

Comparing the Performance of Deep Learning, Polynomial Neural Network and HEC-HMS Models in Predicting Daily Runoff

S. Mostafaei¹, V. Moosavi^{2*}, and R. Berndtsson³

Abstract

Estimating runoff caused by excess rainfall at the watershed scale is necessary for precise design of water structures, comprehensive watershed, and flood management. In this research, we evaluated deep learning methods in comparison to polynomial neural networks and HEC-HMS models in three watersheds, i.e., Bar-Erieh, Kasilian, and Latian. For this purpose, daily runoff was simulated using a long short-term memory (LSTM) deep learning model and compared to multi-layer perceptron (MLP) as the most common artificial intelligence model, group method of data handling (GMDH) and HEC-HMS as a physically based model for robust neural network modeling. The results showed that the R^2 ranged from 0.872 to 0.986, RMSE from 0.086 m³/s to 2.22 m³/s, and NRMSE from 18.9 to 66.0%. The results indicate that the performance of the MLP model is mediocre with an average NRMSE of 51.2%, the performance of the GMDH model is good with an average NRMSE of 44.6%, and the LSTM model is very good with an average NRMSE of 26.8%. Considering the high computational cost of LSTM compared to the GMDH model, it can be recommended that the GMDH model should be used if the user does not expect very high accuracy and precision, and if higher accuracy is required, the user may need to accept a high computational cost and the LSTM model. Also, if the process and scenario-based modeling are the focus, the HEC-HMS model is preferred.

Keywords: Artificial Intelligence, Flood, Modeling, Rainfall-Runoff Process.

Received: November 19, 2022

Accepted: June 7, 2023

مقایسه عملکرد مدل‌های یادگیری عمیق با شبکه عصبی چند جمله‌ای و مدل HEC-HMS در پیش‌بینی رواناب روزانه

سحر مصطفایی^۱، وحید موسوی^{۲*} و رونی برندسون^۳

چکیده

تخمین رواناب ناشی از بارش مازاد حوضه آبخیز می‌تواند کمک شایانی به طراحی دقیق سازه‌های آبی، مدیریت جامع حوضه‌های آبخیز و مدیریت سیلاب نماید. لذا در این پژوهش سعی شده است قدرت برآورد روش‌های یادگیری عمیق در مقایسه با شبکه عصبی چند جمله‌ای و مدل HEC-HMS در حوضه‌های آبخیز بار اریه، کسلیان و لتیان مورد ارزیابی قرار گیرد. برای این منظور رواناب روزانه با استفاده از مدل LSTM شبیه‌سازی و نتایج آن با نتایج مدل‌های MLP به عنوان رایج‌ترین مدل هوش مصنوعی، مدل GMDH به عنوان یکی از قوی‌ترین شبکه‌های عصبی مصنوعی و مدل HEC-HMS به عنوان یک مدل فیزیک‌پایه مقایسه شد. نتایج پژوهش نشان داد ضریب R^2 در مدل‌های مختلف بازه‌ای بین ۰/۸۷۱۵ تا ۰/۹۸۶۴، ضریب RMSE بازه‌ای از ۰/۰۸۶ تا ۲/۲۱۶۵ و ضریب NRMSE بازه‌ای بین ۱۸/۸۸ تا ۶۵/۹۶ را در حوضه‌های آبخیز مختلف به خود اختصاص داده است. نتایج حاکی از عملکرد متوسط مدل MLP با متوسط NRMSE معادل ۵۱/۱۷ درصد، عملکرد مناسب مدل GMDH با متوسط NRMSE معادل ۴۴/۶ درصد و عملکرد بسیار خوب مدل LSTM با متوسط NRMSE معادل ۲۶/۸ درصد است. با توجه به هزینه محاسباتی بالای LSTM در مقایسه با مدل GMDH می‌توان توصیه کرد که اگر دقت و صحت خیلی بالا از طرف کاربر مورد انتظار نیست از مدل GMDH استفاده شود و در صورت نیاز به صحت بالاتر کاربر می‌تواند هزینه محاسباتی بالای روش LSTM را پذیرفته و از این مدل استفاده نماید. همچنین، اگر فرآیند محاسباتی و مدل‌سازی سناریو محور مد نظر است مدل HEC-HMS ارجحیت دارد.

کلمات کلیدی: سیلاب، فرآیند بارش-رواناب، مدل‌سازی، هوش مصنوعی.

تاریخ دریافت مقاله: ۱۴۰۱/۸/۲۸

تاریخ پذیرش مقاله: ۱۴۰۲/۳/۱۷

1- M.Sc. Student, Department of Watershed Management Engineering, Faculty of Natural Resources, Tarbiat Modares University (TMU), Tehran, Iran.

2- Assistant Professor, Department of Watershed Management Engineering, Faculty of Natural Resources, Tarbiat Modares University (TMU), Tehran, Iran. Email: v.moosavi@modares.ac.ir

3- Assistant director at Centre for Advanced Middle Eastern Studies (CMES) and Professor at Division of Water Resources Engineering, Lund University, Lund, Sweden.

*- Corresponding Author

Doi: [10.22034/IWRR.2023.172260](https://doi.org/10.22034/IWRR.2023.172260)

۱- دانشجوی کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، تهران، ایران.
۲- استادیار گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، تهران، ایران.

۳- استاد مرکز مطالعات پیشرفته خاورمیانه و بخش مهندسی منابع آب، دانشگاه لوند، لوند، سوئد.

*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان زمستان ۱۴۰۲ امکان‌پذیر است.



مدل‌های هیدرولوژیکی در حوضه آبخیزی در کشور چین نمودند. نتایج نشان داد که با افزایش زمان پیش‌بینی، قدرت پیش‌بینی شبکه‌های عصبی کاهش می‌یابد و تا بازه زمانی ۱۱ روز می‌تواند به خوبی رواناب را پیش‌بینی نماید. (Patel and Joshi, 2017) از شبکه عصبی مصنوعی برای پیش‌بینی رواناب در حوضه آبخیز Sabarmati در کشور هند استفاده کردند. نتایج آن‌ها نشان داد که مدل شبکه عصبی خطای بسیار پایینی داشته و برای شبیه‌سازی بارش-رواناب در این حوضه مناسب است. روش دیگر برآورد رواناب در سطح حوضه آبخیز استفاده از یادگیری عمیق است که به دلیل داشتن ساختار سلسه مراتبی، قابلیت بالایی در دسته‌بندی داده‌ها و نیز تخمین روابط بین پدیده‌ها دارند. همچنین ساختارهای عمیق می‌توانند ارائه جامع‌تری از توابع در مقایسه با ساختارهای سطحی فراهم کنند (Mirabedini, 2018). مدل‌های یادگیری عمیق در پردازش داده‌های حجیم عملکرد بهتری دارند (Schmidhuber, 2015). مطالعات متعددی از این روش در راستای برآورد رواناب استفاده کرده‌اند که به نمونه‌هایی از آن در ادامه اشاره می‌شود. Xiang et al. (2020) به منظور پیش‌بینی رواناب رودخانه Wapsipinicon آمریکا در بازه‌های زمانی ۲۰۱۵ تا ۲۰۱۶ از مدل یادگیری عمیق LSTM^۶ و بر اساس مدل توالی استفاده کردند. مدل LSTM-seq2seq نشان داد که از قدرت پیش‌بینی کافی برخوردار است و می‌تواند برای بهبود دقت در پیش‌بینی کوتاه‌مدت سیل استفاده شود. (Baek et al., 2020) در یک تحقیق اقدام به پیش‌بینی سطح و کیفیت آب با استفاده از تلفیق دو مدل یادگیری عمیق CNN^۷ و LSTM^۸ در کشور کره جنوبی در بازه زمانی ۲۰۱۶ تا ۲۰۱۷ نمودند. نتایج ایشان نشان داد که روش تلفیقی توانایی بالایی در مدل‌سازی سطح و کیفیت آب دارد. (Han et al., 2021) در بازه زمانی ۲۰۱۵ تا ۲۰۱۹ اقدام به مدل‌سازی جریان رودخانه‌ای در ایالت کالیفرنیا آمریکا با استفاده از مدل یادگیری عمیق LSTM با ساختار دنباله به دنباله نمودند. نتایج این مطالعه نشان داد که روش مذکور نسبت به مدل LSTM ساده از عملکرد بالاتری برخوردار است. (Bai et al., 2021) رواناب روزانه را در آبخیزی در کشور اسلوانی بر اساس مدل LSTM آبشاری یا C-LSTM با در نظر گرفتن متغیرهای مختلف پیش‌بینی نمودند. نتایج نشان داد که روش C-LSTM نسبت به روش‌های LSTM و شبکه عصبی مصنوعی دارای خروجی بهتری است. (Li et al., 2021) در بازه زمانی ۲۰۰۶ تا ۲۰۱۳ اقدام به مدل‌سازی فرآیند بارش-رواناب در آبخیزی در کشور آلمان نمودند. در این مطالعه مدل بارش-رواناب با الگوریتم‌های یادگیری عمیق CNN و LSTM برای محاسبه رواناب بر اساس نقشه‌های رادار دو بعدی تهیه شد. نتایج نشان داد که CNN-LSTM برای تخمین رواناب و

پیش‌بینی و تخمین میزان رواناب^۱ در مقیاس زمانی روزانه و مقیاس مکانی حوضه آبخیز از مهم‌ترین عوامل مؤثر بر مدیریت یکپارچه سیستم‌های آبی بوده و از پیچیدگی زیاد و روابط غیر خطی خاصی برخوردار می‌باشد (Seo et al., 2018). مدل‌سازی^۲ و تخمین رواناب در مقیاس‌های زمانی کوتاه مدت و بلند مدت می‌تواند نقش غیرقابل انکاری در مطالعات مهندسی آب ایفا نماید (Kuok et al., 2010). به طور کلی هدف اصلی از مدل‌سازی فرآیند بارش-رواناب در حوضه آبخیز، تعیین روش یا راه حل دقیق و مطمئن برای پیش‌بینی یا تخمین رواناب است. اما وجود مشکلات متعدد از جمله تأثیر نفوذ، دما، تبخیر و همچنین غیرخطی و پیچیده بودن این فرآیندها بحث مدل‌سازی را با مشکل مواجه ساخته است. داشتن درک درست از حوضه آبخیز و فرآیندهای حاکم بر آن می‌تواند کمک شایانی به مدل‌سازی هرچه بهتر فرآیند بارش-رواناب داشته باشد (Ahmadi, 2019). در این راستا به طور کلی دو روش مدل‌سازی مبتنی بر دانش و مدل‌سازی مبتنی بر داده برای مدل‌سازی فرآیند بارش-رواناب ارائه شده است. روش‌های دانش‌محور به عنوان رویکردهای فیزیک‌پایه نیز شناخته می‌شوند (Solomatine and Ostfeld, 2008). از جمله پرکاربردترین روش‌های داده‌محور می‌توان به مدل‌های هوش مصنوعی اشاره نمود. در سال‌های اخیر روش‌های هوش مصنوعی به‌علت دقت و سرعت زیاد مورد توجه قرار گرفته‌اند. مدل‌های شبکه عصبی مصنوعی با کم‌ترین ورودی، رابطه بین متغیرها و ساختار آن‌ها را بررسی می‌کنند و در پیش‌بینی و دسته‌بندی اطلاعات توانایی بالقوه‌ای دارند و با ایجاد یک مدل غیرخطی اثر متقابل بین متغیرها را نشان می‌دهند (Biglerian et al., 2009). روش‌های MLP^۳ و GMDH^۴ به‌عنوان مرسوم‌ترین و پرستفاده‌ترین روش‌های هوش مصنوعی در زمینه‌های مختلف مدل‌سازی کاربرد دارند (Lorrai and Sechi, 1995). مطالعات متعددی در این باره صورت گرفته است. به عنوان نمونه Riad et al. (2004) در مطالعه‌ای از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) برای مدل‌سازی فرآیند بارش-رواناب در حوضه آبخیزی با اقلیم نیمه خشک در مراکش استفاده نمودند و نتایج نشان داد که روش شبکه عصبی مصنوعی به منظور پیش‌بینی رواناب از مدل رگرسیون کلاسیک مناسب‌تر است. (Kuok et al., 2007) اقدام به پیش‌بینی رواناب روزانه با استفاده از روش شبکه عصبی مصنوعی در حوضه Sungai Bedup کشور اندونزی نمودند. نتایج نشان داد که شبکه‌های عصبی مصنوعی قادر به شبیه‌سازی رواناب روزانه با دقت زیاد (R=0.97) و در بازه چند روزه هستند. (Xu et al., 2009)، اقدام به پیش‌بینی رواناب روزانه توسط شبکه عصبی مصنوعی (ANN)^۵ و

هشدار سیل برای مدیریت حوضه آبخیز عملکرد مناسبی دارد. Ahmed et al. (2022) یک مدل ترکیبی یادگیری عمیق جدید برای پیش‌بینی رواناب و جریان رودخانه با استفاده از شبکه‌های عصبی CNN و شبکه حافظه کوتاه‌مدت دو جهته (BiLSTM) و بهینه‌سازی کلونی مورچه‌ها^۹ (ACO) با رویکرد تجزیه دو فازی ارائه کردند. بازه‌های پیش‌بینی ۷، ۱۴ و ۲۸ روزه در نظر گرفته شد. ایشان در پژوهش خود از سه مجموعه داده (گرفته شده از ماهواره، شاخص‌های حالت آب و هوا، و مشاهدات هواشناسی در ایستگاه‌های زمینی) برای بهبود قابلیت پیش‌بینی مدل ترکیبی^{۱۰} CVMD-CBiLSTM، در ۱۹ ایستگاه اندازه‌گیری مختلف در حوضه آبخیز رودخانه موری استرالیا استفاده کردند. نتایج نشان داد که استفاده از مدل جدید یادگیری عمیق ترکیبی با انتخاب ویژگی‌ها توسط ACO می‌تواند به طور قابل توجهی دقت سطح آب پیش‌بینی شده رودخانه را بهبود بخشد.

