

بررسی کارایی 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 جبران ناپذیری 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 به موقع وقوع سیل می‌تواند تا حد قابل توجهی 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 بهبود یافته 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 ده‌بالا 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. به منظور بررسی کارایی مدل LSTM در پیش‌بینی دبی، معیارهای ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) بین مقادیر دبی مشاهده‌ای و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های باغستان و طزرجان در مقیاس روزانه و سری زمانی سه ماهه 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.

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

۱-۱ مقدمه

در طول قرن گذشته، شتاب جهانی شدن و صنعتی شدن منجر به وقوع پدیده تغییر اقلیم شده است که به طور قابل توجهی شرایط هیدرولوژیکی را تغییر داده است (Kreibich et al., 2022). رواناب یک سیگنال طبیعی و یک سری زمانی غیرخطی پیچیده است که به طور 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 به شدت 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 (Moreno

^۱ دانش آموخته کارشناسی ارشد علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و کوریشناسی، دانشگاه یزد. nastaran.vahdatinasab@gmail.com

^۲ استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و کوریشناسی، دانشگاه یزد. ایمیل amin.asadi@yazd.ac.ir

(et al., 2020; Giovannettone et al., 2018). 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 (Wang et al., 2022; Teufel et al., 2019).

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، جنگل زدایی، تغییرات در عملیات کشاورزی، شهرسازی، مخازن و تغییرات کانال ریسک سیلاب را تا حدی تغییر می‌دهد (Kumar et al., 2024). افزایش روز افزون غلظت گازهای گلخانه‌ای به ویژه گاز دی‌اکسید کربن 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 می‌گردد. 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 به موقع 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 ad Mohammadi., 2023). تاکنون روش‌های مختلفی برای تجزیه و تحلیل و پیش‌بینی سری زمانی دبی جریان خروجی در مناطق مختلف استفاده شده است که به طور 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 اینست 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 ad Mohammadi., 2023). مدل مبتنی بر داده LSTM 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 می‌باشند پس به خوبی می‌تواند از شبکه مذکور برای پیش‌بینی آن بهره برد.

Zhang et al. (2022) به بررسی کارایی 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 توسعه یافته از مدل LSTM را برای پیش‌بینی سیل در حوضه آبخیز در آیووا، ایالات متحده، با مقایسه مدل‌های رایج یادگیری ماشین، مانند رگرسیون خطی، اعمال کرد. آن‌ها تایید کردند که مدل پیشنهادی می‌تواند دقت پیش‌بینی‌های کوتاه مدت سیل را بهبود بخشد. Ha et al. (2021) سه مدل DNN از جمله Conv LSTM 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 شبکه‌ی LSTM بیشتر است. بر اساس مرور منابع انجام گرفته، مطالعه مستقلی که کارایی 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 کوتاه مدت و بلند مدت مورد مطالعه قرار گرفت. همچنین روند تغییرات دبی و بارش نیز در منطقه مطالعه مورد بررسی قرار گرفت.

۲. مواد و روش‌ها

۱.۲ 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 درجه و ۲ دقیقه تا ۵۴ درجه و ۱۵ دقیقه شرقی و عرض ۳۱ درجه و ۳۱ دقیقه تا ۳۱ درجه و ۴۱ دقیقه شمالی می‌باشد. رژیم حرارتی منطقه از نوع مدیترانه‌ای با زمستان‌های سرد در فصول سرد و تابستان‌هایی گرم و خشک می‌باشد (Sharaki and Mohseni, 2010). خروجی این حوزه دشت ابراهیم آباد مهریز نام دارد که آب ناشی از بارندگی و ذوب برف این حوزه توسط رودهای فصلی به این دشت سرازیر می‌گردد. روستاهای ده‌بالا، طزرجان و فخرآباد در این حوزه قرار دارند. متوسط ارتفاع در این حوزه ۲۷۲۰ متر و شیب متوسط در این حوزه ۱۸ درصد می‌باشد. متوسط بارش سالانه حوزه تقریباً ۲۰۵ میلی‌متر است. توزیع بارش‌ها در بخش‌های مختلف این حوزه بسیار متفاوت است زیرا در این حوزه قله‌ی شیرکوه با ارتفاع ۴۰۷۵ متر از سطح دریا وجود دارد و همچنین ارتفاع خروجی حوزه ۱۸۰۰ متر بالاتر از سطح دریا می‌باشد. به عنوان مثال، بارش‌ها در ده‌بالا بیشتر به صورت برف و متوسط بارش ۲۰ ساله این زیر حوزه حدود ۳۰۰ میلی‌متر می‌باشد. در حالت کلی اغلب بارش از نوع باران و متوسط بارش سالانه حدود ۱۰۰ میلی‌متر می‌باشد. به طور 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 ده‌بالا که در شکل ۱ قابل رویت هستند.

