm{RMSE} = \sqrt{\sum_{i=1}^{N} (x_{est,i} - x_{meas,i})^2 / N} \qquad (۸)$$

در روابط ۷ و ۸، N تعداد داده‌هاست، $x_{est,i}$ مقدار واقعی خروجی و $x_{meas,i}$ مقدار پیش‌بینی‌شده آن برای داده iام است (Pir Ali et al., 2020).

۳- نتایج

در این بخش در ابتدا مقادیر بارش ایستگاه ده بالا و دبی جریان خروجی ایستگاه‌های هیدرومتری باغستان و طرزجان مورد بررسی قرار می‌گیرد. در ادامه با استفاده از برنامه متلب، نتایج مدل LSTM برای پیش‌بینی دبی جریان خروجی ایستگاه‌های باغستان و طرزجان مورد تجزیه‌وتحلیل قرار می‌گیرد.

۳-۱- مقادیر بارش در ایستگاه ده بالا

مقادیر مجموع بارش روزانه و ماهانه در ایستگاه ده بالا در شکل ۳ نمایش داده شده است. طول آماری این داده‌ها ۲۹ سال (از سال ۱۳۷۰ تا سال ۱۳۹۸) است. همان‌گونه که شکل نشان می‌دهد، پیک بارش روزانه در سال ۱۳۹۷ بوده است که مقدار بارش حدود ۸۶ میلی‌متر است. همچنین، پیک بارش ماهانه در سال ۱۳۸۵ بوده است که مقدار مجموع بارش ماهانه حدود ۲۴۰ میلی‌متر است.

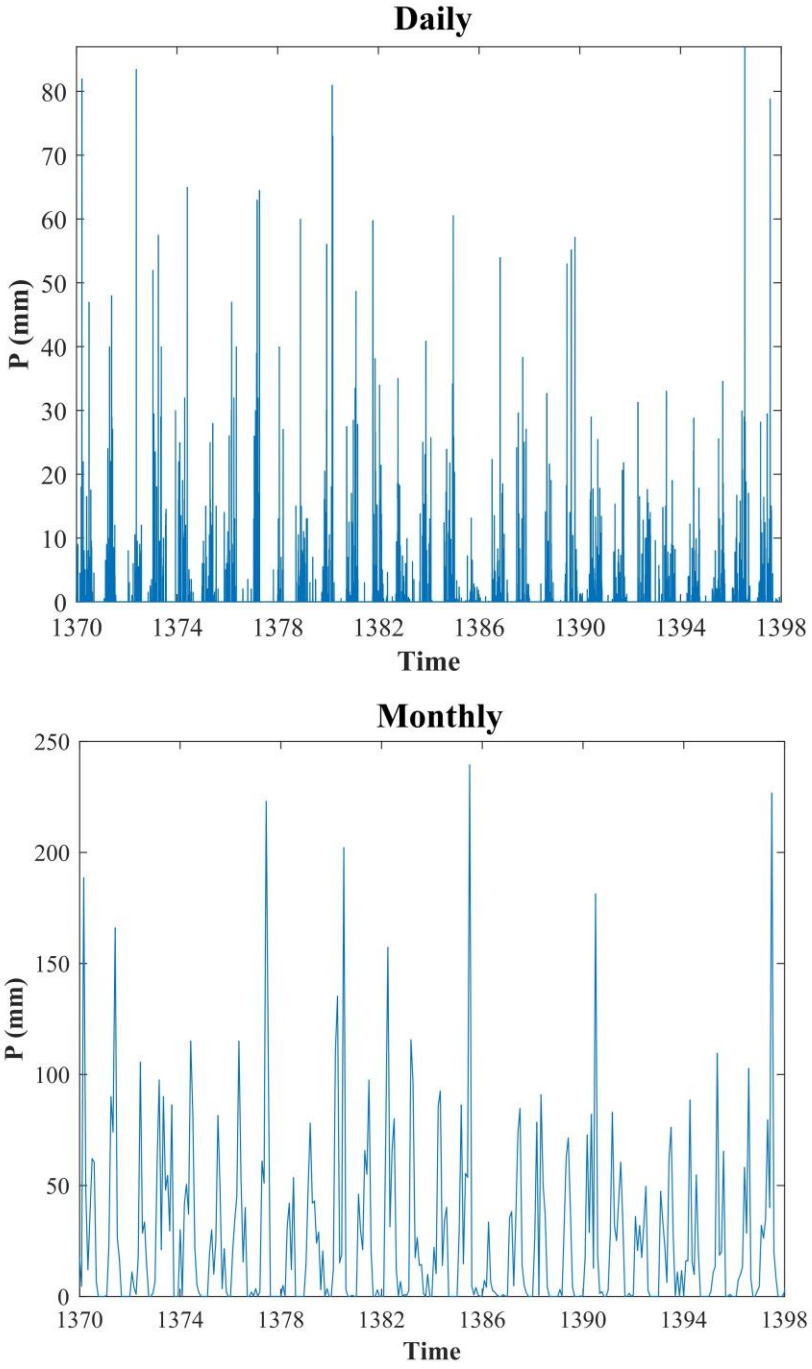

Fig. 3- Daily and monthly total precipitation values at Deh Bala station during the period 1370-1398