همانطور که مرور منابع نشان داد، استفاده از مدل‌های یادگیری عمیق و هوش مصنوعی کاربرد گسترده‌ای پیدا کرده است. در این پژوهش سعی شده است عملکرد مدل یادگیری عمیق در پیش‌بینی رواناب روزانه با روش GMDH به عنوان یکی از قوی‌ترین و مدل MLP به عنوان یکی از رایج‌ترین مدل‌های شبکه عصبی مصنوعی مقایسه شود. علت این مقایسه تفاوت در میزان هزینه محاسباتی این سه روش است. مدل MLP روشی ساده‌تر و با هزینه محاسباتی به مراتب پایین‌تر نسبت به دو مدل دیگر است و روش یادگیری عمیق روشی پیچیده‌تر با هزینه محاسباتی به مراتب بالاتر می‌باشد. روش GMDH نیز حالتی بینابینی دارد. لذا بررسی عملکرد این روش‌ها می‌تواند در انتخاب مدل مناسب‌تر برای پیش‌بینی رواناب در مقیاس روزانه از اهمیت بالایی برخوردار باشد. در این مطالعه عملکرد این مدل‌ها برای امکان تعمیم بیشتر نتایج در سه حوضه آبخیز بار-اریه، لتیان و کسلیان مورد ارزیابی قرار گرفته است.

۲- موارد و روش‌ها

۲-۱- منطقه مورد مطالعه و داده‌ها

این تحقیق در سه حوضه آبخیز کسلیان، سد لتیان و بار-اریه انجام شده است. حوضه آبخیز کسلیان، به عنوان یکی از حوضه‌های مورد مطالعه بخشی از رودخانه‌ی تالار با مختصات طول جغرافیایی ۵۳ درجه و ۱۸ دقیقه تا ۵۳ درجه و ۳۰ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۵۸ دقیقه تا ۳۶ درجه و ۷ دقیقه شمالی در رشته کوه البرز مرکزی در استان مازندران قرار گرفته است. حوضه آبخیز معرف

کسلیان با مساحت ۶۸ کیلومتر مربع به سه زیرآبخیز ولیک چال، سنگده و سربند تقسیم شده و خروجی حوضه در محل ایستگاه ولیک بن با ارتفاع ۱۱۲۵ متر است. بارندگی متوسط آن ۷۹۱ میلی‌متر و متوسط دما ۱۳ درجه سانتی‌گراد است. حوضه آبخیز سد لتیان با مساحت تقریبی ۴۳۶ کیلومترمربع در استان تهران قرار گرفته است. این حوضه آبخیز شامل زیرآبخیز گرمابدر، میگون، آهار، امامه و رودک می‌باشد. این آبخیز کوهستانی بوده و دارای تغییرات ارتفاعی ۱۷۰۰ تا ۴۲۱۲ متر با افزایش ارتفاع به سمت شمال و دارای ارتفاع میانگین ۲۸۳۰ متر و شیب میانگین ۴۵/۶٪ است (Sedighi et al., 2015). حوزه آبخیز بار-اریه نیشابور به مساحت ۱۱۳/۸۸ کیلومتر مربع در جنوب غربی سلسله جبال بینالود قرار گرفته است. متوسط ارتفاع حوزه آبخیز بار ۲۲۲۶ متر و در محل ایستگاه هیدرومتری ۱۵۶۰ متر است. محیط این حوزه آبخیز ۵۴ کیلومتر و شیب متوسط آن ۱۱/۹ درصد محاسبه شده است. آب و هوای منطقه نیمه خشک و متوسط درجه حرارت آن ۵/۴ درجه سانتی‌گراد و میزان متوسط بارندگی سالانه آن ۳۳۰/۴ میلی‌متر است. متوسط دبی آن ۰/۶۶ متر مکعب بر ثانیه است (Jaefari et al., 2013). شکل ۱ مناطق مورد مطالعه در این تحقیق را نشان می‌دهد. در این مطالعه از داده‌های سری زمانی بارش، متوسط دما و تبخیر، رطوبت هوا و سرعت باد، بارش یک و دو روز قبل، دبی یک و دو روز، شاخص بارش پیشین^{۱۱} (API) و شاخص دبی پیشین^{۱۲} (ADI) استفاده شد. مدل‌سازی در این بخش برای یک دوره ۲۰ ساله صورت گرفت که از این دوره آماری ۷۰ درصد داده‌ها برای آموزش مدل‌ها و ۳۰ درصد برای آزمون مورد استفاده قرار گرفت. با توجه به اینکه هدف مقایسه عملکرد چند مدل با یکدیگر می‌باشد، داده‌های مورد استفاده در هر دو بخش آموزش و آزمون برای همه مدل‌ها یکسان در نظر گرفته شد تا امکان مقایسه وجود داشته باشد.

۲-۲- روش تحقیق

داده‌های مورد نیاز شامل داده‌های دبی از شرکت ملی منابع آب ایران و شرکت‌های سهامی آب منطقه‌ای استان‌ها (خراسان رضوی، تهران و مازندران) و نیز داده‌های اقلیمی از سازمان هواشناسی ایران دریافت، مرتب‌سازی و نواقص آماری احتمالی رفع شد. به منظور تعیین تأخیرهای مناسب زمانی در داده‌ها، از آزمون خود همبستگی و خود همبستگی جزئی استفاده شد. در بحث مربوط به سری زمانی، بین مشاهدات براساس زمان وابستگی وجود دارد. خود همبستگی^{۱۳} به معنی همبستگی سریالی^{۱۴} یا وابستگی بین مقدار دنباله‌ای برحسب زمان است.

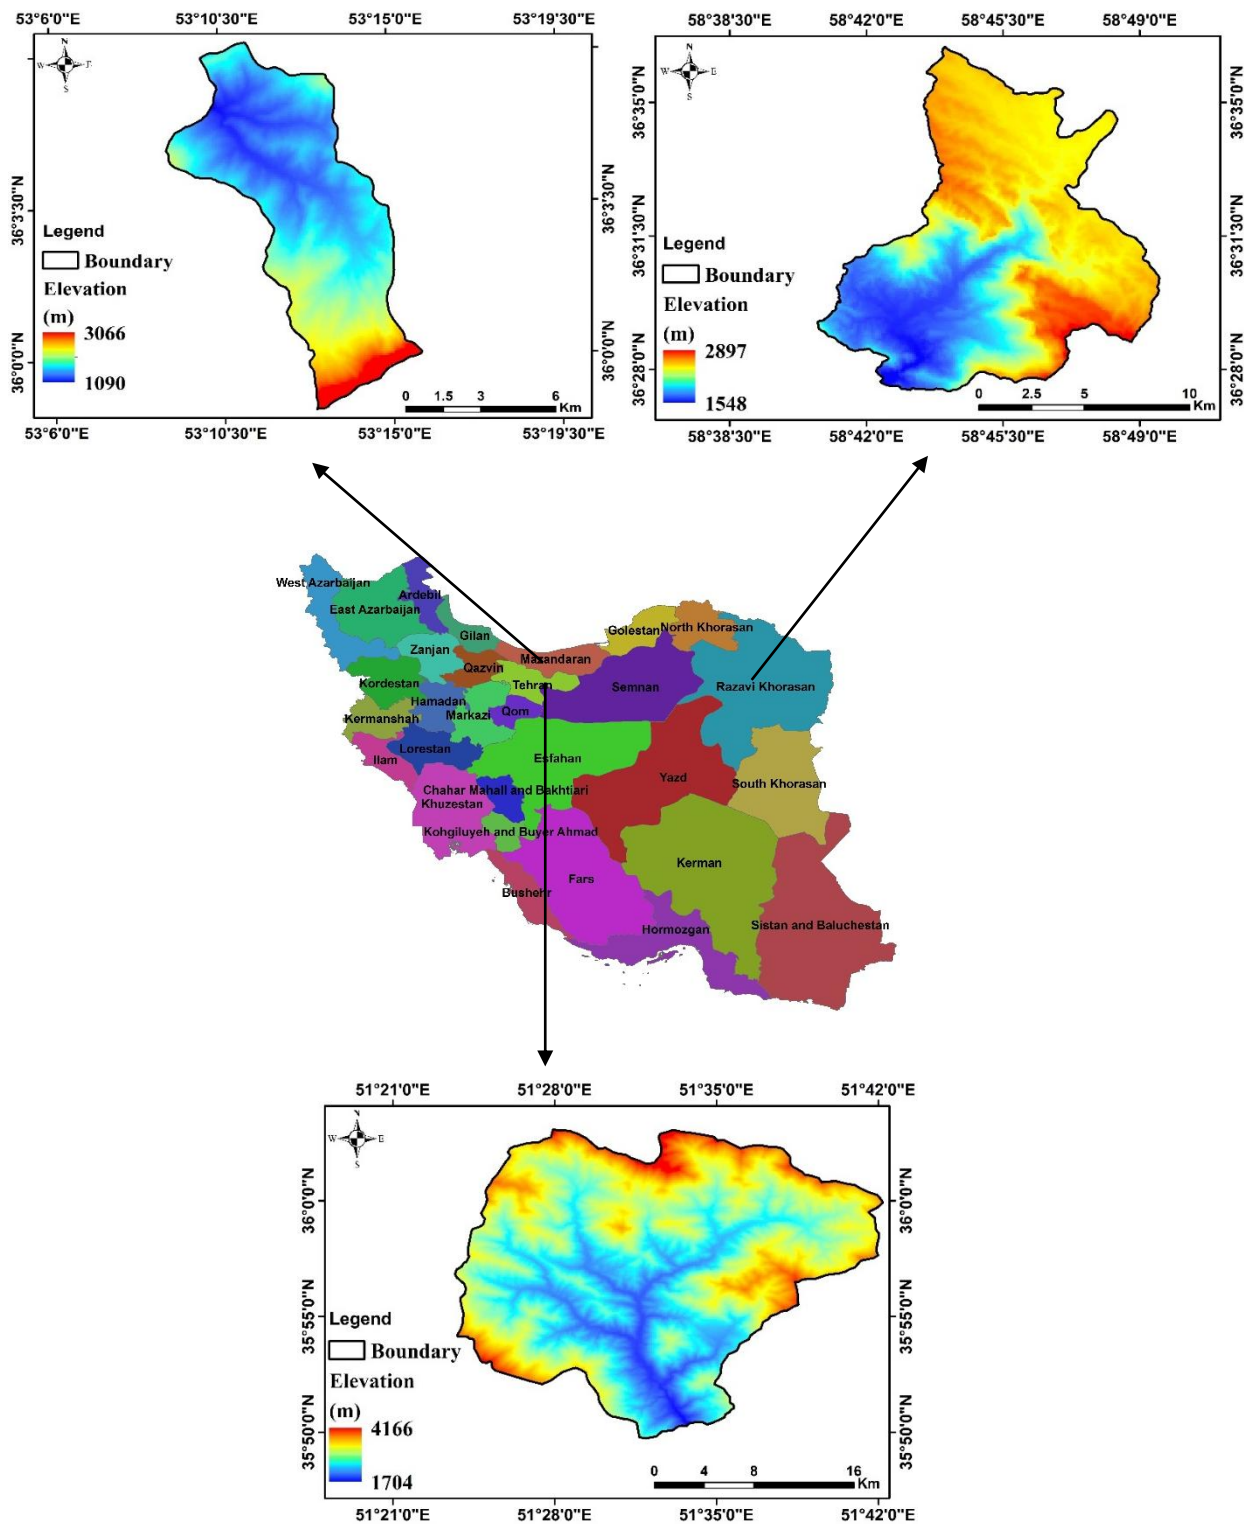


Fig. 1- Location of the studied watersheds
 شکل ۱- موقعیت مکانی حوضه‌های آبخیز مورد مطالعه

شکل ۲ ساختار یک بلاک LSTM را نشان می‌دهد. همانطور که در این شکل دیده می‌شود این ساختار دارای سه دروازه ورودی، خروجی و فراموشی می‌باشد. خروجی این بلاک به ورودی سه دروازه ذکر شده به صورت بازگشتی وارد می‌شود. همانند شبکه عصبی MLP شبکه دارای توابع فعال‌سازی است که در این مطالعه براساس مرور منابع تابع تانژانت هذلولی برای گیت‌های ورودی و خروجی و تابع سیگموئید برای گیت فراموشی در نظر گرفته شد. مواردی که در شکل روابطی که به صورت نقطه چین نشان داده شده‌اند روابط وزن دار و سایرین روابط غیر وزن دار هستند.

