

# Evaluating the Performance of the LSTM Model in Forecasting Daily Inflow the Dam Reservoirs

## Abstract

Real-time forecasting of daily inflows to reservoirs with a prediction horizon that extends several steps into the future is crucial for water resource planning and management. Despite numerous studies on inflow prediction using machine learning methods, few have investigated the predictive capabilities of these approaches with long lead time (several steps ahead) or gained insights through systematic comparisons of model predictive performance in the short term. In this study, the daily inflow to the Seimareh reservoir was predicted for the next 7 days using the Adaptive Neuro-Fuzzy Inference System (ANFIS) and the Long Short-Term Memory (LSTM) network. For this purpose, daily data on precipitation, temperature and inflow to the Seimareh reservoir from 2012 to 2018 were used for modeling. The results showed that the performance of the LSTM model was better than that of ANFIS in the daily forecast in several steps. Specifically, the maximum and minimum values of the Nash coefficient in the forecast horizon for the next seven days were 0.971 and 0.628 for the LSTM model and 0.858 and 0.393 for the ANFIS model, respectively. The optimal setting of the parameters, including the number of neurons in each layer, the number of epochs and the stack size in the LSTM model, is the key to the model's high potential to predict the inflow for the next seven days. Finally, the performance of the LSTM model in predicting the inflow to Seimareh during the 2019 flood was evaluated and it was found to predict flood discharges with acceptable accuracy up to the forecast horizon of the next seven days. These results indicate that the LSTM model is suitable for forecasting daily inflow and can help make strategic decisions in water resource management, especially under flood conditions.

Keywords: *daily reservoir inflow forecast, flood management, long lead-time forecast, machine learning.*

مجله علمی پژوهشی  
مهندسی و فناوری

## ارزیابی کارایی مدل LSTM در پیش‌بینی جریان روزانه ورودی به مخازن سدها

### چکیده

پیش‌بینی زمان واقعی جریان روزانه ورودی به مخازن با افق پیش‌بینی چند گام جلوتر جهت برنامه‌ریزی و مدیریت منابع آب اهمیت زیادی دارد. با وجود مطالعات زیاد پیش‌بینی جریان با روش‌های یادگیری ماشین، مطالعات کمی برای بررسی قابلیت‌های پیش‌بینی طولانی مدت (چند گام جلوتر) این روش‌ها و به دست آوردن بینشی نسبت به مقایسه سامان‌مند عملکرد پیش‌بینی مدل در کوتاه‌مدت انجام شده است. در این پژوهش با استفاده از سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) و شبکه حافظه کوتاه و بلند مدت (LSTM) پیش‌بینی جریان روزانه ورودی به مخزن سیمره تا ۷ روز آینده انجام شد. برای این کار از داده‌های روزانه بارش، دما و جریان ورودی به سیمره از سال ۱۳۹۱ تا ۱۳۹۷ جهت انجام مدل سازی استفاده شده است. نتایج نشان داد که در پیش‌بینی روزانه چند گام جلوتر، عملکرد مدل LSTM بهتر از ANFIS است به طوری که بیشینه و کمینه مقدار ضریب نش در افق پیش‌بینی تا هفت روز آینده به ترتیب برای مدل LSTM برابر ۰/۹۷۱ و ۰/۶۲۸ و برای مدل ANFIS برابر ۰/۸۵۸ و ۰/۳۹۳ می‌باشد. تنظیم بهینه پارامترهای مربوط به تعداد نرون‌ها در هر لایه، تعداد تکرارها و تعداد دسته‌ها در مدل LSTM، کلیدی برای پتانسیل بالای مدل جهت پیش‌بینی جریان تا افق پیش‌بینی هفت روز آینده می‌باشد. در نهایت عملکرد LSTM جهت پیش‌بینی جریان ورودی به سیمره در سیلاب ۹۸ ارزیابی و مشخص شد که جریان‌های سیلابی را با دقت قابل قبولی تا افق پیش‌بینی ۷ روز آینده، پیش‌بینی کرده است. این یافته‌ها نشان می‌دهد که LSTM می‌تواند در پیش‌بینی جریان روزانه مناسب باشد. بنابراین برای کمک به تصمیم‌گیری‌های راهبردی در مدیریت منابع آب بخصوص در شرایط سیلابی می‌توان از آن بهره گرفت.