شکل ۳- مقادیر مجموع بارش روزانه و ماهانه ایستگاه ده بالا در دوره ۱۳۹۸-۱۳۷۰

شکل ۴ نشان‌دهنده مجموع بارش ایستگاه ده بالا در سری‌های زمانی مختلف است. تحلیل سری زمانی، در سال‌های گذشته توسط بسیاری از محققین مورد توجه قرار گرفته است. هدف اصلی در تحلیل سری زمانی در مورد یک رخداد نیز ایجاد یک مدل آماری برای داده‌های وابسته به زمان بر اساس داده‌های گذشته آن پدیده است. این اقدام امکان پیش‌بینی در مورد آینده رخداد مورد مطالعه را میسر می‌سازد. به عبارت دیگر تحلیل سری زمانی، مدلی را با اطلاعات گذشته می‌سازد تا زمینه تصمیم‌گیری برای اقدامات آینده را مشخص سازد. در این تحقیق برای مطالعه بارش سری‌های زمانی ۳، ۶، ۹، ۱۲، ۱۸ و ۲۴ ماه در نظر گرفته شده است. خط روند نیز جهت بررسی روند کلی بارش در دوره مطالعه به هر شش نمودار اضافه شده است. نمودارها نشان می‌دهند که هرچه سری زمانی طولانی‌تر باشد، روند بارش بهتر نشان داده می‌شود. در مقابل هرچه سری زمانی کوتاه‌تر باشد، به دلیل نوسانات بیشتر، روند نمودار وضوح کمتری دارد. به‌طور کلی می‌توان نتیجه گرفت روند بارش در هر شش مقیاس زمانی ارائه شده کاهشی است.

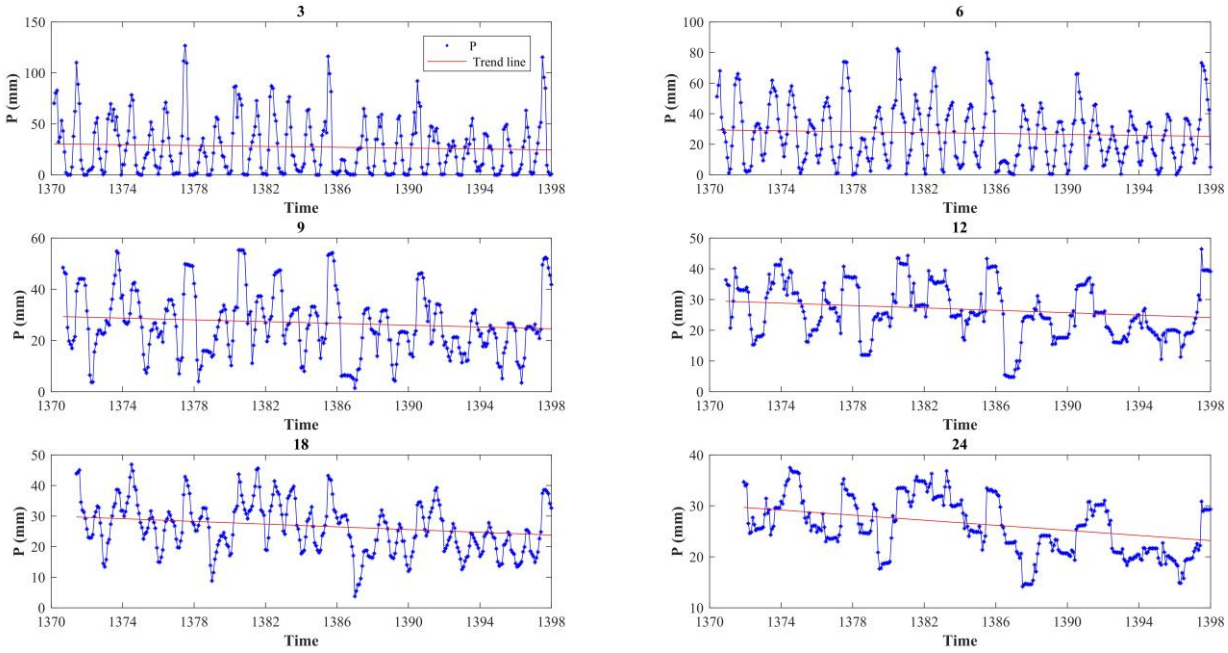

Fig. 4- Precipitation time series at Deh Bala stataion during the period 1370- 1398

شکل ۴- سری‌های زمانی بارش ایستگاه ده بالا در دوره ۱۳۹۸-۱۳۷۰

۳-۲- مقادیر دبی مشاهداتی

ایستگاه‌های باغستان و طزرجان، دو ایستگاه هیدرومتری حوزه فخرآباد است. شکل ۵ مقادیر دبی متوسط روزانه و ماهانه ایستگاه‌های باغستان و طزرجان را در دوره آماری مورد مطالعه نمایش می‌دهد. مطابق با شکل ۵ (الف)، مقدار دبی روزانه ایستگاه باغستان در سال‌های ۱۳۹۷ و ۱۳۹۸ به پیک خود رسیده است. نکته قابل ذکر این است که مقادیر پیک دبی با گذر زمان افزایش داشته است. همچنین، فاصله زمانی بین دو رخداد پیک افزایش یافته است. خط روند نشان‌دهنده الگوی ملایم کاهشی در دبی‌های روزانه ایستگاه باغستان در دوره مطالعه است. طبق شکل ۵ (ب)، فاصله زمانی رسیدن به هر رخداد پیک دبی ماهانه در ایستگاه باغستان نیز با پیشرفت زمان تا حدی افزایش داشته است. دبی ماهانه ایستگاه باغستان روند کاهشی شدیدتری را نسبت به دبی روزانه نشان می‌دهد. اشکال ۵ (ج) و ۵ (د) نشان می‌دهد که در ایستگاه طزرجان نیز مقادیر دبی متوسط روزانه و ماهانه دارای روند کاهشی هستند.