همانطور که پیشتر ذکر شد، عملکرد مدل یادگیری عمیق با دو مدل متداول‌تر یعنی شبکه عصبی مصنوعی MLP و GMDH مقایسه خواهد شد. ساختار شبکه عصبی مصنوعی با دریافت بردار ورودی، بردار خروجی را برای هر ورودی تولید می‌کند (Rohani et al., 2015). شبکه عصبی مصنوعی MLP از جمله مدل‌های جعبه سیاه است که در سال‌های اخیر به دلیل توانمندی‌هایی که در زمینه مدل‌سازی روابط پیچیده هیدرولوژیکی از جمله فرآیند بارش-رواناب دارد به‌وفور مورد استفاده قرار می‌گیرد و با دریافت مجموعه‌ای از داده‌های اولیه از طریق لایه ورودی و پردازش روی آنها در لایه پنهان به یکسری اطلاعات جدید دست می‌یابد و در نهایت نتایج حاصل را در لایه خروجی ارائه می‌کند (Zorati et al., 2009; Dehghani et al., 2016; Razavi zadeh and Darghahian, 2018). این شبکه‌ها از سه لایه تشکیل شده‌اند که شامل لایه ورودی، مخفی و خروجی است.

در این پژوهش، عملکرد مدل یادگیری عمیق LSTM با دو مدل رایج GMDH و MLP در سه حوضه آبخیز مورد مقایسه قرار گرفت. تمامی بخش‌های تحقیق با کدنویسی در زبان برنامه‌نویسی متلب صورت پذیرفت. LSTM یک شبکه عصبی مصنوعی است که در حوضه‌های موضوعی هوش مصنوعی و یادگیری عمیق به کار گرفته می‌شود. LSTM به دسته شبکه‌های عصبی بازگشتی (RNN) تعلق دارد. RNNها نمایش‌هایی از جدیدترین ورودی‌ها را با استفاده از بازخورد ذخیره می‌کنند، به همین دلیل است که آنها را شبکه‌های عصبی مکرر می‌نامند. ایده LSTM این است که وضعیت حافظه را حتی پس از مدت طولانی به دلیل وجود سلول حافظه حفظ می‌کند. حالت حافظه شامل دروازه‌هایی است که جریان داده‌ها را در حافظه تنظیم می‌کنند. وضعیت حافظه پیش اثبات در تمام سلول‌های LSTM وجود دارد تا مقادیر اطلاعات حالت‌های قبلی را براساس اهمیت واحدهای ورودی تغییر دهد. LSTM استاندارد از سه لایه تشکیل شده است، لایه ورودی اولین لایه در مدل است. لایه دوم لایه بازگشتی در LSTM است. لایه خروجی به سه گیت سلول (دریچه‌های ورودی، خروجی و فراموشی) و در نهایت لایه خروجی متصل می‌شود (Drewil et al., 2022). بر خلاف شبکه عصبی پیشخور، LSTM دارای اتصالات بازخوردی است. LSTM مانند شبکه عصبی بازگشتی، نه تنها به پردازش داده‌های مفرد مثل تصاویر می‌پردازد، بلکه این نوع شبکه می‌تواند داده‌های متوالی مثل داده‌های هیدرولوژیکی اقلیمی را نیز پردازش کند.




Fig. 2- Structure of a LSTM block
شکل ۲- ساختار یک بلاک LSTM

در هر لایه تعدادی نرون در نظر گرفته می‌شود که به وسیله اتصالاتی به نرون‌های لایه‌های مجاور وصل می‌شوند. نرون‌های لایه اول، اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه، به نرون‌های لایه مخفی منتقل می‌کنند.

GMDH نوعی از شبکه‌های عصبی مصنوعی به‌شمار می‌رود. آنچه الگوریتم GMDH را به‌عنوان یک روش هیوریستیک (اکتشافی، فراکاوشی) معرفی می‌کند، ساختن مدل‌هایی برای سیستم‌های پیچیده از نوع رگرسیون با درجات زیاد است که دارای مزایایی نسبت به مدل‌سازی کلاسیک است (Moosavi et al., 2017; Godarzi and Godarzi, 2020; Moosavi et al., 2021). در این مدل، ارتباط بین ورودی‌ها و خروجی‌ها به‌صورت غیرخطی می‌تواند به‌صورت سری چند جمله‌ای‌های ولترا بیان شود (رابطه ۱).

$$y(t) = \int_0^t h_1(\tau)x(t-\tau)d\tau + \iint_0^t h_2(\tau_1\tau_2)x(t-\tau_1)x(t-\tau_2)d\tau_1d\tau_2 + \iiint_0^t h_3(\tau_1\tau_2\tau_3)x(t-\tau_1)x(t-\tau_2)x(t-\tau_3)d\tau_1d\tau_2d\tau_3 + \dots \quad (1)$$

که در رابطه ۱: $h_n(\tau_1, \dots, \tau_n)$ به‌عنوان کرنل درجه n ام ولترا شناخته می‌شود. فرم گسسته معادله بالا، می‌تواند به‌صورت چند جمله‌ای‌های Kolmogorov-Gabor بیان شود (رابطه ۲-۳). در رابطه ۳-۲: x ورودی‌ها، N تعداد ورودی‌ها و a نشان‌دهنده ضرایب است (Ivakhnenko, 1971).

$$y = a_0 + \sum_i^N a_i x_i + \sum_i^N \sum_j^N a_{ij} x_i x_j + \sum_i^N \sum_j^N \sum_k^N a_{ijk} x_i x_j x_k + \dots \quad (2)$$

در ادامه به منظور مقایسه عملکرد مدل‌های مذکور با یک مدل فیزیکی پایه، مدل HEC-HMS مورد استفاده قرار گرفت. این مدل یک مدل مفهومی نیمه توزیعی است که می‌تواند برای پیش‌بینی جریان مورد استفاده قرار گیرد. این فرآیند معمولاً شامل شبیه‌سازی شرایط گذشته و آینده می‌شود. پیش‌بینی با انتخاب زمان پیش‌بینی شروع می‌شود. زمان پیش‌بینی معمولاً آخرین زمان موجود برای مشاهدات هواشناسی از بارش، دما و سایر متغیرها را نشان می‌دهد. نتایج محاسبه شده بین زمان شروع و زمان پیش‌بینی، می‌تواند به‌عنوان دوره "Look back" نامیده شود. زمانی که مشاهداتی از شرایط فعلی حوضه در دسترس هستند، می‌توان آن‌ها را با نتایج محاسبه شده از دوره بررسی گذشته

مقایسه کرد تا تنظیمات کالیبراسیونی انجام شود تا عملکرد مدل را بهبود بخشد. در این مطالعه الگوریتم SMA loss برای تلفات رطوبت خاک استفاده شد. الگوریتم SMA loss توانایی مدل‌سازی پیوسته را برای دوره‌های زمانی طولانی دارد (HEC, 2008). این الگوریتم از طریق یک سری لایه ذخیره‌سازی (Bennett, 1998) حوضه را نمایش می‌دهد. هنگامی که بارش روی می‌دهد، اولین لایه پر شده ذخیره برگابی را نشان می‌دهد. لایه دوم ذخیره‌سازی، ذخیره چالابی بوده و سومین لایه ذخیره پروفیل خاک است. آب مازاد بر این سه ذخیره، به‌عنوان رواناب در نظر گرفته می‌شود. به منظور مدل‌سازی رواناب با استفاده از مدل HEC-HMS دقیقاً همان دوره واسنجی و اعتبارسنجی که برای مدل‌های هوش مصنوعی در نظر گرفته شده بود مورد استفاده قرار گرفت تا نتایج قابل مقایسه باشد. به منظور مدل‌سازی رواناب نقشه‌های کاربری اراضی و نیز گروه‌های هیدرولوژیکی خاک به منظور محاسبه CN برای هر سه حوضه تهیه شدند.

به‌منظور ارزیابی و مقایسه عملکرد مدل‌های داده‌محور در تخمین رواناب روزانه از چند معیار آماری از جمله ضریب تبیین (R^2)^{۱۶}، مجذور مربعات خطای نرمال شده^{۱۷} استفاده شد که معادلات آن‌ها در در رابطه‌های ۳ تا ۵ ارائه شده است. لازم به ذکر است که به جهت وجود سه منطقه مورد مطالعه و طبعاً تفاوت در دامنه داده‌های مورد استفاده آماره مجذور مربعات خطای نرمال شده مبنای مقایسه نهایی عملکرد مدل‌ها قرار گرفت.

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - o^-)(e_i - e^-)}{\sqrt{\sum_{i=1}^n (O_i - o^-)^2 \sum_{i=1}^n (e_i - e^-)^2}} \right)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - e_i)^2}{n}} \quad (4)$$

$$NRMSE = \frac{RMSE}{\text{Mean of Observed Data}} \quad (5)$$

۳- نتایج و تحلیل نتایج

شکل ۳ نتایج تحلیل خود همبستگی و خود همبستگی جزئی را نشان می‌دهد. این نتایج نشان داد که داده‌های بارش و دبی تا یک گام زمانی دارای خود همبستگی هستند. لذا در مدل بارش-رواناب ارائه شده یک روز تاخیر زمانی برای این داده‌ها در نظر گرفته شد و داده‌های $P(t-1)$ یعنی بارش یک روز قبل و $D(t-1)$ یعنی دبی یک روز قبل علاوه بر داده‌های بارش و دبی زمان t به مدل وارد شد. علاوه بر این داده‌ها در این مطالعه از داده‌های سری زمانی متوسط دما و تبخیر، رطوبت هوا

و سرعت باد، شاخص بارش پیشین (API)^{۱۸} و شاخص دبی پیشین (ADI)^{۱۹} نیز به عنوان ورودی استفاده شد. شکل ۴ نتایج R^2 ، RMSE و NRMSE در حوضه بار-اریه را برای مدل‌های (الف) MLP، (ب) GMDH و (پ) LSTM نشان می‌دهد. همانطور که این شکل نشان می‌دهد، در حوضه آبخیز بار-اریه در مدل‌های MLP، GMDH و LSTM به ترتیب R^2 برابر با ۰/۸۷۱، ۰/۸۸۱ و ۰/۹۸۰ و RMSE برابر با ۰/۱۷۵، ۰/۱۶۸ و ۰/۰۸۶ و NRMSE برابر با ۰/۵۵، ۰/۵۵ و ۰/۹۷ و ۳۰/۹۷ درصد بوده است. اما در حوضه کسلیان (شکل ۵) در مدل‌های MLP، GMDH و LSTM به ترتیب R^2 برابر با ۰/۹۰۴۶، ۰/۹۱۷۲ و ۰/۹۶۰۴ و RMSE برابر با ۰/۱۵۸۱، ۰/۱۷۰۴۱ و ۰/۱۱۴۳ و NRMSE برابر با ۵۱/۹۱، ۴۸/۱۶۷ و ۳۴/۸۲ درصد بوده است. نتایج ارزیابی شاخص‌های R^2 ، RMSE و NRMSE در حوضه لتیان (شکل ۶) در مدل‌های MLP، GMDH و LSTM به ترتیب ۰/۸۷۱۵، ۰/۹۵۶۸ و ۰/۹۸۶۴ برای R^2 و ۲/۲۱۶۵، ۱/۲۷۷۱ و ۱/۰۶۶ برای RMSE و ۳۹/۲۶، ۲۲/۶۲ و ۱۸/۸۸ درصد برای NRMSE تعیین گردید.