**کلمات کلیدی:** افق پیش‌بینی بلندمدت، پیش‌بینی جریان روزانه مخزن، مدیریت سیلاب، یادگیری ماشین.

### مقدمه

پیش‌بینی دقیق جریان برای برنامه‌ریزی و مدیریت مؤثر منابع آب، مدیریت سیلاب، زمان‌بندی رهاسازی از مخازن و بسیاری از کاربردهای دیگر نقش مهمی دارد (Ni et al., 2019; Fathian et al., 2019). یکی از ابزارهای مهم جهت برنامه‌ریزی و مدیریت بهره‌برداری بهینه از سامانه‌های منابع آب مانند مخازن سدها، پیش‌بینی جریان روزانه ورودی به آن‌ها است. از جمله مهم‌ترین هدف‌های پیش‌بینی‌های روزانه، مقابله مناسب و به‌موقع با خطر سیلاب و سرریز شدن سدها و کمینه کردن خسارت ناشی از آن می‌باشد (موسوی ندوشنی و همکاران، ۱۳۹۰). از آنجایی که جریان وابستگی غیرخطی شدیدی به عوامل آب‌وهوایشناسی و انسانی نشان می‌دهد از این‌رو تغییرات زیادی در بعد مکانی و زمانی دارد و پیش‌بینی آن در مقیاس زمانی کوتاه‌مدت و بلندمدت دشوار است (Milly et al., 2005; Nourani & Komasi, 2013; Xiao et al., 2019). از این‌رو پیش‌بینی جریان ورودی روزانه به مخازن یک چالش مهم در مدیریت منابع آب می‌باشد. با پیشرفت فناوری، روش‌های هوش مصنوعی مانند شبکه‌های عصبی، الگوریتم‌های یادگیری ماشین، و روش‌های داده‌کاوی باعث شده است تا بتوان از این ابزارها برای پیش‌بینی جریان ورودی به مخازن در زمان واقعی استفاده نمود. با این وجود، پیش‌بینی در زمان واقعی جریان به دلیل پیچیدگی بالای فرآیندهای هیدرولوژیکی، چالش‌های زیادی دارد و غالباً با خطاهای قابل توجهی همراه است (صمدی بروجنی و عسکری، ۱۳۸۷). پیش‌بینی کوتاه‌مدت (روزانه) را نمی‌توان به راحتی انجام داد، زیرا میزان جریان روزانه ورودی به مخازن به عوامل بسیاری وابسته است (Noorbeh et al., 2020). برای پیش‌بینی جریان روزانه ورودی به مخازن معمولاً از مجموعه‌ای از متغیرهای هیدرولوژیکی در روش‌های هوش مصنوعی استفاده می‌شود. این روش‌ها با استفاده از داده‌های هیدرولوژیکی تاریخی از مخازن و عوامل محیطی مرتبط، مشاهدات هواشناسی و هیدرولوژیکی فعلی به یادگیری الگوهای پیچیده مرتبط با جریان آب می‌پردازند و قادر به پیش‌بینی جریان ورودی در زمان واقعی می‌باشند (موسوی ندوشنی و همکاران، ۱۳۹۰؛ شاه کرمی و همکاران، ۱۳۹۴).

برای این منظور، تحقیقات زیادی بر روی پیش‌بینی کوتاه‌مدت جریان رودخانه‌ها و ورودی سدها انجام شده است. این تحقیقات عمدتاً به منظور ارائه مدل‌های پیش‌بینی دقیق‌تر و کارآمدتر برای مدیریت بهینه منابع آب و بهره‌برداری از سدها صورت گرفته‌اند (Sun & Burian, 2016). این رویکردها با همکاری بین‌رشته‌ای متخصصان هیدرولوژی، هواشناسی، علوم داده و مهندسی سامانه‌های آبی، بهبود پیش‌بینی‌ها در زمان واقعی جریان رودخانه‌ها و بهره‌برداری بهینه از سدها را ممکن ساخته است (Mousavi & Mahjoobi, 2019). به طور کلی بر اساس مطالعات انجام‌شده می‌توان روش‌های پیش‌بینی جریان را به چند دسته مختلف