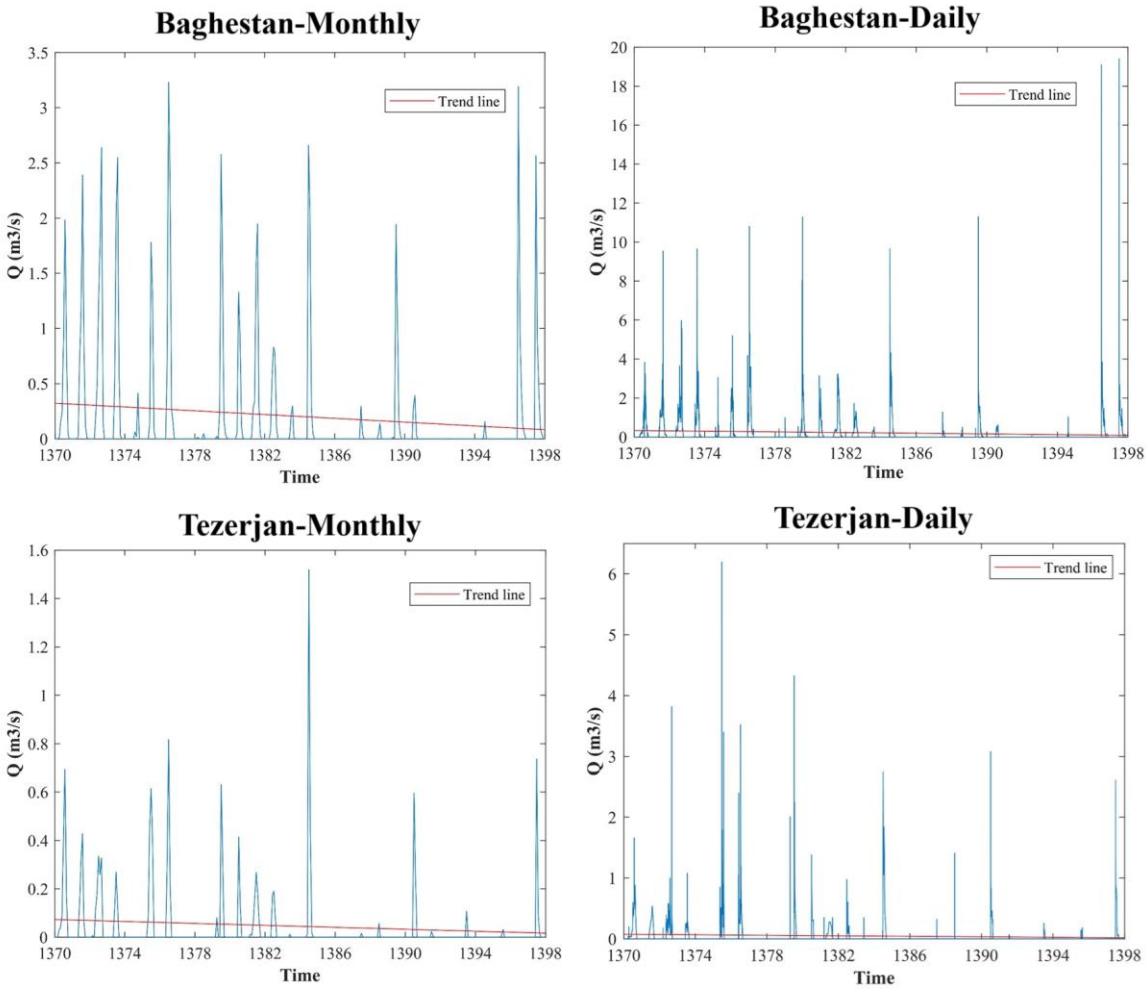

Fig. 5- Daily and monthly streamflow of Baghestan and Tezergan during the study period

شکل ۵- مقادیر دبی روزانه و ماهانه ایستگاه‌های باغستان و طزرجان در دوره آماری مورد مطالعه

۳-۳- پیش‌بینی دبی توسط الگوریتم شبکه عصبی LSTM

در این بخش به بررسی کارآیی مدل LSTM در پیش‌بینی دبی پرداخته می‌شود. بدین منظور حدود ۹۰ درصد داده‌ها (مقادیر مربوط به سال‌های ۱۳۷۰ تا ۱۳۹۵) جهت آموزش و تقریباً ۱۰ درصد باقی‌مانده (مقادیر مربوط به سال‌های ۱۳۹۶ تا ۱۳۹۸) جهت تست در اختیار مدل قرار گرفت. جهت آموزش مدل از الگوریتم Adam استفاده شد. تابع هزینه (Loss Function) فرآیند آموزش مدل برای پیش‌بینی دبی سه‌ماهه ایستگاه باغستان به‌عنوان نمونه در شکل ۶ نمایش داده شده است. منحنی تابع هزینه، مقدار loss در فرایند آموزش مدل را در مقابل تعداد تکرارها رسم می‌کند. یک منحنی loss، نکات زیر را در مورد آموزش مدل ارائه می‌دهد: شیب رو به پایین نشان می‌دهد که مدل در حال بهبود است. شیب رو به بالا نشان می‌دهد که مدل در حال بدتر شدن است. شیب صاف نشان می‌دهد که مدل به همگرایی رسیده است. منحنی loss در شکل زیر نشان می‌دهد شیب تند رو به پایین در طول تکرارهای اولیه، ناشی از بهبود سریع عملکرد مدل است. شیب به‌تدریج صاف (اما همچنان رو به پایین) تا نزدیک به پایان آموزش نشان‌دهنده بهبود مداوم مدل با سرعتی تا حدودی کندتر از طول تکرارهای اولیه است. شیب صاف به سمت پایان آموزش نشان‌دهنده همگرایی مدل است. همگرایی در یادگیری ماشین به این معنی است که مدل با به حداقل رساندن تابع loss که تفاوت بین نتایج پیش‌بینی‌شده و واقعی را اندازه‌گیری می‌کند، پیش‌بینی‌های خود را در طول زمان بهبود می‌بخشد. اگر همگرایی اتفاق نیافتد، فرایند یادگیری مدل به‌طور صحیح انجام نشده است. همان‌گونه که شکل نشان می‌دهد،

RMSE و loss (MAE) در طول فرآیند آموزش مدل کاهش یافته‌اند.