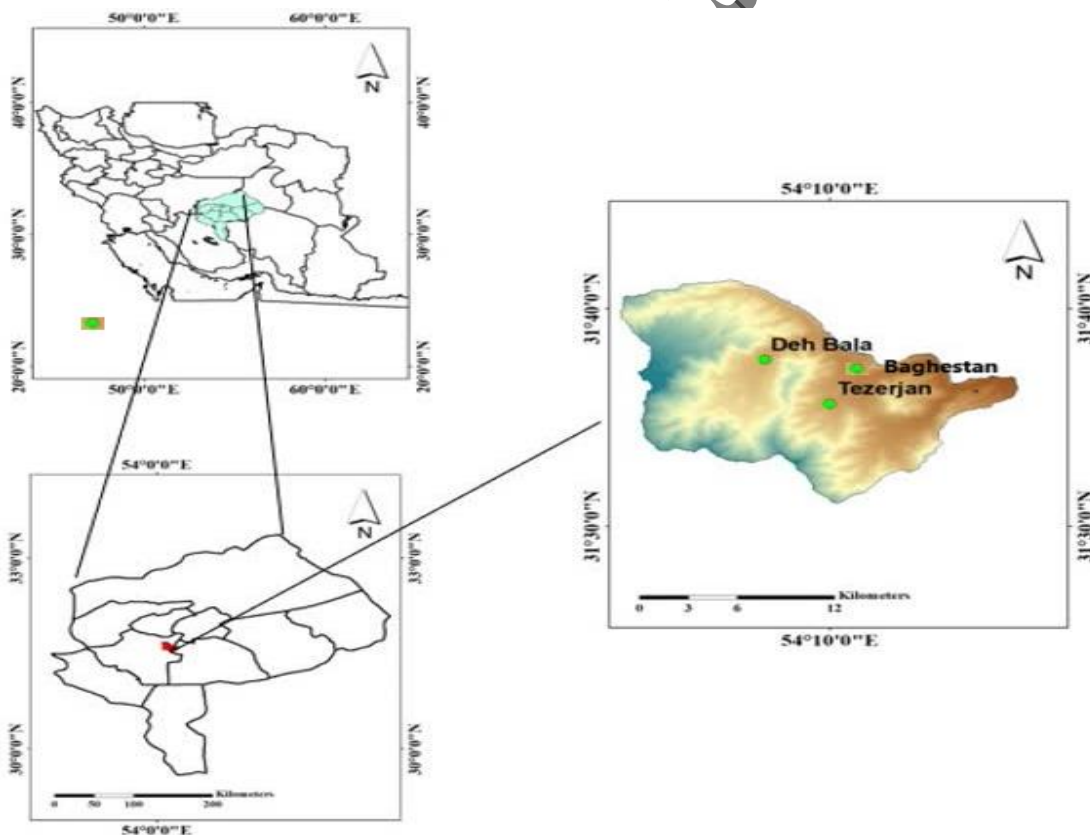


Fig. 1- Geographic location of Fakhrabad watershed in Yazd province, Iran

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

۲.۲ شبکه‌ی 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 گردیدند. 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). شبکه‌ی 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 بود. RNN ها، ساختاری بسیار مشابه با شبکه‌های چندلایه پرسپترون (MLP) دارند، با این تفاوت که نورون‌های لایه مخفی علاوه بر یال‌های رو به جلو، یک یال هم به صورت بازگشتی و با احتساب یک زمان تأخیر، از خودشان به خودشان دارند. چنین ساختاری به یادسپاری وابستگی‌های کوتاه مدت 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 گردید (Tabibian, 2022). در واقع در مدل LSTM، خروجی شبکه به عنوان یک ورودی در نظر گرفته می‌شود و دوباره به شبکه باز می‌گردد. 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 تجزیه و تحلیل 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 می‌گیرند. 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 LSTM ها معرفی شده‌اند: دروازه ورودی، دروازه فراموشی و دروازه خروجی. علاوه بر آن، سلول‌های حافظه وجود دارند که شکلی مشابه حالت پنهان دارند. یک سلول حافظه فقط یک نسخه از یک حالت پنهان است که به صورت 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 هم از حرکت زیگزآگی جلوگیری می‌کند، هم شدت جهت حرکت را کنترل می‌نماید و همچنین احتمال پیدا کردن 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:

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

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

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

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

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

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

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 فعال سازی 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).

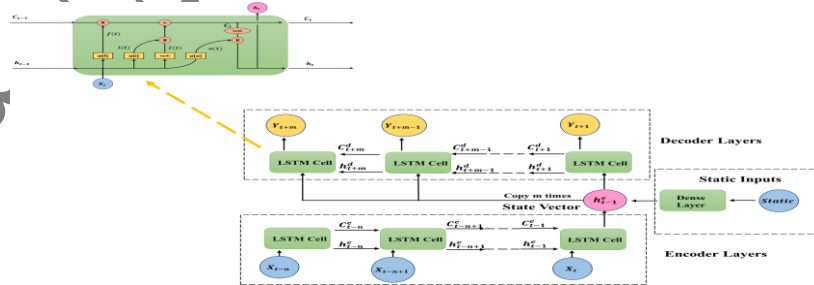


Fig. 2 - LSTM Cell Configuration: σ and \tanh represent the sigmoid and tanh activation functions, respectively. X represents the input. C and h represent the cell state and hidden state at the current time step (Zhang et al., 2022).

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

۳.۲ 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) 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):

$$MAE = \sum_{i=1}^N |x_{est,i} - x_{meas,i}| / N \quad (7)$$

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

$$RMSE = \sqrt{\sum_{i=1}^N (x_{est,i} - x_{meas,i})^2 / N} \quad (8)$$

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

۳ نتایج

در این بخش در ابتدا مقادیر بارش ایستگاه ده‌بالا و دبی جریان خروجی ایستگاه‌های هیدرومتری باغستان و طزرجان مورد بررسی قرار می‌گیرد. در ادامه با استفاده از برنامه‌ی متلب، نتایج مدل LSTM برای پیش‌بینی دبی جریان خروجی ایستگاه‌های باغستان و طزرجان مورد تجزیه و تحلیل قرار می‌گیرد.

۳.۱ مقادیر بارش در ایستگاه ده‌بالا

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

میلی متر است. همچنین بیک بارش ماهانه در سال ۱۳۸۵ بوده است که مقدار مجموع بارش ماهانه حدود ۲۴۰ میلی متر است.