تقسیم نمود: روش‌های مبتنی بر فیزیک (مدل‌های مفهومی)، روش‌های آماری<sup>۲</sup>، روش‌های هوش مصنوعی و داده محور<sup>۳</sup> و روش‌های ترکیبی<sup>۴</sup>. هر یک از این دسته‌بندی‌ها طیف وسیعی از روش‌ها و مدل‌های خاص مورد استفاده برای پیش‌بینی جریان ورودی به مخازن را در برمی‌گیرد و انتخاب روش مناسب به عواملی مانند در دسترس بودن داده‌ها، منابع محاسباتی و ویژگی‌های خاص سامانه هیدرولوژیکی مورد بررسی بستگی دارد. امروزه به دلیل نیاز به داده و اطلاعات زیاد در مدل‌های مفهومی هیدرولوژیکی و سهولت استفاده از مدل‌های هوش مصنوعی با توجه به نیاز به داده و اطلاعات کمتر مربوط به فرآیندهای هواشناسی و هیدرولوژیکی و همچنین پیشرفت‌های صورت گرفته در علوم داده و هوش مصنوعی، بیشتر مطالعات در زمینه پیش‌بینی جریان ورودی به مخازن با استفاده از مدل‌های یادگیری ماشین انجام می‌شود. اخیراً، شبکه حافظه کوتاه و بلند مدت<sup>۵</sup> (LSTM) توجه زیادی را در میان هیدرولوژیست‌ها به خود جلب کرده است و ثابت کرده است که یک ابزار قدرتمند برای پیش‌بینی سری زمانی است (Hu et al., 2019). در مقایسه با شبکه‌های عصبی کلاسیک، LSTM‌ها می‌توانند هم رفتارهای دوره‌ای و هم رفتارهای آشفته داده‌های سری زمانی را ضبط کنند و وابستگی‌های دوربرد آن‌ها را با دقت بیشتری یاد بگیرند (Mouatadid et al., 2019). برای مثال، (Kratzert et al., 2018) نشان دادند که مدل LSTM را برای توصیف رفتار بارش-رواناب تعداد زیادی از حوضه‌های آبریز پیچیده در مقیاس روزانه عملکرد خوبی دارد. همچنین (Hu et al., 2018) عملکرد مدل‌های شبکه عصبی مصنوعی<sup>۶</sup> (ANN) و LSTM را برای پیش‌بینی جریان سیلابی بررسی کردند. نتایج نشان داد که مدل LSTM از مدل ANN برای پیش‌بینی سیل تا ۶ ساعت آینده بهتر عمل می‌کند. (Le et al., 2019) قابلیت مدل‌های ANN و LSTM را برای پیش‌بینی جریان یک، دو و سه روزه در هوآیین<sup>۷</sup> را بررسی کردند. نتایج آنها نشان داد که مدل LSTM می‌تواند وابستگی‌های بلندمدت بین سری داده‌های متوالی را بیاموزد و عملکرد خوبی در پیش‌بینی سیل از خود نشان دهد. (Latif et al., 2021) از الگوریتم‌های یادگیری ماشین برای توسعه سه مدل LSTM، ANN و ماشین بردار پشتیبان<sup>۸</sup> (SVM) به منظور پیش‌بینی جریان روزانه ورودی به سدی در کشوری مالزی پرداختند. طبق نتایج، مدل LSTM نسبت به دو مدل دیگر عملکرد بهتری داشت. همچنین مطالعات زیادی با سایر مدل‌های هوش مصنوعی در این راستا انجام شده است مانند: (Kumar et al., 2015) از پنج مدل ترکیبی متشکل از رویکردهای آنالیز موجک، شبکه عصبی و بوت‌استرپ، به منظور پیش‌بینی روزانه جریان ورودی به مخزن یک سد در هند و همچنین بازه عدم قطعیت آن، پرداختند. طبق نتایج، مدل موجک-عصبی بهترین عملکرد را از خود نشان داد. میثاقی (۱۳۹۵) پیش‌بینی جریان ورودی به مخزن علویان در شمال غرب ایران را با به کارگیری سامانه استنتاج عصبی-فازی تطبیقی<sup>۹</sup> (ANFIS) بهینه‌شده با استفاده از اطلاعات روزانه، هفتگی، ۱۰ روزه و ماهانه جریان آب ورودی به سد علویان، انجام داد. نتایج حاکی از عملکرد مناسب مدل در برآورد جریان بوده و طبق آنالیز حساسیت، مؤثرترین متغیر ورودی در همه مدل‌ها، دبی جریان در گام زمانی قبلی است. (Zhang et al., 2020) از یک مدل ترکیبی متشکل از سه مدل ANN، SVM و ANFIS به منظور برآورد ۱۰ روزه جریان ورودی به مخزن سد هوآنرن<sup>۱۰</sup> در چین، استفاده کردند. پیش‌بینی کننده‌های مورد استفاده در این پژوهش عبارت‌اند از بارش، دبی رطوبت نسبی، کمینه دما، بیشینه دما و بارش پیش‌بینی شده. طبق نتایج، سناریوی مدل‌سازی متشکل از متغیرهای دبی، بارش و بارش پیش‌بینی شده دقت بالایی را نشان داد و اضافه کردن سه متغیر دیگر در مدل‌سازی موجب افزایش چشم‌گیری در دقت مدل نشده است. (Babaei et al., 2019) به پیش‌بینی جریان ورودی به سد زاینده‌رود با استفاده از مدل‌های ANN و SVM پشتیبان پرداختند. نتایج آن‌ها نشان داد که مدل ماشین بردار پشتیبان عملکرد بهتری را نسبت به شبکه عصبی مصنوعی برای پیش‌بینی جریان دارد.