در آموزش مدل‌های یادگیری عمیق، داده‌ها معمولاً به‌صورت mini-batch پردازش می‌شوند؛ روشی که در آن گرادیان‌ها بر اساس یک بخش کوچک از داده‌ها محاسبه و وزن‌ها در هر مرحله به‌روز می‌شوند. این شیوه، ضمن افزایش سرعت و کارایی محاسباتی، ذاتاً باعث ایجاد نوسانات موقت در مقدار خطا می‌شود؛ زیرا ترکیب نمونه‌های هر mini-batch از نظر سختی و پراکندگی یکنواخت نیست. ازاین‌رو، وقوع نوساناتی مانند پرش محسوس در حوالی ایپاک ۲۰۰ و نوسانات کوچک‌تر در ایپاک‌های بعدی، رفتاری طبیعی و مورد انتظار در آموزش مبتنی بر mini-batch بوده و همان‌طور که در نمودار نیز مشاهده می‌شود، این نوسانات گذرا بوده و بر روند همگرایی و عملکرد نهایی مدل تأثیری ندارند.

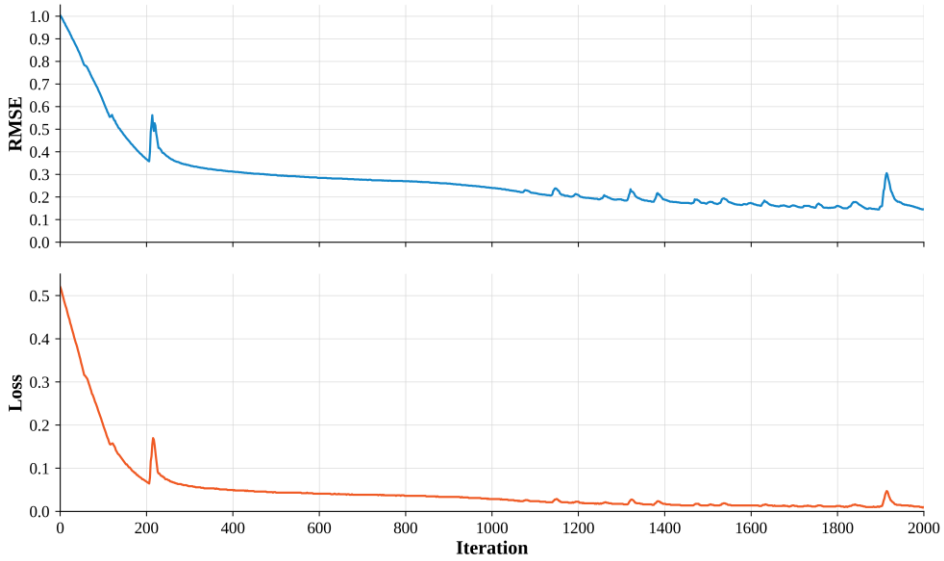

Fig. 6- Training process of LSTM model for predicting three-month streamflow at Baghestan station

شکل ۶- نمودار تکرار آموزش مدل LSTM برای پیش‌بینی دبی سه‌ماهه ایستگاه باغستان

مقایسه مقادیر دبی مشاهداتی روزانه ایستگاه‌های باغستان و طزرجان با مقادیر پیش‌بینی شده توسط مدل LSTM مربوط به دوره تست (۱۳۹۶ تا ۱۳۹۸) در شکل ۷ نمایش داده شده است. ایستگاه باغستان در دوره تست مدل شاهد وقوع دو رخداد دبی پیک و ایستگاه طزرجان شاهد یک رخداد بوده است. مقادیر دبی پیک پیش‌بینی شده توسط مدل LSTM در هر دو ایستگاه کمتر از مقدار واقعی برآورد شده است. اما مدل در پیش‌بینی مقدار دبی پیک ایستگاه باغستان دقت لازم را ارائه نکرده است. به‌طور کلی اساس نتایج مدل می‌توان نتیجه گرفت با استفاده از نتایج پیش‌بینی دبی ارائه شده توسط مدل در هر دو ایستگاه هشدار وقوع سیلاب برای رخدادهای سیلاب قابل صدور بوده است.

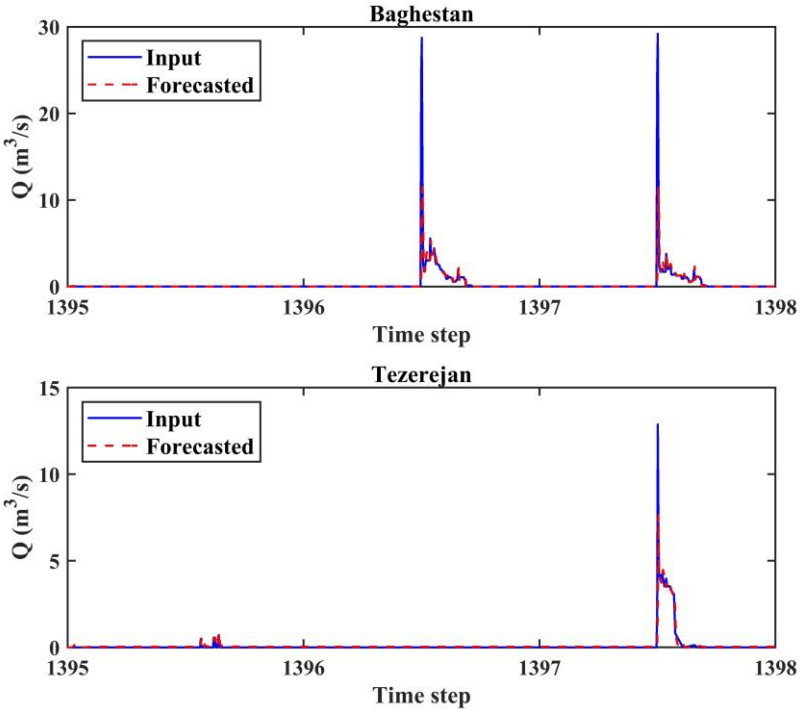

Fig. 7- Comparison of observed daily stramflow with predicted values by the LSTM at Baghestan and Tezergan stations