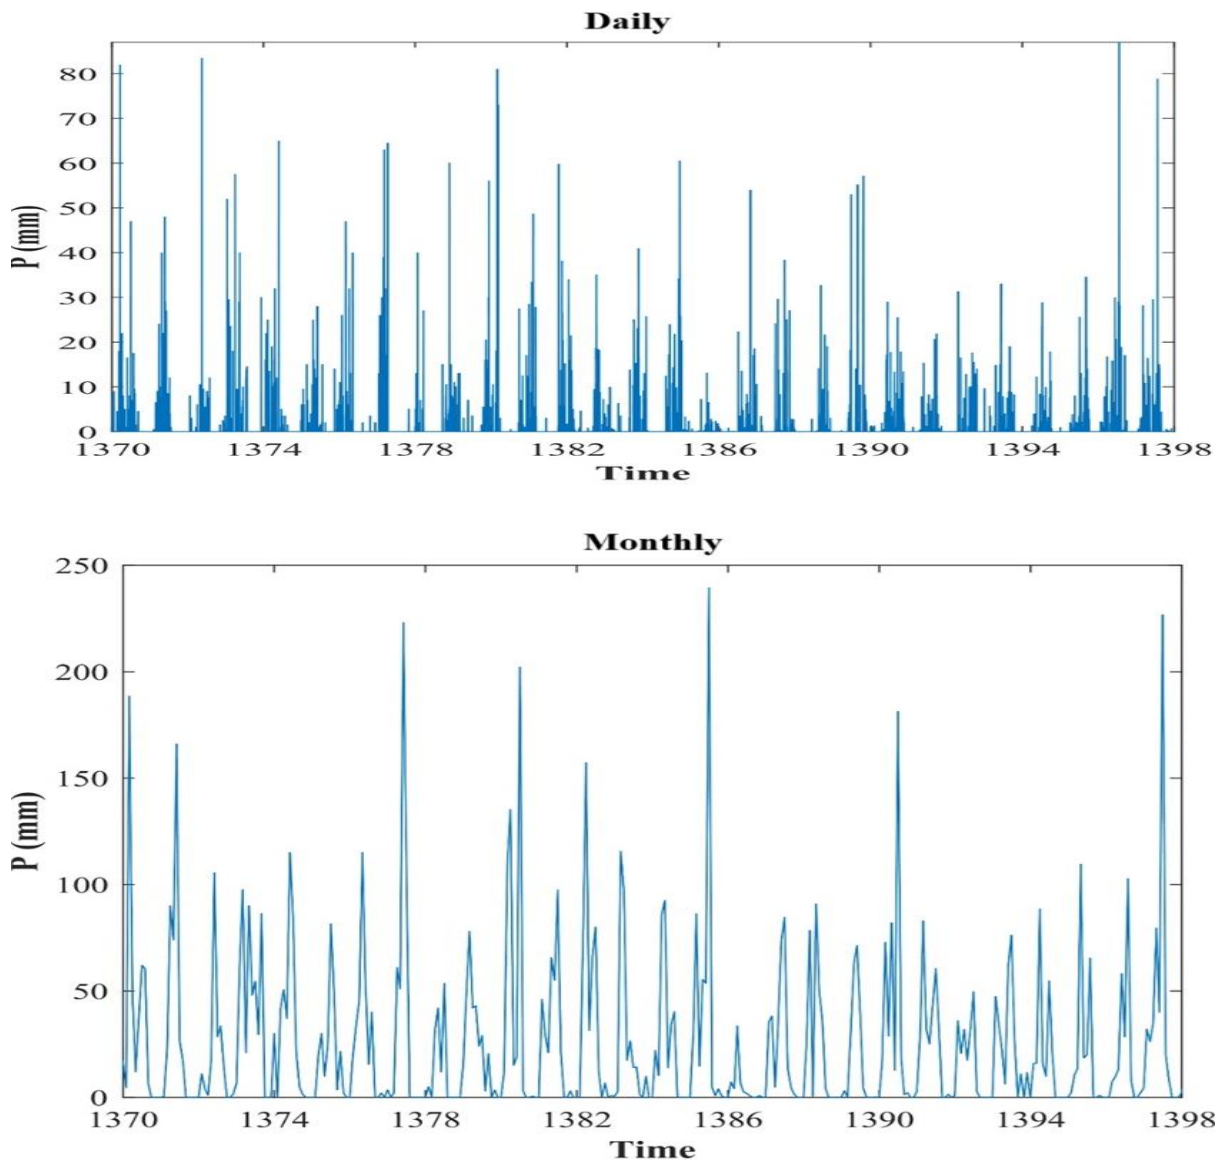


Figure 3- Daily and monthly total precipitation values at Deh Bala station during the period 1370-1398

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

شکل ۴ نشان دهنده 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 می‌باشد. 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 زمینه‌ی 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. به طور کلی می‌توان نتیجه گرفت روند بارش در هر شش مقیاس زمانی ارائه شده کاهش یافته است.