درحالی‌که تحقیق بر روی مدل‌های یادگیری ماشین در زمینه پیش‌بینی جریان به سرعت توسعه یافته است، برخی از کاستی‌ها همچنان پابرجا هستند. (۱) بیشتر تحقیقات فاقد بررسی سامان‌مند عملکرد مدل پیش‌بینی در کوتاه‌مدت هستند (Yaseen et al.,

1. Physics-based methods
2. Statistical Methods
3. Artificial intelligence and data-driven methods
4. Combined method
5. Long Short Term Memory
6. Artificial Neural Network
7. Hoa Binh
8. Support Vector Machine
9. Adaptive Neuro-Fuzzy Inference System
10. Huanren

(2015). ۲) برای به دست آوردن پیش‌بینی جریان در زمان‌های مختلف، بیشتر مطالعات باید مدل‌های چندگانه را با ورودی‌ها و خروجی‌های مختلف در چند تأخیر متوالی بسازند (Hu et al., 2018; Nourani & Partoviyan, 2018). برای مثال نورانی (۲۰۱۷) سه نوع رابطه را در سه مدل ایجاد کرد تا مقادیر پیش‌بینی را به ترتیب در زمان‌های ۲، ۴ و ۷ روز به دست آورد. ۳) تنظیم پارامتر در روش‌های یادگیری ماشین، نکته کلیدی در توسعه مدل است (Cheng et al., 2020)، برای مثال طول تأخیر زمانی (Dehghani et al., 2015)، تعداد دسته‌ها، تعداد دوره‌ها و تعداد نرون‌ها در هر لایه در مدل LSTM، بر پیش‌بینی جریان مؤثر است.

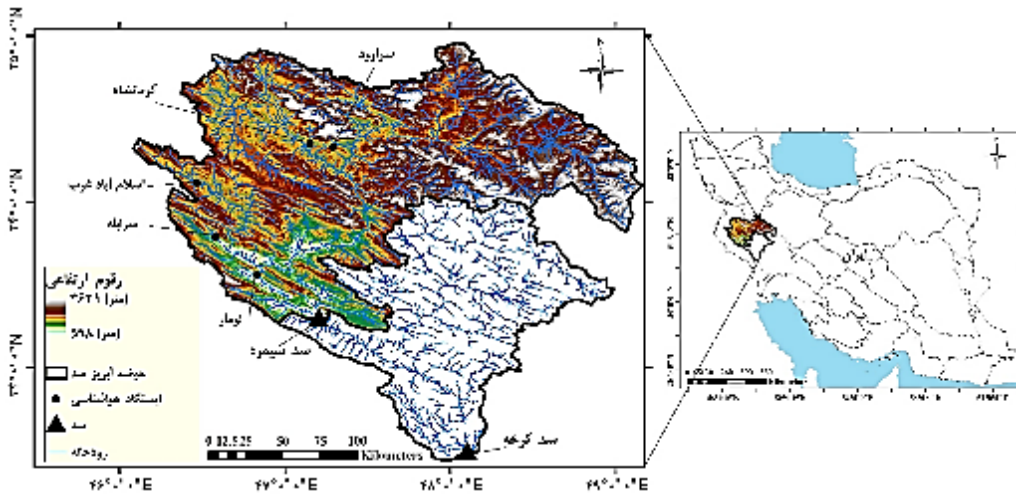
از این‌رو در مطالعه حاضر برای رفع نقص‌ها و عیب‌های روش‌های استفاده شده پیشین، نوع پیشرفته‌ای از شبکه‌های عصبی بازگشتی با عنوان مدل LSTM، به منظور پیش‌بینی جریان روزانه ورودی به مخازن سدها ارائه شده است. LSTM نوعی شبکه عصبی یادگیری عمیق است که در آن بجای توابع ساده، از توابع پیچیده و ترکیبی به‌منظور تنظیم و تقویت حافظه کوتاه‌مدت استفاده می‌شود و با تنظیم بهینه پارامترهای مربوط به مدل‌سازی، مانند تعداد نرون‌ها<sup>۱</sup> در هر لایه، تعداد تکرارها<sup>۲</sup> و تعداد دسته‌ها<sup>۳</sup> در آن، پتانسیل بالایی جهت پیش‌بینی طولانی‌مدت دارد. لذا هدف از این پژوهش در ابتدا ارزیابی کارایی و مقایسه مدل‌های ANFIS و LSTM در پیش‌بینی جریان روزانه ورودی به مخازن سدها و سپس مدل‌سازی جریان ورودی به مخزن سیمره با استفاده از آن‌ها به‌ویژه برای قابلیت پیش‌بینی طولانی‌مدت (۷ روز آینده) می‌باشد. درنهایت پیش‌بینی جریان ورودی به مخزن در شرایط سیلابی با استفاده از مدل برتر انجام می‌شود. سؤال اساسی این تحقیق این است که با توجه به معیارهای ارزیابی، آیا مدل یادگیری ماشین برتر در این مطالعه، می‌تواند به‌منظور بهره‌برداری از مخزن در شرایط بحرانی و سیلاب، جهت پیش‌بینی عملیاتی و زمان واقعی جریان ورودی به مخزن عملکرد خوبی داشته باشد و به نتایج حاصل از آن اعتماد کرد. همانطور که می‌دانیم یکی از مهم‌ترین اهداف پیش‌بینی‌های زمان واقعی و عملیاتی جریان روزانه، مقابله مناسب و به‌موقع با خطر سیلاب و سرریز شدن سدها و حداقل نمودن خسارت ناشی از آن می‌باشد بنابراین با توجه به اینکه تاکنون پژوهشی به منظور پیش‌بینی زمان واقعی جریان روزانه ورودی به مخازن سدها در شرایط سیلابی با مدل LSTM، در ایران انجام نشده است، این تحقیق می‌تواند راهنما و الگوی جدیدی برای محققین باشد.