شکل ۷- نمودار مقایسه مقادیر واقعی دبی روزانه ایستگاه‌های باغستان و طزرجان با مقادیر پیش‌بینی شده توسط مدل LSTM

با افزایش مقیاس سری زمانی انتظار می‌رود با کاهش نوسانات کوتاه‌مدت، دقت مدل برای پیش‌بینی بهبود یابد. بدین منظور در این بخش، توانایی مدل LSTM برای پیش‌بینی دبی سه‌ماهه ایستگاه‌های باغستان و طزرجان مورد بررسی قرار گرفت. همان‌گونه که قبلاً ذکر شد، برای این بخش ابتدا دبی متوسط ماهانه برای دو ایستگاه هیدرومتری مورد مطالعه در دوره آماری موردنظر محاسبه شد. سپس میانگین متحرک دبی سه‌ماهه برای هر ایستگاه محاسبه شد. دبی‌های محاسبه شده به دو دوره آموزش و تست تقسیم شد و در اختیار مدل قرار گرفت.

در شکل ۸ مقادیر دبی مشاهداتی سه‌ماهه ایستگاه باغستان و طزرجان در دوره ارزیابی و مقادیر پیش‌بینی شده توسط الگوریتم LSTM مقایسه شده‌اند. نتایج نشان می‌دهد مدل LSTM در مقیاس سه‌ماهه عملکرد نسبتاً بهتری را در مقایسه با پیش‌بینی روزانه ارائه کرده است. در مقیاس سه‌ماهه، ایستگاه هیدرومتری باغستان در دوره ارزیابی مدل، سه رخداد دبی پیک و ایستگاه طزرجان دو رخداد را ثبت کرده است. همان‌گونه که شکل ۸ نشان می‌دهد، در ایستگاه باغستان، مقادیر پیش‌بینی شده برای رخداد دبی پیک اول و دوم از مقادیر مشاهداتی کوچک‌تر برآورد شده‌اند که مقدار این کوچک‌نمایی در رخداد پیک دوم، کمتر است. رخداد سوم با بزرگ‌نمایی پیش‌بینی شده است. در ایستگاه طزرجان نیز رخداد پیک اول با بزرگ‌نمایی و رخداد دوم با کوچک‌نمایی پیش‌بینی شده است. البته لازم به ذکر است مقادیر کوچک‌نمایی و بزرگ‌نمایی در هر دو ایستگاه نسبتاً قابل‌قبول است و هشدار وقوع سیلاب برای هر دو ایستگاه قابل صدور بوده است.

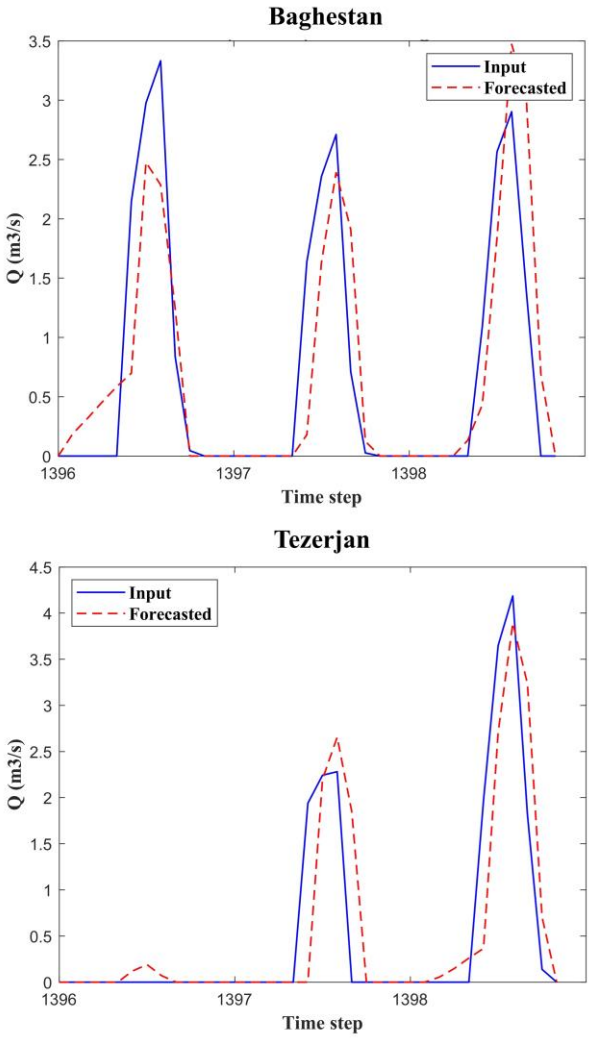

Fig. 8- Comparison of observed 3-month stramflow with predicted values by the LSTM at Baghestan and Tezergan stations

شکل ۸- نمودار مقایسه مقادیر واقعی دبی سه ماهه ایستگاه‌های باغستان و طزرجان با مقادیر پیش‌بینی شده توسط مدل LSTM