همانطور که در شکل‌های ۴ تا ۶ نشان داده شده است ضریب R^2 در مدل‌های مختلف بازه‌ای بین ۰/۸۷۱۵ تا ۰/۹۸۶۴ را در حوضه‌های آبخیز مورد مطالعه به خود اختصاص داده است. تغییرات ضریب RMSE نشان می‌دهد این شاخص از ۰/۰۸۶ تا ۲/۲۱۶۵ در مدل‌ها و حوضه‌های آبخیز مختلف متغیر است. همانند ضریب R^2 ضریب RMSE نیز در مدل LSTM در هر سه حوضه آبخیز نشان دهنده بهترین عملکرد است. ارزیابی شاخص NRMSE حاکی از آن است که همانند دو شاخص قبلی، این شاخص در مدل LSTM کمترین مقدار در هر سه حوضه آبخیز را دارا می‌باشد. دامنه تغییرات این شاخص از ۱۸/۸۸ تا ۶۵/۹۶ متغیر برآورد گردید. بخش I در این نمودارها سری زمانی دبی مشاهداتی و تخمینی را نشان می‌دهد. بخش‌های II و III نیز به ترتیب مقادیر خطای مدل برای هر یک از داده‌ها و نمودار جعبه‌ای را برای مقادیر تخمینی و مشاهداتی نشان می‌دهد.

بر اساس نتایج حاصله، شبیه‌سازی انجام شده در حوضه آبخیز لتیان دارای بیش‌ترین R^2 ، حوضه آبخیز بار-اریه کم‌ترین RMSE و حوضه آبخیز لتیان کم‌ترین NRMSE را دارا است. بر این اساس مدل LSTM با کم‌ترین مقدار NRMSE بهترین شبیه‌سازی را در داشته

است. نتایج نشان داد که مدل MLP در پیش‌بینی رواناب روزانه از عملکرد متوسطی برخوردار است. سادگی ساختار این مدل و پیچیدگی زیاد روابط بین متغیرها در فرآیند بارش-رواناب می‌تواند سبب این عملکرد نه چندان قوی باشد. به علاوه، این نوع شبکه دارای یک ساختار تماما متصل است یعنی همه ورودی‌ها و همه نرون‌ها در همه لایه‌ها به طور کامل به یکدیگر متصل می‌شوند که این امر موجب ایجاد تعداد بسیار زیادی رابطه و به تبع آن نیاز به بهینه‌سازی تعداد بسیار زیادی وزن است. تعیین دقیق این وزن‌ها که براساس داده‌ها تعیین می‌شود، می‌تواند با عدم قطعیت‌های بالایی مواجه شود. در صورت عدم تعیین درست این وزن‌ها، پاسخ مدل می‌تواند با خطای بالایی همراه باشد. به علاوه، تصادفی بودن وزن‌های اولیه در این نوع مدل‌ها می‌تواند مشکلاتی را به وجود بیاورد. این تصادفی بودن باعث می‌شود تا در هر بار اجرای مدل نتیجه حتی با ساختار یکسان متفاوت به دست بیاید. این امر موضوع تکرار پذیری را در این مدل‌ها با مشکلاتی مواجه می‌سازد. نتایج نشان داد که روش GMDH²⁰ دارای توانایی بالاتری در پیش‌بینی رواناب روزانه داشته است. علت بهتر بودن عملکرد مدل GMDH نسبت به مدل MLP می‌تواند به ساختار این شبکه مربوط باشد.

همانند مدل MLP، مدل GMDH نیز دارای ساختار سه لایه ورودی، پنهان یا میانی و خروجی است. اما برخلاف مدل MLP در مدل GMDH همه نرون‌ها در هر لایه به همه نرون‌ها در لایه بعدی متصل نمی‌شوند. این امر باعث کاهش یافتن تعداد اتصالات و به تبع آن کاهش تعداد وزن‌هایی که باید مقدار آن بهینه شود می‌شود. نکته دیگر مربوط به نوع تعیین نرون‌هایی است که باید به نرون‌های لایه بعد متصل شوند. در این مدل تنها نرون‌هایی از هر مدل به لایه بعد متصل میشوند که عملکرد مناسبی داشته‌اند. در واقع در این مدل یک حد آستانه تعریف می‌شود که بر اساس آن بهترین نرون‌ها برای ورود به لایه بعدی انتخاب می‌شوند. در واقع در این مدل ورودی‌ها دو به دو به نرون‌های لایه مخفی وارد می‌شوند و توسط دو جمله‌ای‌های کولموگروف-گابور با هم ترکیب می‌شوند. سپس نرون‌هایی از لایه اول مخفی که عملکرد مناسب‌تری داشته‌اند وارد لایه بعدی می‌شوند. این به‌گزینی باعث بهتر شدن دقت و صحت پیش‌بینی‌ها و تخمین‌ها در مدل GMDH می‌شود.

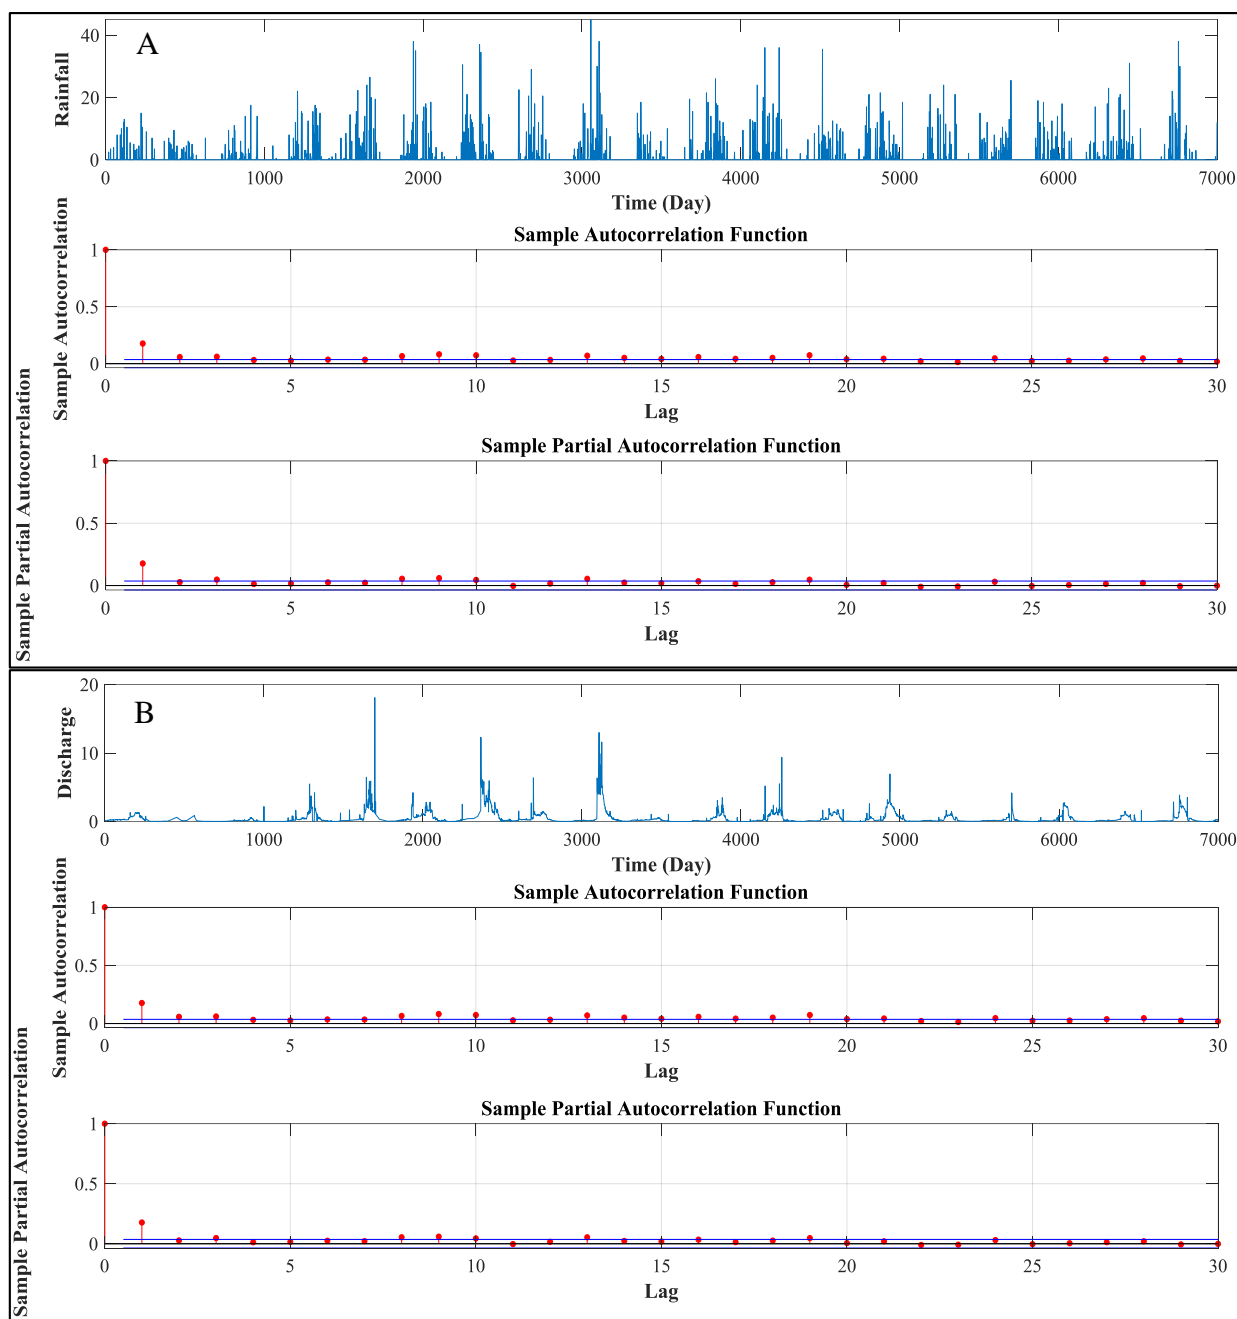


Fig. 3- Autocorrelation and partial autocorrelation results for A) rainfall and B) discharge data
 شکل ۳- نتایج آزمون خود همبستگی و خود همبستگی جزئی برای داده‌های (A) بارش و (B) دبی