## مواد و روش‌ها

### منطقه مطالعاتی

منطقه مطالعاتی در این پژوهش واقع در حوضه آبریز کرخه می‌باشد که در جنوب غربی ایران واقع شده است. این حوضه مساحتی معادل ۵۱۶۴۳ کیلومتر مربع دارد که حدود ۵۵/۵ درصد آن را مناطق کوهستانی تشکیل می‌دهد. حوضه آبریز کرخه در محدوده مختصات جغرافیائی ۰۶° ۴۶ تا ۰۱۰° ۴۹ طول شرقی و ۰۵۸° ۳۰ تا ۰۴° ۳۵ عرض شمالی قرار گرفته است. پیش‌بینی جریان ورودی به مخازن در زمان واقعی در این حوضه به دلیل موقعیت جغرافیایی و هیدرولوژیکی خاص حوضه و تعداد سدها و همچنین اهمیت بالای تولید انرژی برق‌آبی در این حوضه، اهمیت ویژه‌ای دارد. در این مطالعه جریان ورودی به سد سیمره مورد بررسی قرار گرفته است که از لحاظ موقعیت سیاسی و اقتصادی از اهمیت ویژه‌ای برخوردار است. در شکل ۱ موقعیت منطقه مطالعاتی، ایستگاه‌های هواشناسی، رودخانه‌ها و سد نشان داده شده است.

1. Nerous
2. Epochs
3. Bach size



شکل ۱. محدوده مطالعاتی و موقعیت سد سیمره

در جدول ۱ نیز برخی از مشخصات مهم سد سیمره ارائه شده است (هیأت ویژه گزارش ملی سیلاب‌ها، ۱۳۹۸).

جدول ۱. برخی مشخصات فنی مخزن سیمره

نام سد	سیمره
نوع سد	بتنی دو قوسی
سال شروع بهره‌برداری	۱۳۹۰
تراز تاج (masl)	۷۳۰
تراز نرمال (masl)	۷۲۳
تراز کمینه بهره‌برداری (masl)	۶۹۲
حجم نرمال (mcm)	۲۶۶۶
حجم کمینه بهره‌برداری (mcm)	۱۳۷۷
تراز آستانه سرریز (masl)	۷۰۴/۵
تراز آبگیر نیروگاه (masl)	۶۶۵
تراز تخلیه‌کننده تحتانی (masl)	۶۴۰
تعداد واحدهای نیروگاهی	۳
ظرفیت نصب نیروگاه (mw)	۴۸۰
هد طراحی نیروگاه (m)	۱۱۴
دبی طراحی نیروگاه (cms)	۴۶۸
بیشینه ظرفیت تخلیه سرریز (cms)	۸۳۰۰
ظرفیت تخلیه‌کننده تحتانی (cms)	۱۱۲۰
ضریب کارکرد نیروگاه (درصد)	۱۶/۶

### داده‌های مورداستفاده

در این مطالعه از داده‌های روزانه جریان ورودی به مخزن سیمره، بارش و دمای کمینه، بیشینه و متوسط از تاریخ ۱۳۹۱/۳/۱۴ تا ۱۳۹۷/۶/۳۱، به‌عنوان داده‌های مشاهده‌شده که منبع داده‌های مورداستفاده در جدول ۲ ارائه شده است. پس از استانداردسازی داده‌ها با استفاده از رابطه ۱، ۸۰ درصد از آنها را برای آموزش مدل و ۲۰ درصد باقیمانده برای آزمایش مدل انتخاب شده است. مشخصات جریان روزانه ورودی به سد سیمره در بازه زمانی مورد نظر در جدول ۳ ارائه شده است.

جدول ۲. داده‌های مورداستفاده و منبع آن‌ها در این پژوهش

نوع داده	منبع
----------	------

داده‌های جریان روزانه ورودی به مخزن	شرکت مدیریت منابع آب ایران
بارش ۵ ایستگاه سینوپتیک بالادست سد	سازمان هواشناسی کشور
بارش، دمای بیشینه، کمینه و متوسط	پایگاه داده جهانی ERA5

جدول ۳. کمینه، بیشینه و میانگین جریان ورودی به مخزن سیمره در بازه موردبررسی

مخزن	متوسط جریان (mcm/day)	بیشینه جریان (mcm/day)	کمینه جریان (mcm/day)
سیمره	۷/۶۵	۲۱۰/۳۸	۰

در این پژوهش به ارزیابی کارایی مدل LSTM و مقایسه عملکرد آن با مدل ANFIS به منظور پیش‌بینی جریان روزانه ورودی به مخزن تا افق پیش‌بینی ۷ روز آینده پرداخته شده است.

### پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها، قبل از ورود به مرحله مدل‌سازی باید انجام شود. از این رو هر یک از متغیرهای ورودی با تأخیر زمانی یک تا هفت روز، به عنوان متغیر ورودی یا پیش‌بینی‌کننده در فرآیند مدل‌سازی استفاده شده‌اند و جریان ورودی به سد در روزهای آینده نیز به عنوان متغیر خروجی (پیش‌بینی‌شونده) در نظر گرفته می‌شود. به منظور هماهنگ‌تر شدن بهتر داده‌ها و بهبود برازش مدل، استانداردسازی داده‌ها با استفاده از رابطه ۱ انجام شده است.

$$y = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه ۱}$$

که در این رابطه  $X$  داده مورد نظر،  $X_{\max}$  بیشینه داده‌ها،  $X_{\min}$  کمینه داده‌ها و  $y$  داده استاندارد شده می‌باشد. برای مدل‌سازی با ANFIS از رویکرد انتخاب ویژگی مبتنی بر روش جنگل تصادفی<sup>۱</sup> (برای انتخاب بهترین پیش‌بینی‌کننده) جهت پیش‌پردازش داده‌ها، قبل از ورود به مرحله مدل‌سازی، استفاده شد که در ادامه توضیح داده شده است.

### الگوریتم جنگل تصادفی

در این مطالعه با توجه به اینکه تعداد متغیرهای ورودی (پیش‌بینی‌کننده) زیاد است، باید مهم‌ترین متغیرهای ورودی جهت مدل‌سازی انتخاب شوند تا از این طریق از پیچیدگی بیش‌ازحد مدل‌های پیش‌بینی و همچنین از بیش‌برازشی مدل‌ها جلوگیری شود. الگوریتم جنگل تصادفی یک الگوریتم گروهی با مجموعه‌ای از درختان تصمیم است که برای انتخاب متغیر استفاده می‌شود. هر طبقه‌بندی برای هر نمونه ورودی، به صورت  $h(x, \theta_k)$  در نظر گرفته می‌شود به طوری که  $x$  یک نمونه ورودی و  $\theta_k$  مجموعه آموزش برای درخت  $k$ ام است.  $\theta$ ها مستقل از یکدیگر ولی با توزیع یکسان هستند. برای هر نمونه  $x$ ، هر درخت یک پیش‌بینی را برای رده نمونه  $x$  ارائه می‌دهد و در نهایت رده‌ای با بیشترین تعداد رأی درختان روی ورودی  $x$ ، به عنوان رده نمونه انتخاب می‌شود. این فرآیند را جنگل تصادفی می‌نامند (Breiman, 2001). دقت طبقه‌بندی با استفاده از جنگل تصادفی با ساخت مجموعه‌ای از درختان و رأی‌گیری بین آن‌ها برای به دست آوردن رده‌ای با بیشترین تعداد رأی، پیشرفت‌های قابل توجهی خواهد داشت. دو ویژگی مهم در ساخت جنگل‌های تصادفی، استفاده از روش بگینگ<sup>۲</sup> (Breiman, 1996) و انتخاب تصادفی در هر گره است. روش بگینگ، یک فرا الگوریتم بر مبنای مفاهیم خود راه‌انداز<sup>۳</sup> و ترکیبی، برای بهبود یادگیری ماشین است. الگوریتم‌های گروهی در یادگیری ماشین، چند یادگیرنده ضعیف را ترکیب کرده تا به یک یادگیری قوی، دست یابند. این روش از بیش‌برازش<sup>۴</sup> داده‌ها جلوگیری می‌کند. در الگوریتم بگینگ، نتایج خوب زمانی حاصل می‌شود که طبقه‌بندی‌های پایه، جزء الگوریتم‌های یادگیری ناپایدار باشند (مانند درخت تصمیم‌گیری یا شبکه‌های عصبی) به طوری که تغییرات کوچک در داده‌های

1. Random Forest
2. Bagging
3. Bootstrapping
4. Overfitting

آموزشی منجر به تغییرات عمده‌ای در مدل ساخته‌شده توسط آن الگوریتم شود. برای مطالعه بیشتر در خصوص الگوریتم بگینگ به مرجع (Breiman, 1996) مراجعه شود.