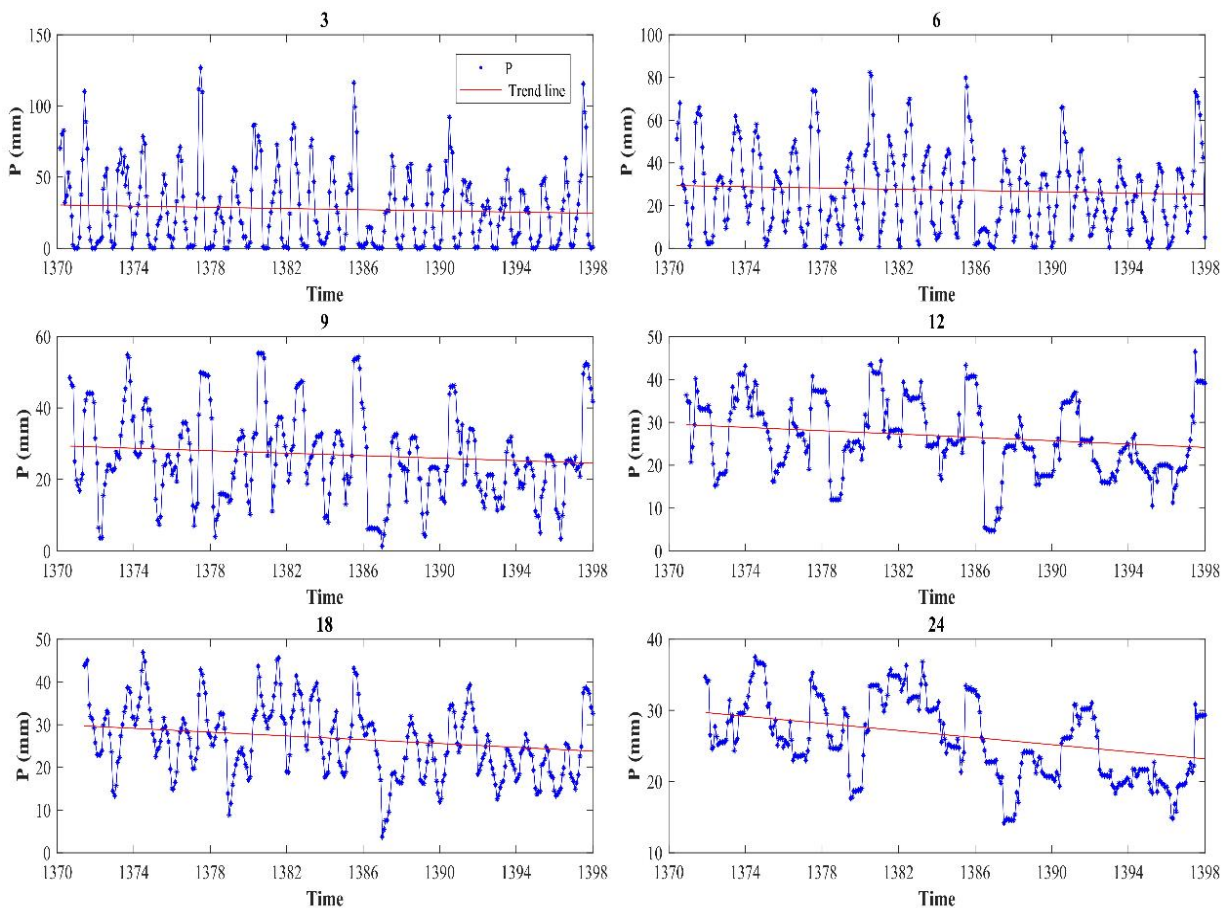


Figure 4- Precipitation time series at Deh Bala station during the period 1370 - 1398

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

۲.۳ مقادیر دبی مشاهداتی

ایستگاه‌های باغستان و طزرجان، دو ایستگاه هیدرومتری حوزه‌ی فخرآباد می‌باشد. 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. نکته‌ی 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 نشان دهنده الگوی ملایم کاهشی در دبی‌های روزانه ایستگاه باغستان در دوره مطالعه می‌باشد. طبق شکل ۵ (ب)، فاصله‌ی 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 می دهد. اشکال ۵ (ج) و ۵ (د) نشان می دهد که در ایستگاه طزرجان نیز مقادیر دبی متوسط روزانه و ماهانه دارای روند کاهشی می باشند.