لازم به ذکر است فرآیند آموزش مدل LSTM در هر دو ایستگاه هیدرومتری مورد مطالعه و مقیاس‌های زمانی موردنظر به‌دفعات متعدد تکرار شد تا با وزن‌های اولیه تصادفی در هر تکرار، مدل از نقاط شروع متفاوتی آموزش را آغاز کند. نتایج نشان داد که اختلاف بین مقادیر خطا در تکرارهای مختلف قابل‌توجه نیست و همه مدل‌ها به مقادیر مشابهی از تابع هزینه همگرا شده‌اند. این رفتار می‌تواند بیانگر آن باشد که مدل در مینیمم محلی گرفتار نشده و فرآیند آموزش به‌صورت پایدار به نقطه همگرایی سراسری نزدیک شده است. نکته دیگر که باید مدنظر قرار گیرد این است که اگر منحنی تابع هزینه (Loss) با گذشت ایپاک‌ها به‌صورت یکنواخت نزولی و در انتها صاف و پایدار باشد، یعنی مدل به نقطه همگرایی واقعی رسیده است.

۳-۴- مقایسه کارآیی مدل‌های LSTM مورد استفاده

به‌منظور بررسی دقیق‌تر کارآیی مدل‌های LSTM به کار رفته در تحقیق در پیش‌بینی دبی ایستگاه‌های مورد مطالعه، ضریب تعیین (R2) و جذر میانگین مربعات خطا (RMSE) بین مقادیر دبی مشاهداتی و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های باغستان و طزرجان محاسبه شد. نتایج به دست آمده در جدول ۱ نمایش داده شده است. نتایج نشان می‌دهد در ایستگاه باغستان، کارآیی مدل در پیش‌بینی دبی متوسط سه‌ماهه از دبی

متوسط روزانه بیشتر است. در حالی که در ایستگاه طزرجان، عملکرد مدل در مقیاس روزانه از کارآیی مدل در مقیاس سه‌ماهه، بالاتر بوده است. در مجموع در بین مدل‌های به کار رفته، مدل LSTM مورد استفاده برای پیش‌بینی دبی روزانه ایستگاه طزرجان با ضریب تعیین برابر ۰/۷۸ و RMSE برابر ۰/۴۳ از عملکرد بالاتری برخوردار است.

Table 1- Comparison of R^2 and RMSE values between observed and LSTM-predicted streamflow at the Baghestan and Tazerjan stations

جدول ۱- مقادیر R2 و RMSE بین مقادیر دبی مشاهداتی و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های باغستان و طزرجان

Station	Time scale	R2	RMSE
Baghestan	Daily	0.51	1.27
Tezergan	Daily	0.78	0.43
Baghestan	Monthly	0.74	0.56
Tezergan	Monthly	0.70	0.62

۴- بحث و نتیجه‌گیری

در مناطقی که مستعد وقوع سیلاب هستند، پیش‌بینی زمان وقوع سیلاب با استفاده از داده‌های گذشته کمک‌کننده و حیاتی است. چون ممکن است از احتمال خسارات مالی و حتی جانی جلوگیری به عمل آورد. در سال‌های اخیر، مدل‌های یادگیری ماشین به‌عنوان جایگزین‌های مناسب برای تحلیل سری‌های زمانی برجسته شده‌اند. الگوریتم‌های یادگیری ماشین و الگوریتم‌های شبکه عصبی چارچوبی انعطاف‌پذیر ارائه می‌کنند که می‌تواند روابط پیچیده درون داده‌ها را ثبت کند (Eghtesad and Mohammadi, 2023). از آنجا که داده‌های دبی جریان خروجی، از نوع تصادفی و پیوسته هستند، می‌توان آن‌ها را به‌صورت سری زمانی در نظر گرفت و از الگوریتم‌های یادگیری عمیقی استفاده کرد که با تکیه بر یادگیری نظارت نشده، برای تحلیل سری‌های زمانی در حال توسعه هستند. در این بین، شبکه‌های عصبی بازگشتی، کارآمدترین روش پیش‌بینی سری زمانی هستند (Ziyadi et al., 2022). در واقع ایده شبکه بازگشتی نیز از رفتار انسان‌ها در زمینه تصمیم‌گیری نشأت گرفته است؛ چراکه انسان‌ها موجوداتی هستند که از تمام اطلاعات قبلی‌شان برای تصمیم‌گیری جدیدشان استفاده می‌کنند و به این حالت نیست که فقط از آخرین اطلاعاتشان استفاده کنند. از آنجا که شبکه‌هایی مثل شبکه‌های حافظه کوتاه‌مدت طولانی‌مدت با موفقیت چشم‌گیر در پیش‌بینی سری‌های زمانی به کار گرفته شده‌اند. LSTM حالت سلولی و مخفی دارد که می‌تواند اثرات حافظه کوتاه‌مدت را در بربگیرد. بنابراین، انتخاب خوبی برای مدل‌سازی سری‌های زمانی رواناب است، زیرا می‌تواند طیفی از تأخیرهای وابسته به زمان، مانند چرخه‌های فصلی و تغییرپذیری طبیعی سالانه (طولانی‌مدت، ماه‌ها تا سال‌ها) و پاسخ فوری بارندگی- رواناب (کوتاه‌مدت، از دقیقه تا ساعت) را در نظر بگیرد (Zhang et al., 2022).