## مدل سازی

### سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)

نظریه مجموعه فازی توسط لطفی عسگرزاده در سال ۱۹۶۵ پیشنهاد شد و به‌طور گسترده در بسیاری از زمینه‌ها استفاده می‌شود (Ross, 1995). سامانه استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به‌منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین با توجه به توانایی در ترکیب قدرت زبانی یک سامانه فازی با قدرت عددی یک شبکه عصبی، در مدل‌سازی فرایندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق بسیار قدرتمند می‌باشد (Nayak et al., 2004; Kişi, 2009). مدل ANFIS براساس تغییر در میزان مقادیر و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس کمینه خطای موجود عمل می‌کند. در مدل ANFIS از روش استنتاجی تاکاگی سوگنو استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین گردند که مقدار خطای مدل به کمینه مقدار خود برسد و همچنین مقادیر کارایی، بیشترین مقدار را داشته باشند.

ANFIS قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به‌طور تطبیقی یک قاعده- بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سامانه‌های فازی را تنظیم کند. مشکل اصلی مدل پیش‌بینی ANFIS احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین پارامترها می‌باشد. به‌منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی موردنظر دو ورودی  $x$  و  $y$  و یک خروجی  $z$  دارد. برای یک مدل فازی تاکاگی سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر-آنگاه فازی به‌صورت زیر بیان کرد:

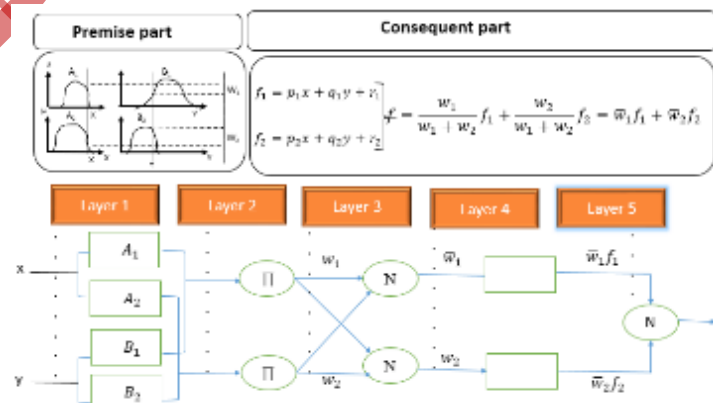
$$z_1 = p_1x + q_1y + r_1$$

قانون اول : اگر  $x$  برابر  $A_1$  و  $y$  برابر  $B_1$  باشد آنگاه:

$$z_2 = p_2x + q_2y + r_2$$

قانون دوم : اگر  $x$  برابر  $A_2$  و  $y$  برابر  $B_2$  باشد آنگاه:


که  $p_i, q_i, r_i$  پارامترهای خطی در بخش تالی مدل فازی تاکاگی- سوگنو درجه اول هستند. مطابق شکل ۲ ساختار مدل ANFIS شامل پنج لایه می‌باشد (Nourani & Komasi, 2013).



شکل ۲. سامانه ANFIS معادل با سامانه فازی سوگنو با تابع عضویت مثلثی (Nourani & Komasi, 2013).

### شبکه عصبی حافظه کوتاه و بلند مدت (LSTM)

یکی از مدل‌های محبوب در شبکه‌های بازگشتی، مدل LSTM است. این نوع شبکه برای اولین بار در سال ۱۹۹۷ میلادی توسط هوخرایتر<sup>۱</sup> و اشمیدهوربر<sup>۲</sup> معرفی شد. طراحی شبکه‌های LSTM به منظور حل مشکلات ناشی از وابستگی بلندمدت داده‌ها انجام شد (Olah, ۲۰۱۵). این مدل نوع خاصی از شبکه عصبی بازگشتی بوده که بجای توابع ساده، از توابع پیچیده و ترکیبی به منظور تنظیم و تقویت حافظه کوتاه‌مدت استفاده می‌کند و قابلیت یادگیری وابستگی‌های بلندمدت را علاوه بر وابستگی‌های کوتاه‌مدت دارد. هدف این نوع شبکه، پردازش داده‌هایی است که نیاز است وابستگی‌های بلندمدت آن‌ها در مدل در نظر گرفته شود. این نوع از شبکه عصبی می‌تواند در پیش‌بینی داده‌های سری زمانی استفاده شود. با توجه به نوع مسئله و ویژگی‌های خاص هر سری زمانی، می‌توان یکی از انواع مدل‌های LSTM را استفاده نمود. مدل‌های LSTM می‌توانند به صورت تک متغیره (Univariate) و چند متغیره (Multivariate) بر اساس تعداد سری زمانی ورودی تقسیم‌بندی شوند. در توسعه مدل، ابتدا مدل پیش‌بینی یک گام جلوتر در فرآیند توسعه مدل به دست می‌آید. سپس یک راهبرد بازگشتی در مدل‌های آموزش دیده اتخاذ می‌شود تا بتوان پیش‌بینی چندمرحله‌ای را به دست آورد. مطابق شکل ۳، شبکه‌های LSTM نیز شبیه ساختار استاندارد شبکه‌های بازگشتی دارای زنجیره‌ای از سلول‌ها است، با این تفاوت که ساختار هر سلول بجای یک لایه دارای چهار لایه مرتبط و متعامل است.