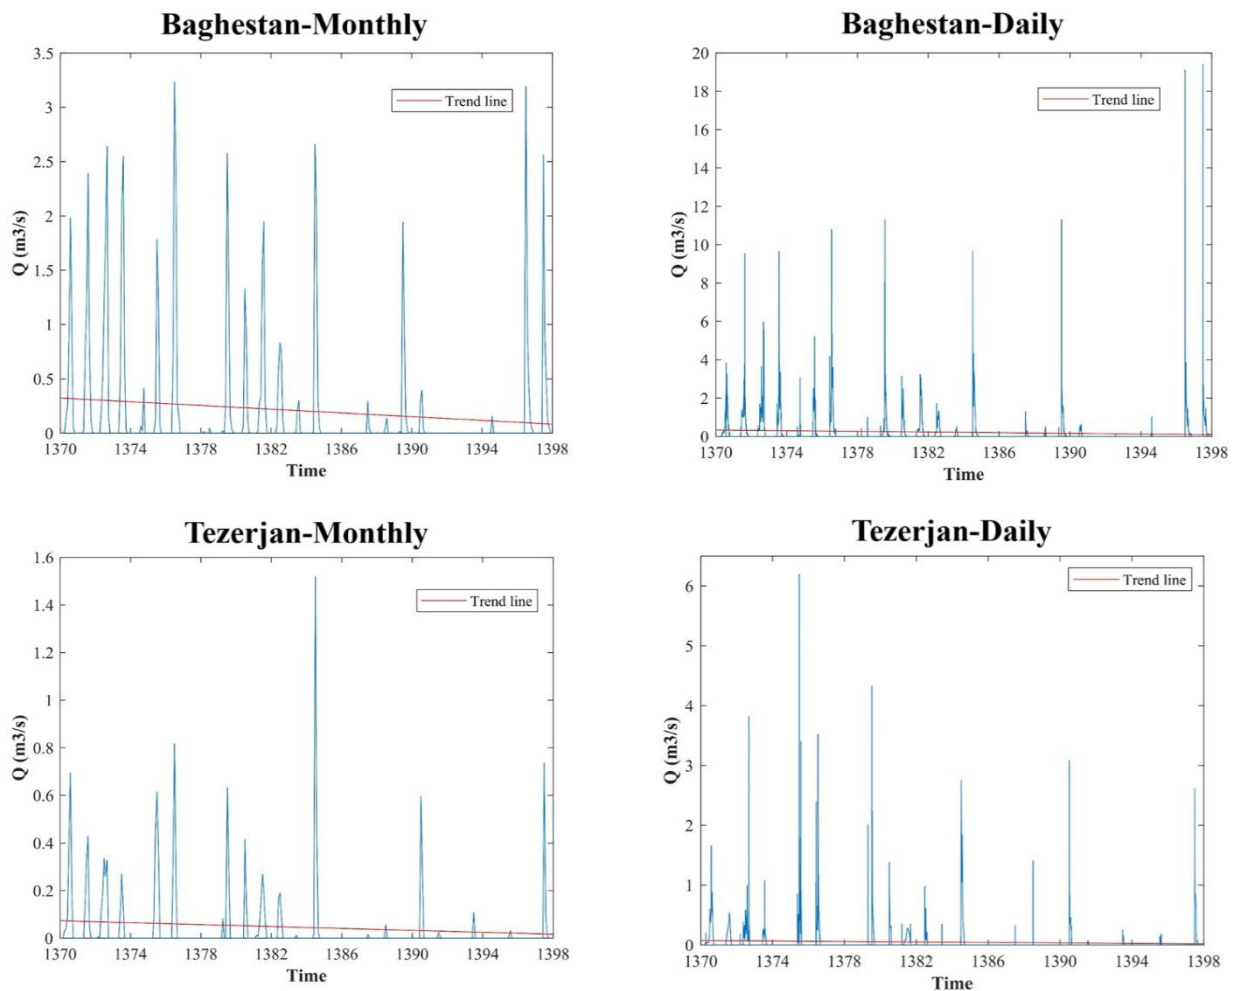


Figure 5- Daily and monthly streamflow of Baghestan and Tezerjan during the study period

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

۵.۳ پیش بینی دبی توسط الگوریتم شبکه عصبی LSTM

در این بخش به بررسی کارایی مدل LSTM در پیش بینی دبی پرداخته می شود. بدین منظور حدود ۹۰ درصد داده ها (مقادیر مربوط به سال های ۱۳۷۰ تا ۱۳۹۵) جهت آموزش و تقریباً ۱۰ درصد باقی مانده (مقادیر مربوط به سال های 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 پیش بینی دبی سه ماهه ایستگاه باغستان به عنوان نمونه در شکل ۶ نمایش داده شده است. منحنی تابع هزینه، مقدار loss در فرآیند 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 به تدریج صاف (اما همچنان رو به پایین) تا نزدیک به پایان آموزش نشان‌دهنده‌ی بهبود مداوم مدل با سرعتی تا حدودی کندتر از طول تکرارهای اولیه است. شیب صاف به سمت پایان آموزش نشان‌دهنده‌ی 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 به طور 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 به صورت mini-batch پردازش می‌شوند؛ روشی که در آن گرادینت‌ها 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. از این رو، وقوع نوساناتی مانند پرش محسوس در حوالی اپیاک ۲۰۰ و نوسانات کوچک‌تر در اپیاک‌های 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.

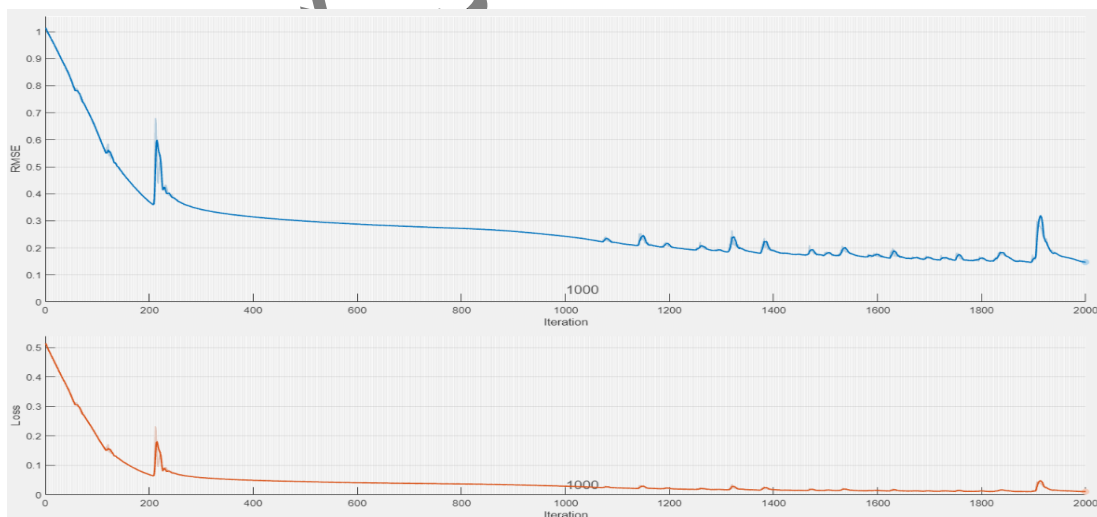


Figure 6 - Training process of LSTM model for predicting three-month streamflow at Baghestan station

شکل ۶- نمودار تکرار آموزش مدل LSTM برای پیش‌بینی دبی سه ماهه 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. به طور 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.