در این پژوهش که در حوزه فخرآباد استان یزد صورت پذیرفت، یک ایستگاه هواشناسی (ده بالا) و دو ایستگاه هیدرومتری شامل باغستان و طزرجان مورد بررسی قرار گرفتند. نتایج نشان داد بارش در ایستگاه ده بالا در دوره آماری مورد مطالعه شاهد یک روند کاهشی ملایم بوده است. در این مطالعه علاوه بر مقیاس روزانه، سری‌های زمانی (میانگین متحرک) سه‌ماهه نیز برای پیش‌بینی دبی مورد استفاده قرار گرفت. نتایج نشان داد پیش‌بینی دبی به کمک مدل LSTM دارای دقت قابل قبولی بود. با توجه به پراکنش نامنظم بارش در مناطق خشک انتظار می‌رود که جریان خروجی حوزه‌ها نیز الگوی نامنظمی داشته باشد. نتایج ارائه شده برای دبی خروجی ایستگاه‌های باغستان و طزرجان در مقیاس‌های زمانی مختلف نشان داد دبی نیز در نتیجه پراکنش نامنظم بارش، دارای الگوی کاملاً نامنظمی بوده است. با توجه به این الگوی نامنظم، کارآمدی مدل‌های پیش‌بینی دچار افت قابل‌توجه می‌شود. اما نتایج مطالعه نشان داد با توجه به اینکه مدل LSTM علاوه بر حافظه کوتاه‌مدت معمول، دارای حافظه بلندمدت نیز است، این مدل افزایش دبی و رخداد سیلاب را قبل از وقوع پیش‌بینی کرده است. البته در مقیاس روزانه، دبی‌های پیش‌بینی شده نسبت به دبی سیلاب‌های اتفاق افتاده، مقادیر کمتری را نشان می‌دهند. اما به‌طور کلی بر اساس مقادیر پیش‌بینی شده، وقوع سیلاب قابل پیش‌بینی است. نتایج به دست آمده از محاسبه ضریب تعیین (R2) بین مقادیر دبی مشاهداتی و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های باغستان و طزرجان نشان داد مدل LSTM مورد استفاده برای پیش‌بینی دبی روزانه ایستگاه طزرجان با ضریب تعیین برابر ۰/۷۸ و RMSE برابر ۰/۴۳ دارای بالاترین کارآیی است.

در مجموع نتایج نشان داد که الگوریتم LSTM توانایی لازم برای ایجاد سامانه هشدار سیلاب برای ایجاد آمادگی لازم برای مقابله با حوادث احتمالی سیلاب در حوزه مورد مطالعه را فراهم می‌سازد. این الگوریتم در کارهای تحقیقاتی دیگر نیز توانسته است کارآمد بودن خود را نشان دهد. به‌عنوان مثال فنگ و همکارانش بعد از بررسی‌های انجام گرفته بر روی منطقه‌ای از کشور چین، دقت الگوریتم LSTM در پیش‌بینی سیل را ۹۳/۷۵ درصد تعیین کردند

(Fang et al., 2021). Hu et al. (2018) نیز در چین برای شبیه‌سازی بارش رواناب از داده‌های ۱۵ ایستگاه در طول ۴۲ سال استفاده کردند. نتیجه نشان‌دهنده این موضوع بود که الگوریتم LSTM نسبت به سایر الگوریتم‌های شبکه عصبی، برای مدل‌سازی بارش و رواناب مناسب‌تر است و می‌تواند پیش‌بینی سیل را به‌درستی انجام دهد.

کارایی الگوریتم LSTM در پژوهش Li et al. (2024) نیز به‌وضوح به چشم می‌آید. در این تحقیق که در ناحیه جین هوآ در چین انجام شده است، بر اثربخشی به‌کارگیری مدل‌های LSTM آموزش‌دیده بر روی مجموعه داده‌های مختلط برای پیش‌بینی سیل تأکید شده و در نهایت پیش‌بینی دقیق و قابل اعتماد سیل ارائه شده است. همچنین، در پژوهش دیگری که توسط Li et al. (2024) بر روی حوزه رودخانه زرد انجام شد، داده‌ها از سال ۱۹۷۱ تا سال ۲۰۱۳ مورد بررسی قرار گرفتند که در نهایت نشان دادند که مدل LSTM از کارایی بالایی در پیش‌بینی سیل برخوردار است. بنابراین نتایج تحقیق حاضر در راستای نتایج سایر محققان از مناطق مختلف است و کارآیی قابل‌قبول مدل LSTM را پیش‌بینی وقوع سیلاب تأیید می‌کند. البته با توجه به نتایج جدول ۱، در ایستگاه باغستان، با افزایش مقیاس زمانی دقت پیش‌بینی افزایش یافته است و کارآیی مدل LSTM در پیش‌بینی سری زمانی سه‌ماهه از روزانه بالاتر بوده است. در ایستگاه طزرجان، عملکرد مدل در مقیاس روزانه از سری زمانی سه‌ماهه بالاتر است.

۵- پیشنهادها

این پژوهش در منطقه‌ای خشک مورد بررسی قرار گرفته است. می‌توان در مناطق با میزان بارندگی بیشتر نیز کارآیی مدل را مورد ارزیابی قرار داد. همچنین، می‌توان با ارائه داده‌ها و اطلاعات بیشتر به مدل نظیر اطلاعات مربوط به خاک و هواشناسی پژوهش را انجام داد تا احتمال رخداد خطا کاهش پیدا کند. در پایان پیشنهاد می‌شود از سایر روش‌های جهانی برای پیش‌بینی سیل نیز استفاده شود و نتایج بدست آمده از مدل‌های مختلف با مدل LSTM مقایسه شود.