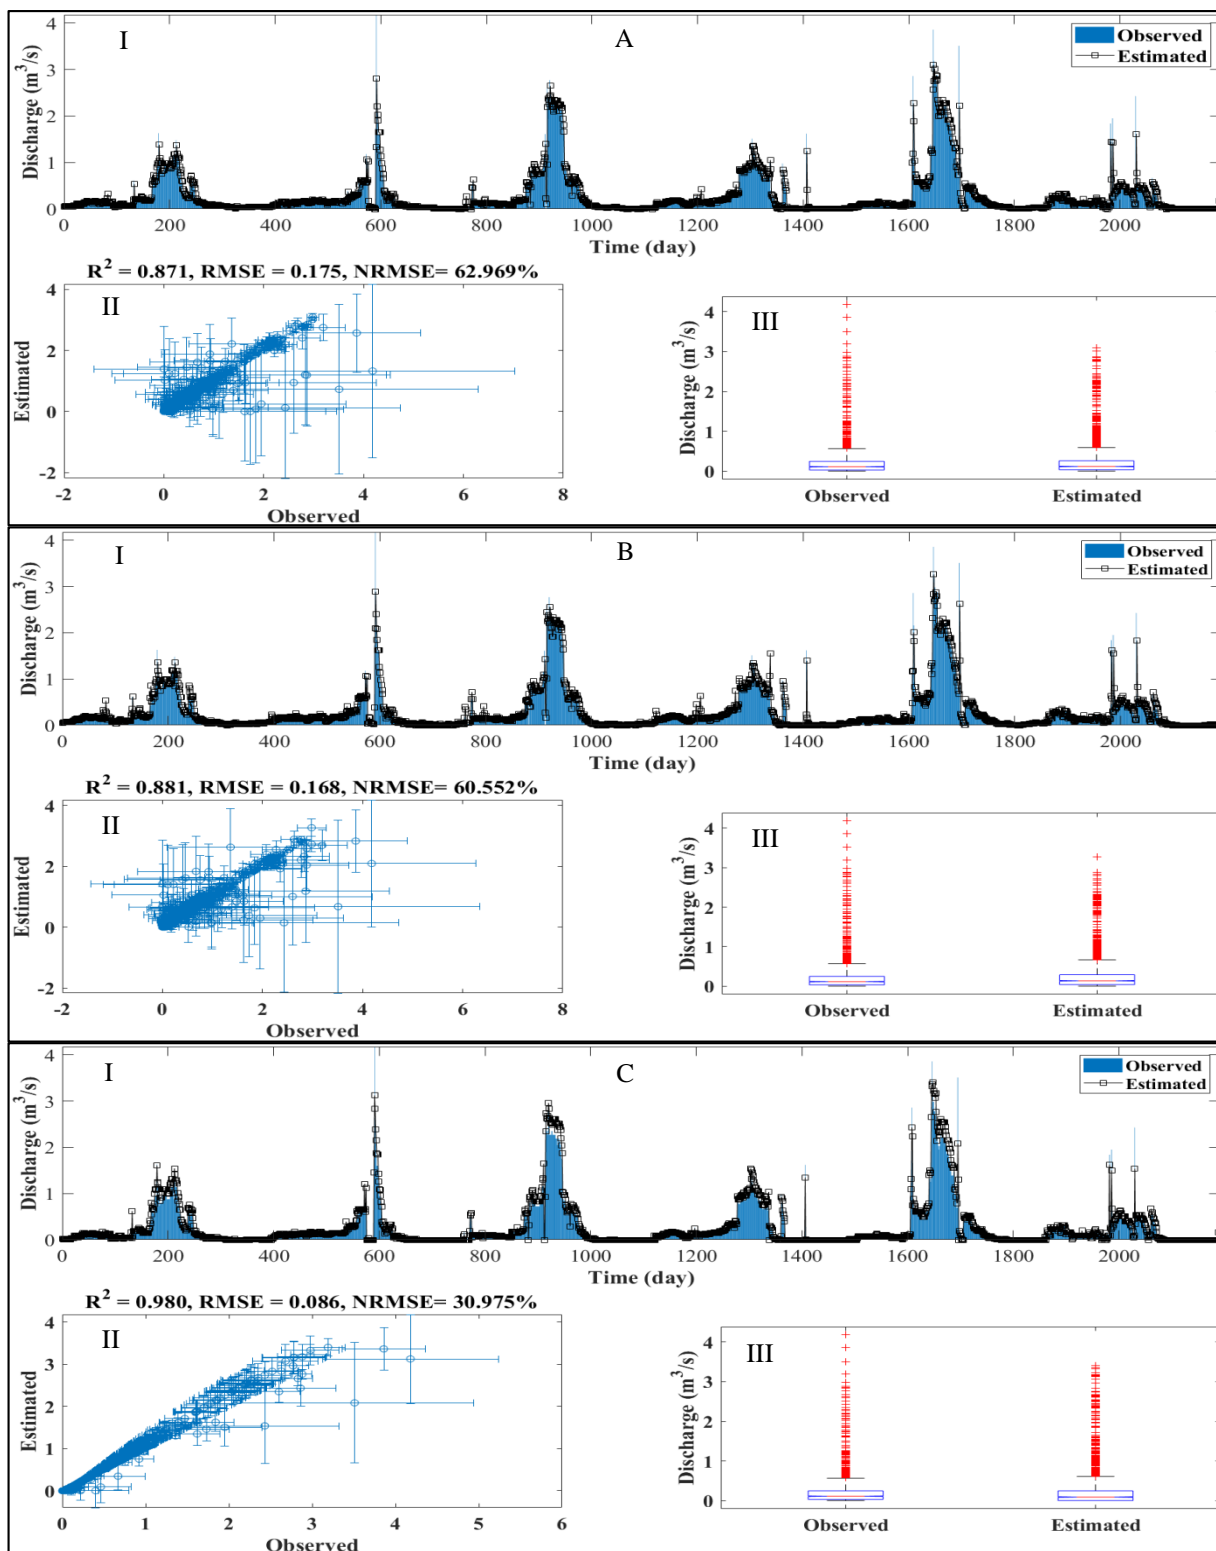


Fig. 4- Results of daily runoff prediction in Bar-Erieh watershed for A) MLP, B) GMDH, C) LSTM
 شکل ۴- نتایج پیش‌بینی رواناب روزانه در حوضه بار-اریه با مدل‌های A) MLP، B) GMDH، C) LSTM

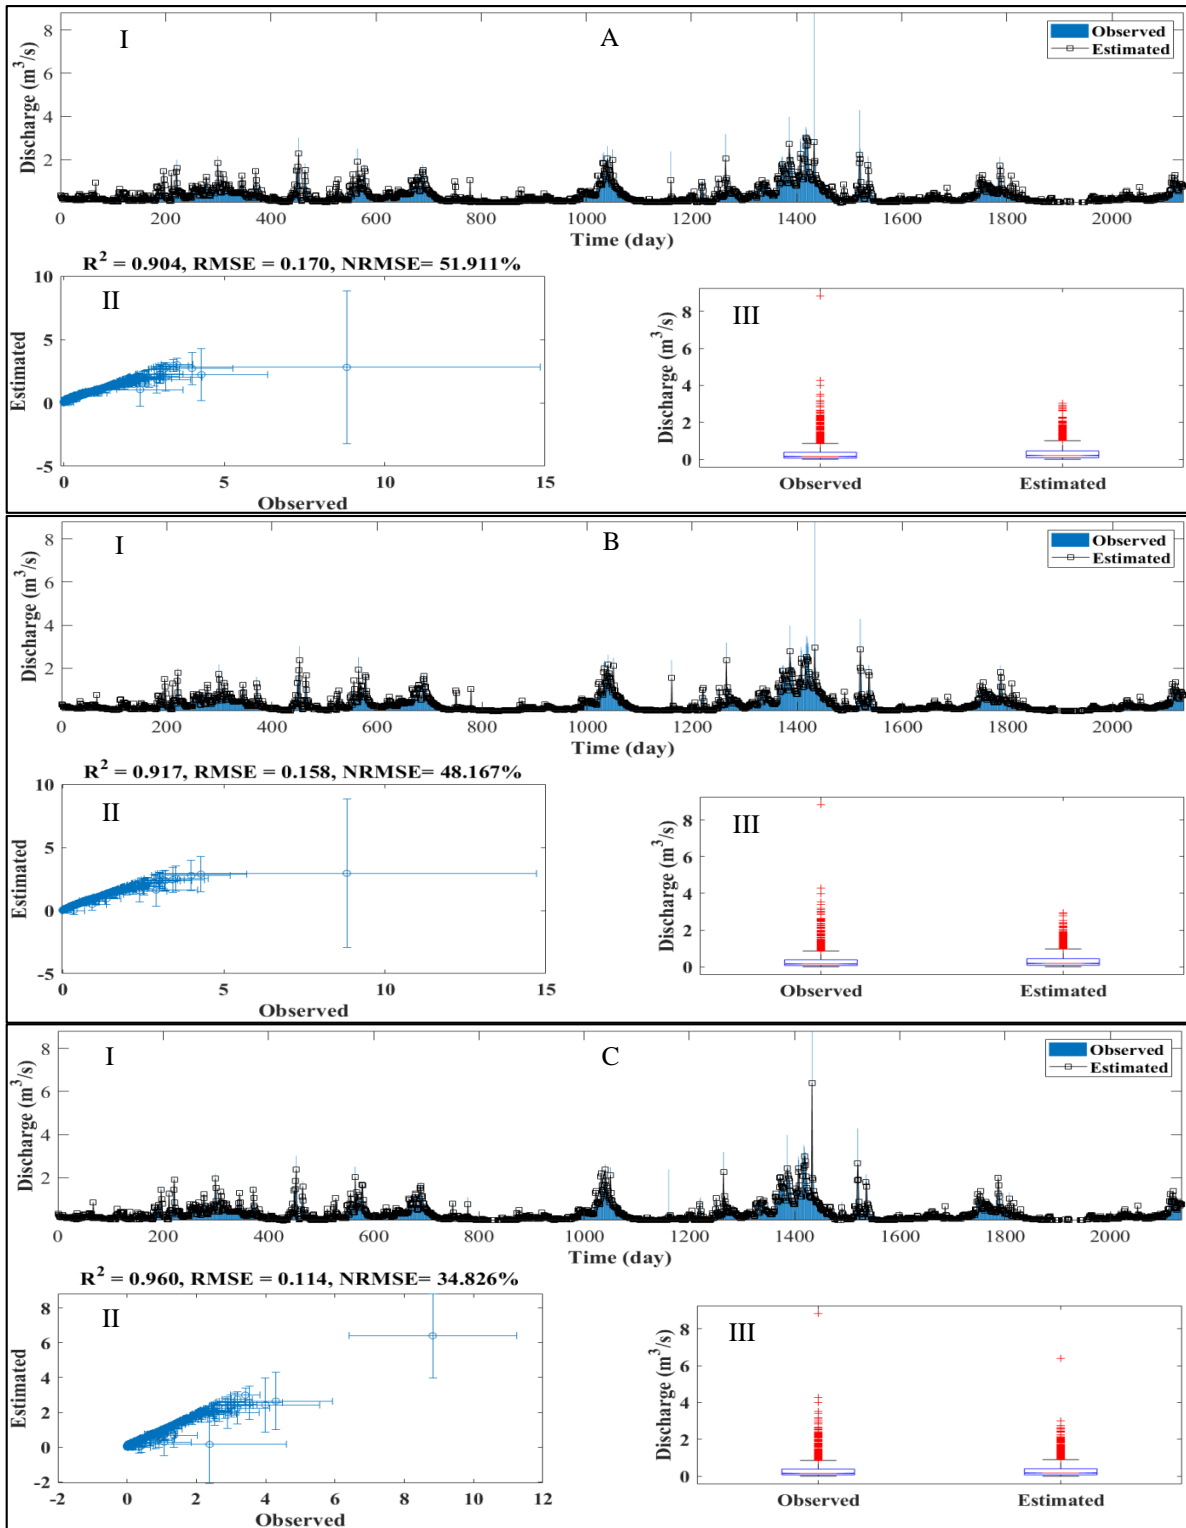


Fig. 5- Results of daily runoff prediction in Kasilian watershed for A) MLP, B) GMDH, C) LSTM
 شکل ۵- نتایج پیش‌بینی رواناب روزانه در حوضه کسلیان با مدل‌های A) MLP، B) GMDH، C) LSTM