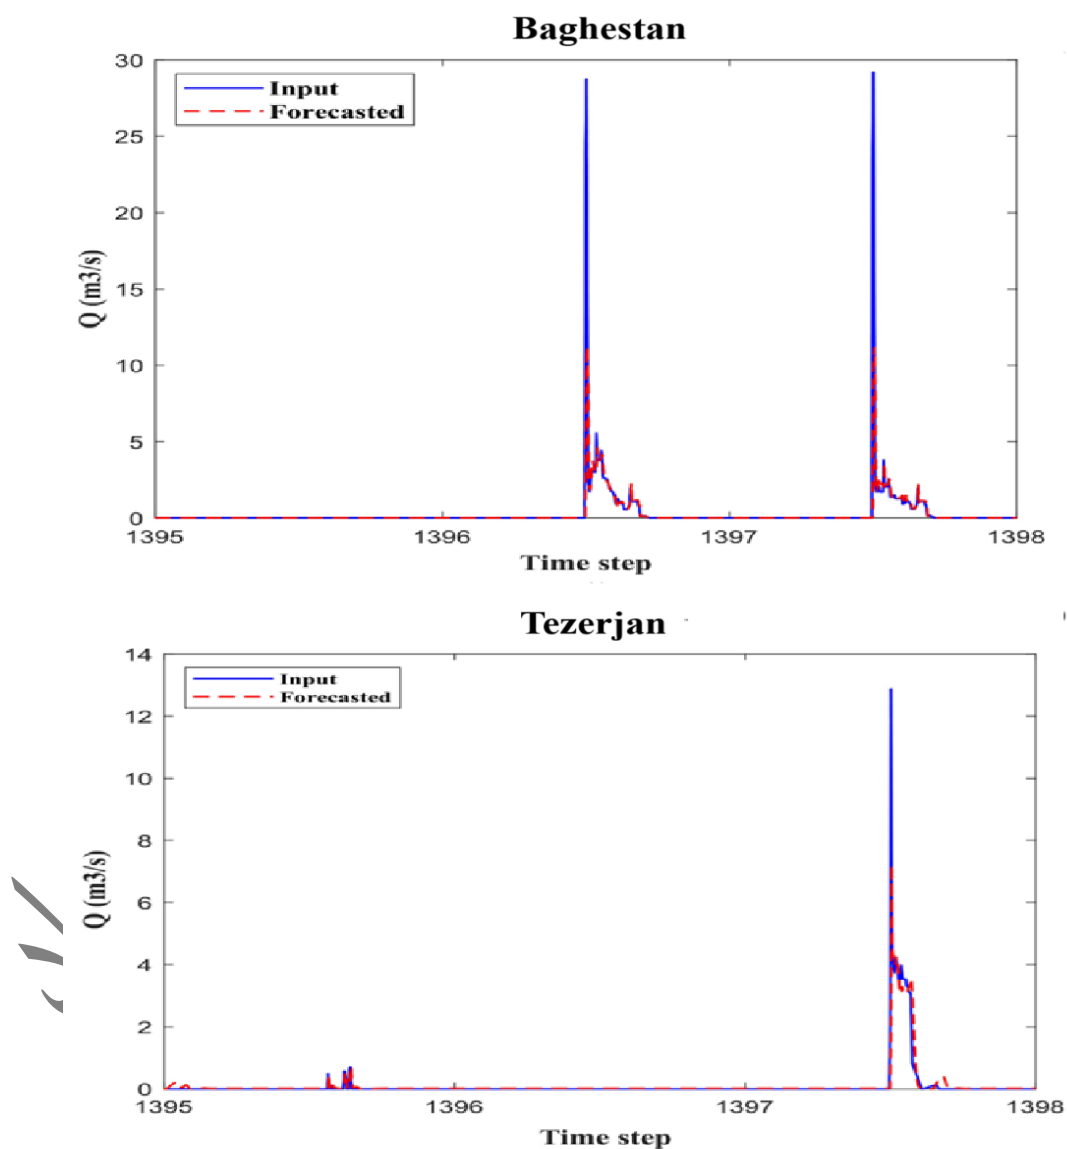


Figure 7 - Comparison of observed daily streamflow with predicted values by the LSTM at Baghestan and Tezerjan stations

شکل ۷ - نمودار مقایسه‌ی 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 کوتاه مدت، دقت مدل برای پیش‌بینی بهبود یابد. بدین منظور در این بخش، توانایی مدل LSTM برای پیش‌بینی دبی سه ماهه 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 مورد نظر محاسبه گردید. سپس میانگین متحرک دبی سه ماهه 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 سه ماهه ایستگاه باغستان و طزرجان در دوره ارزیابی و مقادیر پیش‌بینی شده توسط الگوریتم LSTM مقایسه شده‌اند. نتایج نشان می‌دهد مدل LSTM در مقیاس سه ماهه عملکرد نسبتاً بهتری را در مقایسه با پیش‌بینی روزانه ارائه کرده است. در مقیاس سه ماهه، 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 قابل قبول می‌باشد و هشدار وقوع سیلاب برای هر دو ایستگاه قابل صدور بوده است.