پی‌نوشت‌ها

1- Long Short-Term Memory (LSTM)
2- Deep Neural Network (DNN)
3- Convolutional LSTM
4- Recurrent Neural Network (RNN)
5- Multi-Layer Perceptron (MLP)
6- Root Mean Square Propagation (RMSProp)
7- Mean Absolute Error (MAE)
8- Root Mean Square Error (RMSE)

۶- منابع

Eghtesad A, Mohammadi A (2023) Optimizing the investment portfolio with the help of predicting the expected return using neural network LSTM random forest and ARIMA. Financial Management Perspective 13(43):9-28 (In Persian)

Elharrouss O, Mahmood Y, Bechqito Y, Serhani MA, Badidi E, Riffi J, Tairi H (2025) Loss functions in deep learning: A comprehensive review. arXiv preprint arXiv:2401.12345

Fang Zh, Wang Y, Peng L, Hong H (2021) Predicting flood susceptibility using LSTM neural networks. Journal of Hydrology 594:125734

Filipova V, Hammond A, Leedal D (2022) Prediction of flood quantiles at ungauged catchments for the contiguous USA using artificial neural networks. Hydrology Research 53(1):107–123

Filonchyk M, Peterson M, Zhang L, Hurynovich V, He Y (2024) Greenhouse gases emissions and global climate change: Examining the influence of CO2, CH4, and N2O. Science of The Total Environment 935:173359

Giovannettone J, Copenhaver T, Burns M, Choquette S (2018) A statistical approach to mapping flood susceptibility in the lower Connecticut River Valley region. Water Resources Research 54:7603–7618

Ha S, Liu D, Mu L (2021) Prediction of Yangtze River streamflow based on deep learning neural network with El Niño–Southern Oscillation. Scientific Reports 11:11738

Hassanzadeh Y, Abdi Kordani A, Fakheri Fard A (2011) Drought forecasting using genetic algorithm and combined neural-wavelet network model. Water and Sewage 23(3):48-59 (In Persian)

Hu C, Wu Q, Li H, Jian S, Li N, Lou Z (2018) Deep learning with a long short -term memory networks approach for rainfall - runoff simulation. Water 10(11):1543

Li J, Wu J, Zhang G, Shi Y (2024) Optimizing flood predictions by integrating LSTM and physical based models with mixed historical and simulated data. Heliyon 10(13):e33669

Li W, Liu Ch, Xu Y, Niu Ch, Li R, Li M, Hu C, Tian L (2024) An interpretable hybrid deep learning model for flood forecasting based on Transformer and LSTM. Journal of Hydrology: Regional Studies 54:101873

Liang C, Li H, Lei M, Du Q (2018) Dongting lake water level forecast and its relationship with the three gorges dam based on a long short -term memory network. Water 10:1389

Kingma D P, Ba J (2015) Adam: A Method for Stochastic Optimization. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings.

Kreibich H, Van Loon AF, Schroeter K, et al. (2022) The challenge of unprecedented floods and droughts in risk management. Nature 608:80–86

Kumar GD, Pradhan KC, Tyagi S (2024) Deep learning forecasting: An LSTM neural architecture-based approach to rainfall and flood impact predictions in Bihar. Procedia Computer Science 235:1455-1466

Moalem M, Pouyan A (2018) Anomaly detection using automatic encoder based on LSTM blocks. Modeling in Engineering 17(56):191-211 (In Persian)

Moore RJ, Bell VA, Jones DA (2005) Forecasting for flood warning. Comptes Rendus Geoscience 337(1):203-217

Moreno JM, S´anchez JM, Espitia HE (2020) Use of computational intelligence techniques to predict flooding in places adjacent to the Magdalena River. Heliyon 6(9):6e0487

National Research Council (2009) Mapping the zone: Improving flood map accuracy. Washington, DC: The National Academies Press

Pirali AR, Hedayati AA, Pormanafi S, Birghadar O, Ghorbani R (2020) Investigation of the efficiency of support vector machine in predicting changes in water quality parameters (Case study: Choghakhor International Wetland). Journal of Aquatic Ecology 10(1):23-34 (In Persian)

Sharaki J, Mohseni B (2010) Application of interactive multi-criteria decision-making in the optimal allocation of water resources, Case study of Yazd city. Irrigation and Water Engineering Research Quarterly 3(4):107-117 (In Persian)

Sharghi T, Bari Abarghuei H, Asadi MA, Kousari MR (2010) Estimation of reference evapotranspiration using FAO-Penman-Monteith method and its zonation in Yazd Province. Journal of Arid Biome 1(1):25-33 (In Persian)

Tabibian SH (2020) Noise-resistant recognition of similar Persian numerals based on LSTM network and speech spectral features. Iranian Journal of Electrical Engineering and Computer Engineering, B-Computer Engineering, 19(1):1-17 (In Persian)

Terven J, Cordova-Esparza, DM, Romero-González JA, et al. (2025) A comprehensive survey of loss functions and metrics in deep learning. Artificial Intelligence Review 58:195

Teufel B, Sushama L, Huziy O, Diro GT, Jeong DI, Winger K, Garnaud C, De Elia RFW, Zwiers HD (2019) Matthews, Investigation of the mechanisms leading to the 2017 Montreal flood. Climate Dynamics 52:4193–4206

Wang L, Cui S, Li Y, Huang H, Manandhar B, Nitivattananon V, Fang X, Huang W (2022) A

review of the flood management: from flood control to flood resilience. Heliyon 8(11):e11763
Xiang Z, Demir I (2020) Distributed long-term hourly streamflow predictions using deep learning- A case study for State of Iowa. Environmental Modelling & Software 131:104761
Yaghmaei N (2020) Human cost of disasters: An overview of the last 20 Years, 2000-2019. UN Office for Disaster Risk Reduction, 30p
Zhang Y, Ragettli S, et al. (2022) Generalization of an Encoder-Decoder LSTM model for flood prediction in ungauged catchments. Journal of Hydrology 614:128577
Ziyadi H, Salvati A, Lotfi Heravi M (2022) Housing price prediction using LSTM artificial intelligence algorithm. financial research 25(4):557-576 (In Persian)