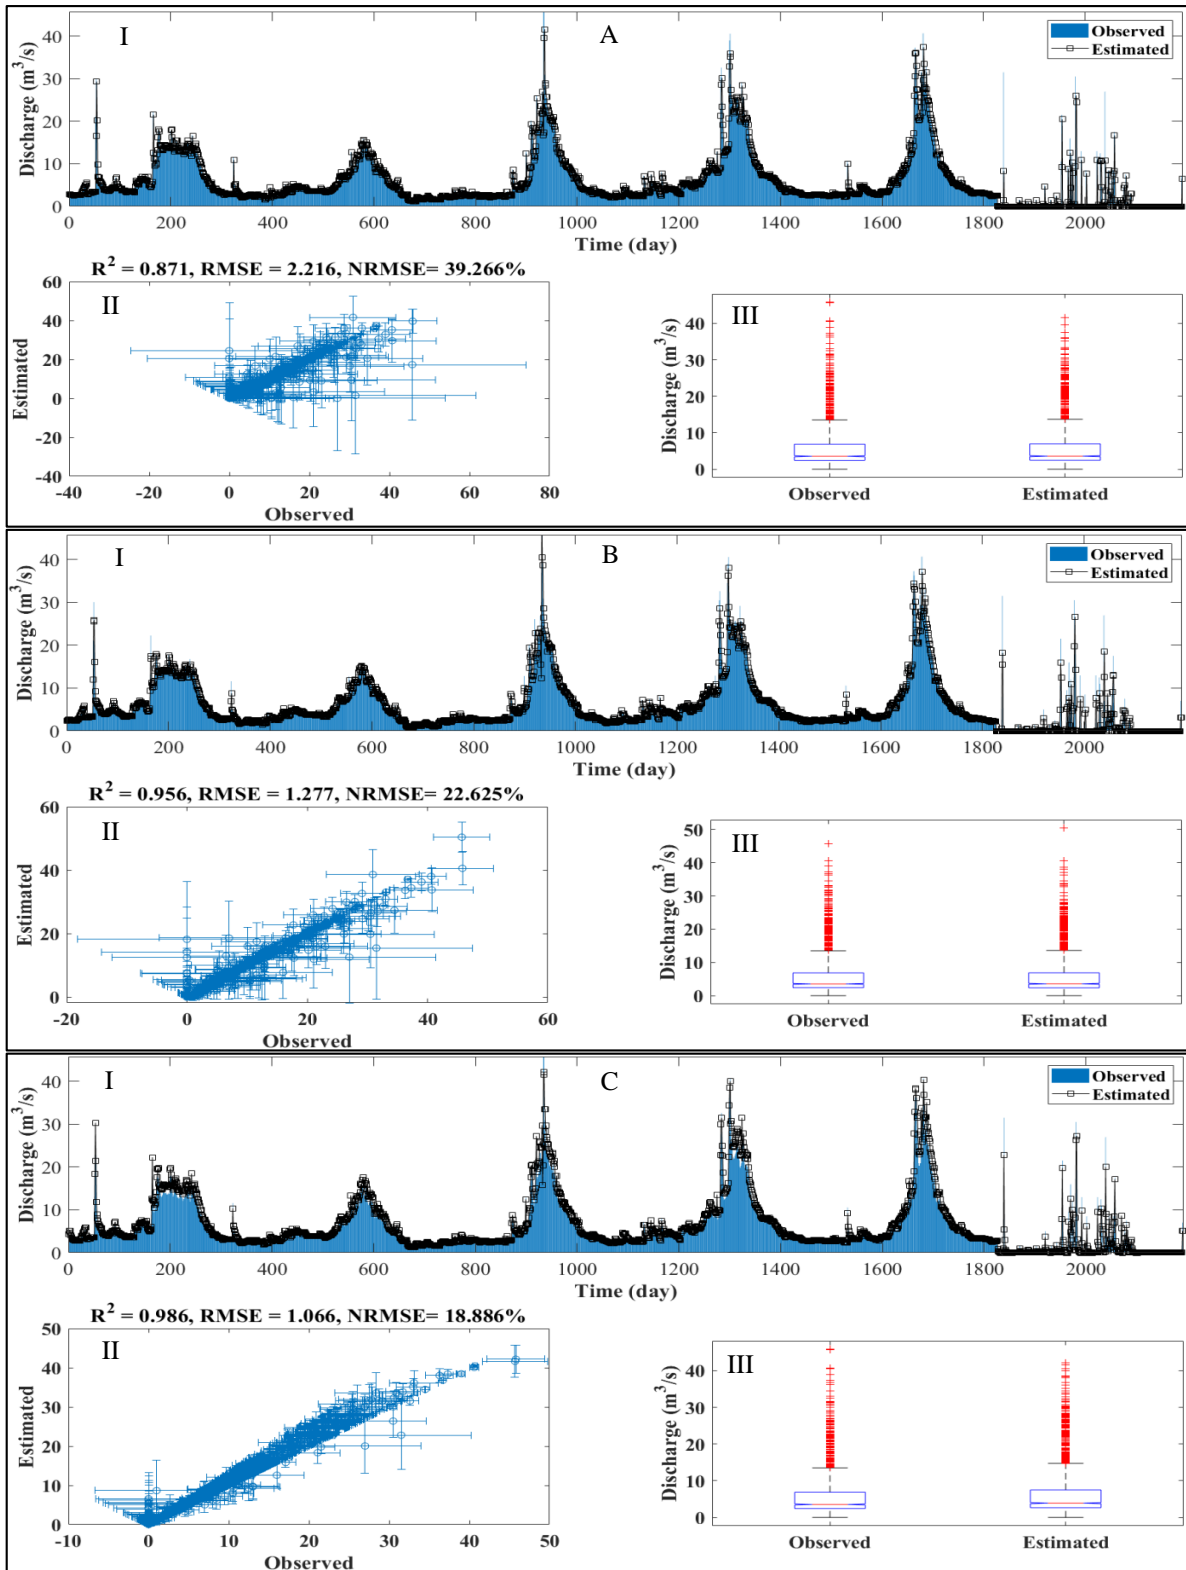


Fig. 6- Results of daily runoff prediction in Latian watershed for A) MLP, B) GMDH, C) LSTM
 شکل ۶- نتایج پیش‌بینی رواناب روزانه در حوضه لتیان با مدل‌های A) MLP، B) GMDH، C) LSTM

جدول ۱ جمع‌بندی نتایج مدل‌های ارائه شده را نشان می‌دهد. همانطور که در این جدول نشان داده شده است، همه مدل‌ها از دقت بالایی در مدل‌سازی رواناب روزانه برخوردارند ولی مدل‌های MLP و GMDH از صحت متوسطی برخوردارند و مدل LSTM از نظر صحت نیز عملکرد قابل قبولی داشته و نسبت به دو مدل دیگر توانایی بالاتری در پیش‌بینی رواناب روزانه داشته است.

نتایج نشان‌دهنده عملکرد بهتر مدل یادگیری عمیق LSTM نسبت به هر دو مدل MLP و GMDH است. علت این برتری می‌تواند به ساختار و نحوه عملکرد این مدل مربوط باشد. در ساختار مدل‌های یادگیری عمیق به جای ساختار سه لایه موجود در الگوریتم‌های قدیمی‌تر هوش مصنوعی از ساختار به مراتب عمیق‌تری برخوردار است. یکی از مزایای اساسی این روش‌ها استخراج ویژگی است. در این الگوریتم‌ها قبل از ورود مدل به فرآیند تشخیص روابط بین متغیرها، ویژگی‌های متعددی از روی داده‌ها استخراج می‌شوند که به فرآیند مدل‌سازی کمک بسیار زیادی می‌نماید. این مدل‌ها قادر هستند با حجم بسیار زیاد داده‌ها کار کرده و به خوبی روابط بین متغیرهای مستقل و وابسته را تشخیص دهد. این مدل نسبت به شبکه‌های عصبی بازگشتی نیز با اضافه کردن نوعی از پس‌انتشار خطا از توانایی بالاتری برخوردار شده است. به علاوه توانایی مدل LSTM در یادگیری از گام‌های زمانی بسیار متعدد نیز از جمله مزایای دیگر این روش می‌باشد.

به علاوه نتایج نشان داد که مدل LSTM توانایی مناسب‌تری در برآورد مقادیر حدی بالا دارد. مقادیر حدی پایین (جریان‌ات کم) تقریباً توسط همه مدل‌ها به خوبی تخمین زده شده است اما مقادیر حدی بالا با خطای بیشتری مواجه بوده است. به خصوص در روش MLP این خطا بالاتر است. بخش III نمودارهای ۴ تا ۶ نشان می‌دهد که هر سه مدل در هر سه حوضه کم تخمینی داشته‌اند. اما بخش II این نمودارها نشان می‌دهد این کم تخمینی در روش LSTM به مراتب کمتر از سایر روش‌هاست و این روش توانسته است مقادیر حدی را به خوبی تخمین بزند. نکته مهم دیگر، بهتر بودن نسبی نتایج در آبخیز

کسیلیان نسبت به دو حوضه بار-اریه و لتیان است. که در تفسیر این امر می‌توان به کمتر بودن داده‌های صفر در سری زمانی بارش و دبی اشاره کرد. وجود داده‌های صفر زیاد می‌تواند عملکرد مدل‌های داده محور را تحت تاثیر قرار دهد. در ضمن تغییرات دبی در حوضه کسیلیان منظم‌تر از دو آبخیز دیگر می‌باشد که این امر نیز به عملکرد بهتر مدل کمک می‌کند. لذا می‌توان نتیجه گرفت مدل‌های بارش-رواناب داده‌محور در مناطق با آب پایه عملکرد بهتری دارند. البته مدل LSTM نشان داد تا حدودی توانسته است رفتارهای سیستم هیدرولوژیک را فرا گیرد و حتی تغییرات ناگهانی را در سری زمانی تشخیص دهد.

در شکل ۷ نقشه‌های مدل رقومی ارتفاع، کاربری/پوشش اراضی و شماره منحنی و نیز مدل HEC-HMS ساخته شده آورده شده است. پس از ساخت مدل مراحل واسنجی مدل بر روی پارامترهای حساس مدل انجام شد. شکل ۸ نیز نتایج مدل HEC-HMS را برای سه حوضه مورد مطالعه نشان می‌دهد. نتایج نشان دهنده عملکرد مناسب این مدل در برآورد میزان رواناب روزانه است. همانطور که نشان داده می‌شود، این مدل با دقت مناسبی توانسته مقادیر دبی را برآورد نماید. از لحاظ میزان صحت و دقت نتایج این مدل نزدیکی زیادی به نتایج مدل LSTM داشته است. اما چند نکته در این خصوص حائز اهمیت است. اول اینکه مدل HEC-HMS یک مدل نیمه توزیعی بوده که می‌تواند مقادیر رواناب را در زیرحوضه‌های مختلف محاسبه نماید اما عموماً مدل‌های هوش مصنوعی به صورت یکپارچه برای کل حوضه محاسبات را انجام می‌دهند. نکته دوم اینکه مدل HEC-HMS یک مدل فرآیندمحور است که فیزیک مسأله را مورد توجه قرار می‌دهد، اما مدل‌های هوش مصنوعی جزو مدل‌های داده محور به حساب می‌آیند که عموماً فرآیند حاکم و فیزیک مسأله را به شکل کامل مورد نظر قرار نمی‌دهند و عموماً به برقراری رابطه بین متغیرهای مستقل و وابسته می‌پردازند.

Table 1- Summary results of artificial intelligence models

جدول ۱ - جمع‌بندی نتایج مدل‌های هوش مصنوعی

Basin	LSTM		GMDH		MLP	
	RMSE (m ³ .s ⁻¹)	R ²	RMSE (m ³ .s ⁻¹)	R ²	RMSE (m ³ .s ⁻¹)	R ²
Bar-Erieh	0.086	0.98	0.16	0.88	0.17	0.87
Kasilian	0.11	0.96	0.15	0.91	0.17	0.90
Latian	1.06	0.98	1.2	0.95	2.2	0.87

در نظر گرفتن فرآیند حاکم بر پدیده مورد مطالعه از جنبه‌های مختلف می‌تواند مهم باشد مثلاً این قابلیت را به کاربر می‌دهد تا بتواند به شکل کارامدی اثر تغییرات کاربری اراضی را بر رواناب بسنجد.

در کل مدل‌های فیزیک پایه مانند HEC-HMS بر اصول اساسی هیدرولوژی و ویژگی‌های فیزیکی آبخیز استوارند. این مدل‌ها به داده‌های ورودی قابل توجهی نیاز دارند، از جمله اطلاعات دقیق در مورد زمین‌شناسی، نوع خاک، کاربری زمین و هواشناسی منطقه مورد نظر که ممکن است زمان‌بر و هزینه‌بر باشد و یا این داده‌ها با دقت مناسب در دسترس نباشند. با این حال، یکی از مزیت‌های این مدل‌ها شفاف و قابل تفسیر بودن آن‌هاست، زیرا پارامترهای آن‌ها به صورت صریح تعریف شده‌اند و متخصصان مربوطه می‌توانند آن‌ها را درک کنند. اما مدل‌های مبتنی بر داده، به داده‌های ورودی کمتر نیاز دارند و با استفاده از الگوریتم‌های یادگیری ماشین، الگوهای پیچیده بین ورودی و خروجی را شناسایی می‌کنند. علاوه بر این، آموزش این مدل‌ها می‌تواند به صورت خودکار باشد که باعث کارایی بیشتر آن‌ها می‌شود. در واقع هزینه محاسباتی این مدل‌ها نسبت به مدل‌های فیزیک پایه به مراتب کمتر است و نیاز کمتری به داده دارند.

۴- خلاصه و جمع‌بندی

تخمین مقدار رواناب روزانه نقش مهمی در مطالعات مختلف منابع آب و هیدرولوژی دارد و نتایج حاصله در طراحی‌های سازه‌ها و در مدیریت منابع آبی در حوضه‌های آبخیز نقش مهمی را ایفا می‌کند. بر این اساس تخمین مقدار صحیح آن از اولویت بالایی برخوردار است. لذا در این پژوهش عملکرد مدل‌های LSTM، GMDH و MLP در برآورد رواناب دبی در حوضه‌های آبخیز بار-آریه، کسلیان و لتیان با استفاده از شاخص‌های R^2 ، RMSE و NRMSE مورد ارزیابی قرار گرفت.