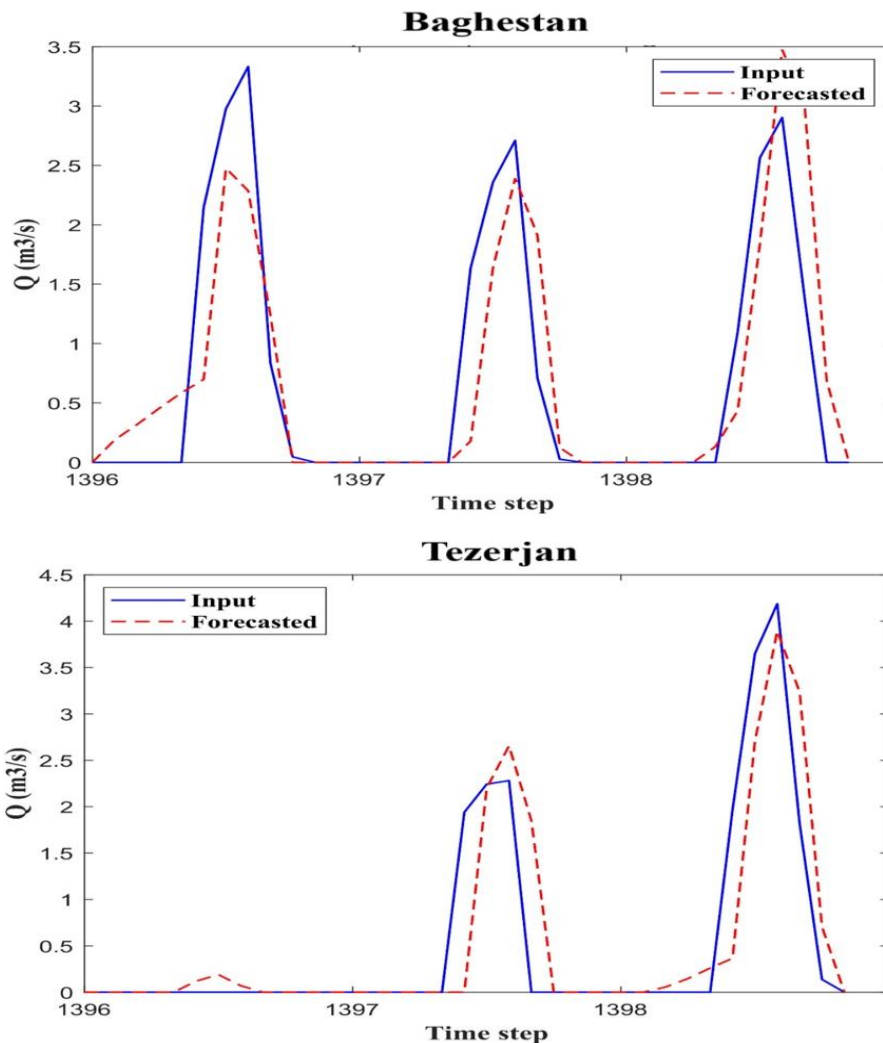


Figure 8 - Comparison of observed 3-month streamflow with predicted values by the LSTM at Baghestan and Tezergan stations

شکل ۸ - نمودار مقایسه‌ی 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 مورد نظر به دفعات متعدد تکرار شد تا با وزن‌های اولیه‌ی تصادفی در هر تکرار، مدل از نقاط شروع متفاوتی آموزش را آغاز کند. نتایج نشان داد که اختلاف بین مقادیر خطا در تکرارهای مختلف قابل توجه نیست و همه‌ی 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 به صورت پایدار به نقطه‌ی همگرایی سراسری نزدیک شده است. نکته دیگر که باید مد نظر قرار گیرد این است که اگر منحنی تابع هزینه (Loss) با گذشت اپیاک‌ها به صورت یکنواخت نزولی و در انتها صاف و پایدار باشد، یعنی مدل به نقطه‌ی همگرایی واقعی رسیده است.

۶.۳ مقایسه کارایی مدل‌های LSTM مورد استفاده

به منظور بررسی دقیق‌تر کارایی مدل‌های LSTM به کار رفته در تحقیق در پیش‌بینی دبی ایستگاه‌های مورد مطالعه، 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 طزرگان محاسبه گردید. نتایج به دست آمده در جدول ۲ نمایش داده شده است. نتایج نشان می‌دهد در ایستگاه باغستان، کارایی مدل در پیش‌بینی دبی متوسط سه ماهه از دبی متوسط روزانه بیشتر است. در حالیکه در ایستگاه طزرگان، عملکرد مدل در مقیاس روزانه از کارایی مدل در مقیاس سه ماهه، بالاتر بوده است. در مجموع در بین مدل‌های به کار رفته، مدل LSTM مورد استفاده برای پیش‌بینی دبی روزانه ایستگاه طزرگان با ضریب تعیین برابر ۰/۷۸ و RMSE برابر ۰/۴۳ از عملکرد بالاتری برخوردار است.

جدول ۱- مقادیر R^2 و RMSE بین مقادیر دبی مشاهداتی و دبی پیش‌بینی شده توسط مدل LSTM در ایستگاه‌های

باغستان و طزرگان

RMSE	R^2	Time scale	Station
1.27	0.51	Daily	Baghestan
0.43	0.78	Daily	Tezergan
0.56	0.74	Monthly	Baghestan
0.62	0.70	Monthly	Tezergan

۴ بحث و نتیجه گیری

در مناطقی که مستعد وقوع سیلاب می‌باشند، پیش‌بینی زمان وقوع سیلاب با استفاده از داده‌های گذشته کمک کننده و حیاتی است. چون ممکن است از احتمال خسارات مالی و حتی جانی جلوگیری به عمل آورد. در سال‌های اخیر، مدل‌های یادگیری ماشین به عنوان جایگزین‌های مناسب برای تحلیل سری‌های زمانی برجسته شده‌اند. الگوریتم‌های یادگیری ماشین و الگوریتم‌های شبکه عصبی چارچوبی انعطاف پذیر 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 به صورت 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 ایده‌ی شبکه‌ی بازگشتی نیز از رفتار انسان‌ها در زمینه‌ی تصمیم‌گیری نشأت گرفته است. چرا که 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 کوتاه مدت طولانی مدت با موفقیت چشم‌گیر در پیش‌بینی سری‌های زمانی به کار گرفته شده‌اند. LSTM حالت سلولی و مخفی دارد که می‌تواند اثرات حافظه کوتاه مدت را در بر بگیرد. بنابراین، انتخاب خوبی برای مدل‌سازی سری‌های زمانی رواناب است.



زیرا می‌تواند طیفی از تأخیرهای وابسته به زمان، مانند چرخه‌های فصلی و تغییرپذیری طبیعی سالانه (طولانی مدت، ماه‌ها تا سال‌ها) و پاسخ فوری بارندگی-رواناب (کوتاه مدت، از دقیقه تا ساعت) را در نظر بگیرد (Zhang et al., 2022).

در این پژوهش که در حوزه‌ی 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) سه ماهه 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 قابل توجه می‌شود. اما نتایج مطالعه نشان داد با توجه به اینکه مدل LSTM علاوه بر حافظه کوتاه مدت معمول، دارای حافظه بلند مدت نیز می‌باشد، 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 به طور کلی بر اساس مقادیر پیش‌بینی شده، وقوع سیلاب قابل پیش‌بینی است. نتایج به دست آمده از محاسبه ضریب تعیین (R^2) 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 0.78 و RMSE برابر 0.43 دارای بالاترین کارایی می‌باشد.

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. به عنوان مثال فنگ و همکارانش بعد از بررسی‌های انجام گرفته بر روی منطقه‌ای از کشور چین، دقت الگوریتم LSTM در پیش‌بینی سیل را $93/75$ 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 نشان دهنده‌ی این موضوع بود که الگوریتم LSTM نسبت به سایر الگوریتم‌های شبکه‌ی عصبی، برای مدل‌سازی بارش و رواناب مناسب‌تر می‌باشد و می‌تواند پیش‌بینی سیل را به درستی انجام دهد.

کارایی الگوریتم LSTM در پژوهش Li et al. (2024) نیز به وضوح به چشم می‌آید. در این تحقیق که در ناحیه‌ی چین هوا در چین انجام شده است، بر اثربخشی به کارگیری مدل‌های LSTM آموزش دیده 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 حوزه‌ی رودخانه‌ی 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 می‌باشد و کارایی قابل قبول 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 کارایی مدل LSTM در پیش‌بینی سری زمانی سه ماهه از روزانه بالاتر بوده است. در ایستگاه طزرجان، عملکرد مدل در مقیاس روزانه از سری زمانی سه ماهه بالاتر است.

۵. پیشنهادات

این پژوهش در منطقه‌ای خشک مورد بررسی قرار گرفته است. می‌توان در مناطق با میزان بارندگی بیشتر نیز کارایی 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 می‌گردد از سایر روش‌های جهانی برای پیش‌بینی سیل نیز استفاده گردد و نتایج بدست آمده از مدل‌های مختلف با مدل LSTM مقایسه گردد.

مراجع

- Abdi N, Moradzadeh Fard M, Ahmadzadeh H, Khoddam M (2021) A Hybrid model for portfolio optimization based on stock price forecasting with LSTM recurrent neural network using cardinality constraints and multi criteria decision making methods (Case Study of Tehran Stock Exchange). *Journal of Financial Management Perspective* 11(36):119-143 (In Persian)
- Atmaja BT, Sasou A, Akag, M (2022) Survey on bimodal speech emotion recognition from acoustic and linguistic information fusion. *Speech Communication* 140(11-28)
- Beylich, M, Haberlandt U, Reinstorf F (2021) Daily vs. hourly simulation for estimating future flood peaks in mesoscale catchments. *Hydrology Research* 52(4):821–833
- Cui Z, Zhou Y, Guo S, Wang J, Xu C-Y (2022) Effective improvement of multi-step-ahead flood forecasting accuracy through encoder-decoder with an exogenous input structure. *Journal of Hydrology* 609:127764
- 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 et al (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. <https://doi.org/10.2166/nh.2021.082>.
- Filonchik 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
- Giovanettoni 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 Diederik P, Jimmy Lei B (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. doi: 10.17226/12573.
- Pir Ali et al (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. <https://doi.org/10.1007/s10462-025-11198-7>
- 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 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)

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

Nastaran Vahdati Nasab¹, Mohammad Amin 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 can significantly prevent financial and human casualties from floods. 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 of the Baghestan and Tezerjan hydrometric stations in the Fakhrabad area of Yazd province during the period 1398-1370 have been used. The precipitation values of the top ten stations in the study period showed a mild decreasing trend. 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 at the Baghestan and Tezerjan stations on a daily and three-month time scale was calculated. The results showed that among the models used, the LSTM model used for predicting the daily streamflow 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.

¹ M.Sc. Graduate of Watershed Science and Engineering, Faculty of Natural Resources and Desert Studies, Yazd University, Yazd, Iran.

^{2*} Assistant Professor, Faculty of Natural Resources and Desert Studies, Yazd University, Yazd, Iran. Email: amin.asadi@yazd.ac.ir