نتایج نشان دهنده عملکرد بهتر مدل یادگیری عمیق LSTM نسبت به هر دو مدل GMDH و MLP می‌باشد. این امر به علت توان بالای روش یادگیری عمیق در استخراج ویژگی از داده‌ها است که باعث عملکرد بالاتر آن شده است. این نتایج با نتایج Coulibaly (2010) و Kratzert et al. (2018) در تطابق است. از نظر داده‌های ورودی نیز مطالعه حاضر با مطالعاتی چون Moosavi et al. (2021) و Tikhamarine et al. (2020) انطباق داشته است. اما نکته مهم در

اینجا میزان هزینه محاسباتی بالاتر LSTM نسبت به دو مدل دیگر است. بهینه‌کردن پارامترهای مدل یادگیری عمیق دشوارتر و اجرای هر بار مدل نسبت به دو مدل ذکر شده نیازمند زمان به مراتب بیشتری است. نیازهای سخت افزاری این مدل نیز بالاتر از دو مدل دیگر است. اجرای هر بار مدل LSTM با یک ساختار مشخص به طور متوسط بیش از ۱۰ برابر بیشتر از اجرای مدل GMDH با همان تعداد داده و با همان سیستم سخت‌افزاری زمان نیاز دارد. اما همانطور که مشاهده شد عملکرد بسیار مناسب‌تر این مدل نسبت به دو مدل دیگر می‌تواند کاربر را به پذیرفتن هزینه محاسباتی بالاتر ترغیب نماید. البته انتخاب مدل برای استفاده به هدف کاربر و میزان دقت و صحت متوقع نیز بستگی دارد. اگر میزان دقت و صحت مدل GMDH برای کاربر کافی باشد با توجه به هزینه محاسباتی پایین‌تر این مدل می‌توان استفاده از این مدل را توصیه نمود. اما اگر برای کاربر صحت مدل‌سازی بیشتری مورد نیاز باشد، استفاده از مدل LSTM در اولویت خواهد بود. پژوهش حاضر از نظر هیدرولوژی دارای اهمیت بالایی است. توانایی پیش‌بینی دبی روزانه در مدیریت منابع آب از اهمیت بالایی برخوردار است. این پیش‌بینی می‌تواند به تخمین حجم منابع آب سطحی و نیز وقایع حدی مانند سیل کمک شایانی نماید. همانطور که در نتایج نشان داده شد، مدل LSTM توانایی خوبی برای مدل‌سازی رواناب روزانه داشته است. این پژوهش نشان داد که مدل یادگیری عمیق می‌تواند به خوبی برای پیش‌بینی رواناب روزانه مورد استفاده قرار گیرد. اینگونه مدل‌سازی‌ها می‌توانند در تهیه سیستم‌های هشدار سیل نیز مورد استفاده قرار گیرند. نتایج پژوهش نشان داد مدل‌های مورد استفاده در حوضه‌های آبخیز با شرایط مختلف، عملکرد متفاوتی دارند. این تفاوت به تفاوت در شرایط این حوضه‌ها از جمله از نظر فیزیوگرافی و اقلیمی مرتبط می‌باشد. در حوضه‌های آبخیزی که رفتار اقلیمی و هیدرولوژیک منظم‌تری داشته‌اند (مانند حوضه کسلیان) عملکرد مدل‌ها نیز به طور کلی بهتر بوده است. وجود آب پایه و یا مقادیر زیاد صفر در داده‌های بارش و دبی می‌تواند تاثیر زیادی در عملکرد مدل‌ها داشته باشد. نوسانات بالای داده‌ها و تغییرات ناگهانی زیاد از صفر به مقادیر بالاتر که عموماً در مناطق خشک اتفاق می‌افتد شرایط دشوارتری را برای مدل داده محور برای شناسایی رفتار سیستم به وجود می‌آورد. در صورتی که در مناطق مرطوب‌تر نوسانات معمولاً ملایم‌تر اتفاق می‌افتد و این امر شناسایی رفتار سیستم را برای مدل ساده‌تر می‌نماید.

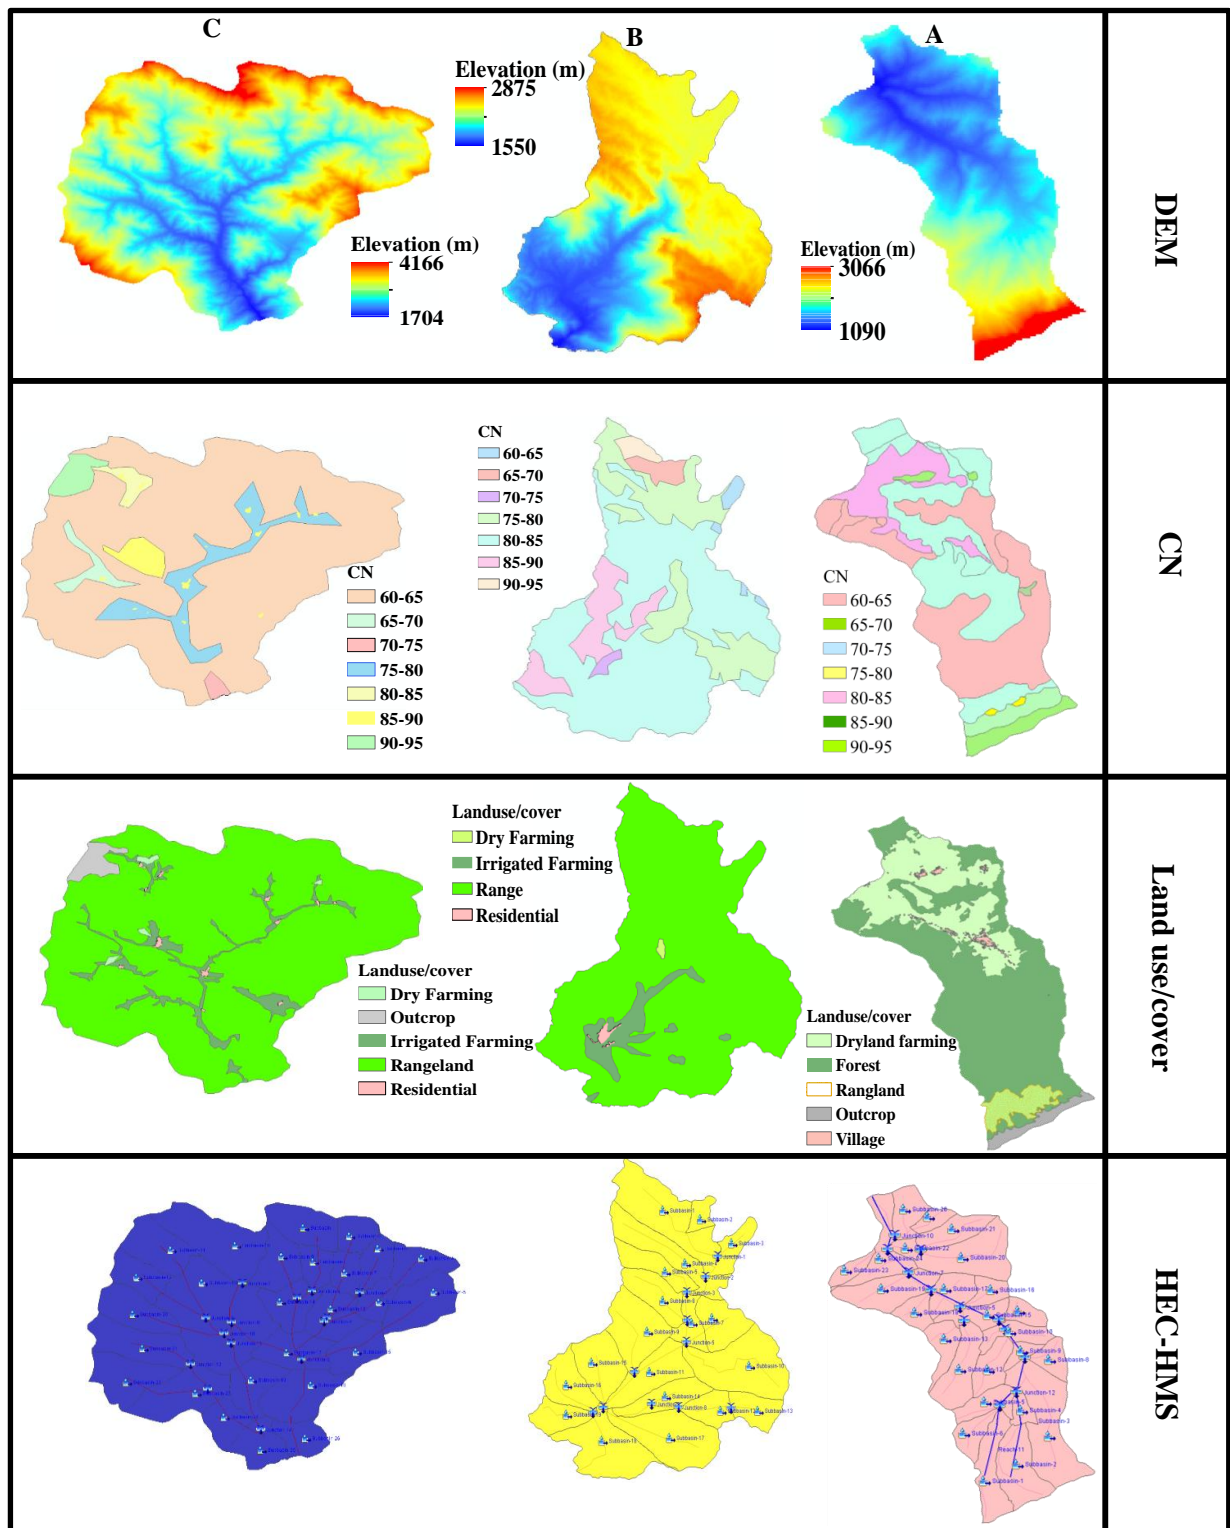


Fig. 7- The input maps and the HEC-HMS models for A) Latian, B) Kasilian, C) Bar-Erieh
 شکل ۷- نقشه‌های ورودی و مدل HEC-HMS برای حوضه‌های (A) لتیان، (B) کسلیان، (C) بار-اریه

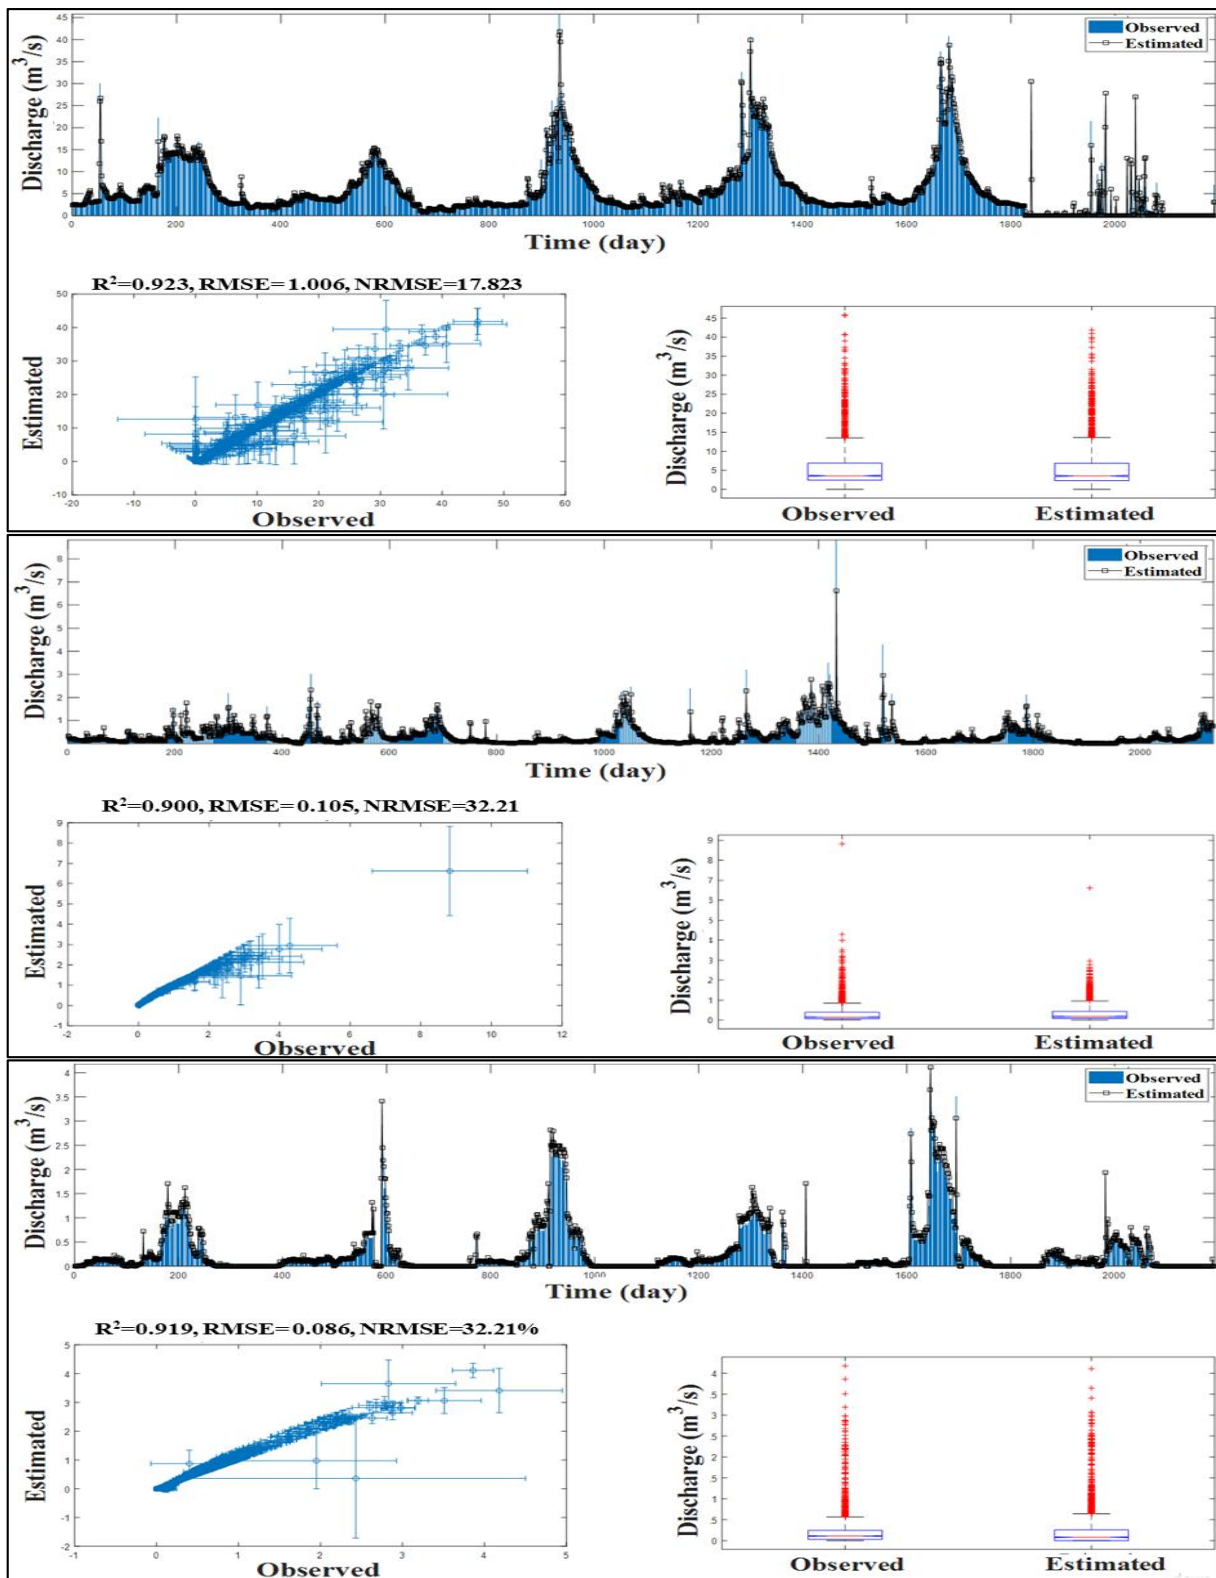


Fig. 8- Results of daily runoff Modeling by HEC-HMS Model in A) Latian, B) Kasilian, C) Bar-Erieh
 شکل ۸- نتایج مدل سازی رواناب روزانه توسط مدل HEC-HMS در حوضه‌های (A) لتیان، (B) کسلیان، (C) بار-اریه

پی‌نوشت‌ها

- 1- Runoff
- 2- Modeling
- 3- Multilayer Perceptron (MLP)
- 4- Group Method of Data Handling (GMDH)
- 5- Artificial Neural Network
- 6- Long Short-Term Memory
- 7- Convolutional Neural Network
- 8- Long Short-Term Memory
- 9- Ant Colony Optimization
- 10- Cross-View Multi-Decoder Convolutional Bidirectional Long Short-Term Memory
- 11- Antecedent Precipitation Index
- 12- Antecedent Discharge Index
- 13- Autocorrelation
- 14- Serial Correlation
- 15- Recurrent Neural Network
- 16- Coefficient of Determination (R²)
- 17- Normalized Root Mean Square Error
- 18- Antecedent Precipitation Index
- 19- Antecedent Discharge Index
- 20- Group Method of Data Handling

در واقع نایستایی داده‌ها در مناطق خشک‌تر نسبت به مناطق مرطوب‌تر به طور نسبی بالاتر است. که این امر لزوم استفاده از روش‌هایی برای غلبه بر نایستایی در داده‌ها را طور برجسته‌تری نشان می‌دهد. یکی از روش‌های مهم که می‌تواند به مدل‌های داده‌محور مخصوصاً مدل‌های هوش مصنوعی برای غلبه بر مشکل نایستایی داده‌ها کمک کند روش‌های پردازش سیگنال مانند موجک و تجزیه حالت متغیر باشد که برای مطالعات آینده پیشنهاد می‌گردد. به علاوه نشان داده شد که مدل‌های فیزیک‌پایه مانند HEC-HMS نیز با دقت و صحت مناسب می‌توانند برای مدل‌سازی فرآیند بارش-رواناب مورد استفاده قرار گیرند. اما نکته مهم در خصوص این مدل‌ها در عین داشتن مزایای بسیار زیاد هزینه محاسباتی بالاتر، نیاز بیشتر به داده و نیز نیاز به توان و تخصص به منظور واسنجی مناسب این مدل‌ها می‌باشد. در صورتی که موارد گفته شده به خوبی رعایت شوند این مدل‌ها می‌توانند عملکرد بسیار مناسبی داشته باشند. در واقع انتخاب نوع مدل بستگی به نیاز کاربر دارد. اگر فرآیند حاکم بر پدیده برای کاربر اهمیت بالایی داشته باشد و یا هدف اعمال سناریوهای مختلف و تعیین اثر عواملی مانند کاربری اراضی و غیره باشد، مدل‌هایی مانند HEC-HMS برای استفاده در اولویت هستند. اما اگر صرفاً میزان عددی رواناب در خروجی مد نظر کاربر باشد، مدل‌های هوش مصنوعی به ویژه مدل‌های یادگیری عمیق می‌توانند انتخاب مناسب‌تری باشند. به عبارت دیگر اگر فرآیند برای کاربر در اولویت است مدل‌های فیزیک پایه و اگر خروجی برای کاربر در اولویت است مدل‌های یادگیری عمیق توصیه می‌گردند.

۵- مراجع

- Ahmadi F (2019) Evaluation of the performance of support vector machine methods and adaptive neural-fuzzy inference system in predicting the monthly flow of rivers (Case study: Nazlo and Caesar rivers). *Research on Water and Soil Resources of Iran (Iranian Sciences and Agriculture)* 51(3):673-686 (In Persian)
- Ahmed AM, Deo RC, Ghahramani A, Feng Q, Raj N, Yin Z, and Yang L (2022) New double decomposition deep learning methods for river water level forecasting. *Science of the Total Environment* 831:154722
- Baek SS, Pyo J, and Chun JA (2020) Prediction of water level and water quality using a CNN-LSTM combined deep learning approach. *Water* 1(12):3399
- Bai Y, Bezak N, Zeng B, Li C, Sapač K, and Zhang J (2021) Daily runoff forecasting using a cascade long short-term memory model that considers different variables. *Water Resources Management* 35(4):1167-1181
- Bennett T (1998) Development and application of a continuous soil moisture accounting algorithm for the Hydrologic Engineering Center-Hydrologic Modeling System HEC-HMS. MS Thesis, Department of civil and environmental engineering, University of, Davis, California
- Biglerian A, Hagizadeh A, and Kazemnejad A (2009) Prediction of incomplete data using artificial neural network model. *Journal of Basic Sciences of JSIAU, Islamic Azad University* 20(78.2):21-28 (In Persian)
- Coulibaly P (2010) Reservoir computing approach to Great Lakes water level forecasting. *Journal of Hydrology* 381:76-88
- Dehghani N, Vafakhah M, and Bahremand AR (2016) Precipitation-runoff modeling using artificial neural network and adaptive neural fuzzy network in Kesilian watershed. *Watershed Management Research* 7(13):128-137 (In Persian)
- Drewil GI, and AL-bahadili RJ (2022) Air pollution prediction using LSTM deep learning and metaheuristics algorithm. *Measurement: Sensors*, 100546
- Godarzi MR, and Godarzi H (2020) Investigating the effectiveness of data group classification method and wavelet transformation in runoff forecasting (study area: Qorso watershed). *Scientific Research Journal of Irrigation and Water Engineering of Iran* 10(4):67-81 (In Persian)
- Han H, Choi C, Jung J, and Kim HS (2021) Deep learning with long short-term memory based Sequence-to-Sequence model for Rainfall-Runoff simulation. *Water* 13(4):437
- HEC (2008) HEC-HMS, User's manual version 3.3. Hydrologic engineering center, California
- Ivakhnenko AG (1971) Polynomial theory of complex systems. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-1(4):364-378
- Jaefari M, Vafakhah M, and Abghari H (2013) Comparison of the performance of two sigmoid and hyperbolic tangent functions of artificial neural network in predicting the runoff coefficient of torrential rain (case study: Arie Neishabur floodplain). *Water and soil Conservation Research (Agricultural Sciences and Natural Resources)* 20(2):85-103 (In Persian)
- Kratzert F, Klotz D, Brenner C, Schulz K, Herrnegger M (2018) Rainfall-runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences* 22(11):6005-6022
- Kuok KK, and Bessaih N (2007) Artificial neural networks (ANNS) for daily rainfall runoff modelling. *The Journal of the Institution of Engineers, Malaysia* 68(3):31-42
- Kuok KK, Harun S, and Shamsudin SM (2010) Global optimization methods for calibration and optimization of the hydrologic Tank model's parameters. *Canadian Journal on Civil Engineering* 1(1):2-14
- Lorrai M, and Sechi GM (1995) Neural nets for modelling rainfall-runoff transformations. *Water Resources Management* 9(4):299-313
- Mirabedini S (2018) An overview of deep learning. 3rd National Technology Conference on Electrical and Computer Engineering (In Persian)
- Moosavi V, Mahjoobi J, and Hayatzadeh M (2021) Combining group method of data handling with signal processing approaches to improve accuracy of groundwater level modeling. *Natural Resources Research* 30(2):1735-1754
- Moosavi V, Talebi A, and Hadian MR (2017) Development of a hybrid wavelet packet-group method of data handling (WPGMDH) model for runoff forecasting. *Water Resources Management* 31(1):43-59
- Moosavi V, Gheisoori Fard Z, Vafakhah M (2022) Which one is more important in daily runoff forecasting using data driven models: Input data,

- model type, preprocessing or data length? *Journal of Hydrology* 606:127429
- Patel AB, and Joshi GS (2017) Modeling of rainfall-runoff correlations using artificial neural network-A case study of Dharoi Watershed of a Sabarmati River Basin, India. *Civil Engineering Journal* 3(2):78-87
- Razavizadeh S, and Dargahian F (2018) Optimizing the neural network structure in predicting sediment discharge using Taguchi method. *Iranian Journal of Watershed Science and Engineering* 12(43):89-97 (In Persian)
- Riad S, Mania J, Bouchaou L, and Najjar Y (2004) Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling* 40(7-8):839-846
- Rohani A, Saedi SE, Gerailu H, Aghkhani MH (2015) Prediction of lateral surface, volume and sphericity of pomegranate using MLP artificial neural network. *Journal of Agricultural Machinery* 5(2):292-301 (In Persian)
- Schmidhuber J (2015) Deep learning in neural networks: An overview. *Neural networks* 61:85-117
- Sedighi F, Vafakhah M, and Javadi M (2015) Application of artificial neural network in predicting runoff caused by snowmelt (case study: Letian dam watershed). *Watershed Management Research* 6(12):43-54 (In Persian)
- Seo Y, Kim S, and Singh VP (2018) Machine learning models coupled with variational mode decomposition: A new approach for modeling daily rainfall-runoff. *Atmosphere* 9(7):251
- Solomatine DP, and Ostfeld A (2008) Data-driven modelling: some past experiences and new approaches. *Journal of Hydroinformatics* 10(1):3-22
- Tikhmarine Y, Souag-Gamane D, Najah Ahmed A, Sammen SS, Kisi O, Feng Huang Y, El-Shafie A (2020) Rainfall-runoff modelling using improved machine learning methods: Harris hawks optimizer vs. particle swarm optimization. *Journal of Hydrology* 589:125133
- Xiang Z, Yan J, and Demir I (2020) A rainfall-runoff model with LSTM-based sequence-to-sequence learning. *Water Resources Research* 56(1):e2019WR025326
- Zorati A, Salajegheh A, Almaali N, Mohammadaskari H (2009) Investigating the rainfall-runoff model using artificial neural network and statistical two-variable regression methods (Case Study: Minab watershed). *Watershed Research (Research and Construction)* 22(2):69-74 (In Persian)