شکل ۳. ساختار شبکه‌های بازگشتی LSTM (ساختار تکرار شونده و چهار لایه‌ای) (Olah ۲۰۱۵).

### تشکیل پنجره‌های متحرک<sup>۳</sup>

منطق و اساس پنجره‌های متحرک به این صورت است که برای پیش‌بینی گام  $n$  ام از پیش‌بینی‌های گام‌های زمان قبل  $(n-1)$  و  $2$  (و ...) استفاده می‌شود. به عنوان مثال برای پیش‌بینی جریان با افق پیش‌بینی ۵ روز آینده از تمامی جریان‌های پیش‌بینی شده از افق ۱ تا ۴ روز به عنوان ورودی استفاده می‌شود که این موضوع در ساختار مدل‌های LSTM مدنظر قرار گرفته است و از نقاط قوت آن می‌باشد. لازم به ذکر است که به دلیل پتانسیل زیاد مدل LSTM در مواجهه شدن با تعداد زیادی از متغیرهای ورودی (مسائل دارای ابعاد بالا)، نیازی به پیش‌پردازش داده‌های ورودی قبل از مدل‌سازی با الگوریتم جنگل تصادفی جهت انتخاب مناسب‌ترین پیش‌بینی‌کننده‌ها نیست.

### شاخص‌های ارزیابی

دقت عملکرد پیش‌بینی مدل‌های LSTM و ANFIS با شاخص‌های ارزیابی ضریب همبستگی (R) (رابطه ۲)، مربع میانگین ریشه خطا (RMSE) (رابطه ۳)، Nash-Suiftclife (NSE) (رابطه ۴)، و مقدار بایاس یا سوگیری (Bias) (رابطه ۵) مورد بررسی قرار گرفت. هر چه مقادیر R و NSE به ۱ نزدیک‌تر باشد و هر چه مقادیر RMSE و MAE به صفر نزدیک‌تر باشد، دقت مدل‌های پیش‌بینی بهتر است.

1. Hochreiter
2. Schmidhuber
3. sliding window



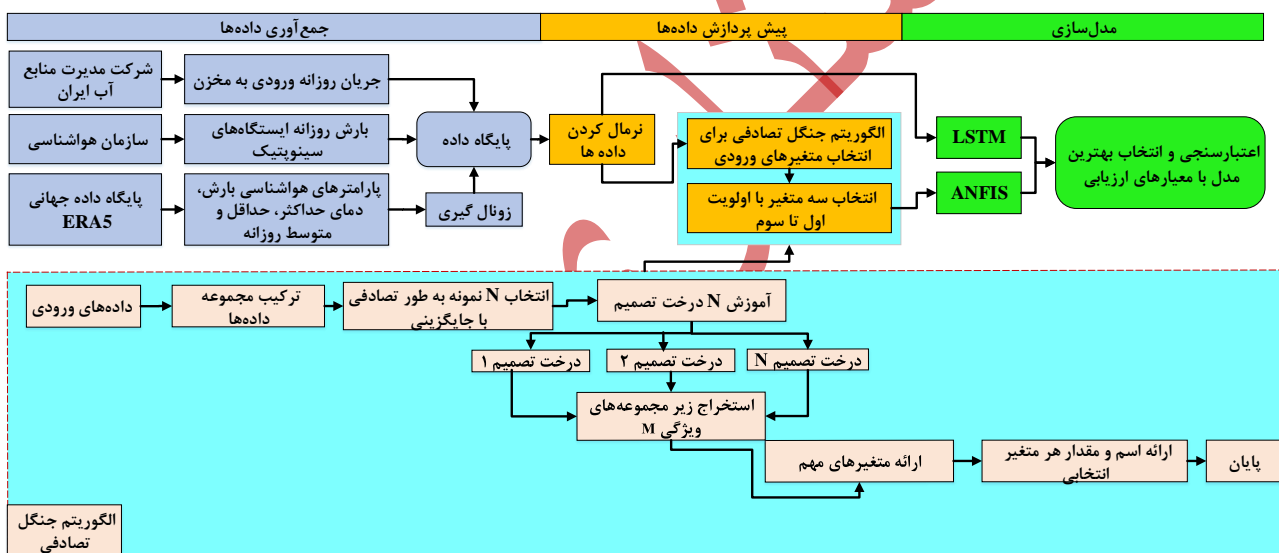
$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(F_i - \bar{F})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (F_i - \bar{F})^2}} \quad \text{رابطه ۲}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (F_i - O_i)^2}{N}} \quad \text{رابطه ۳}$$

$$NSE = 1 - \frac{\sum_{i=1}^N (O_i - F_i)^2}{\sum_{i=1}^N (O_i - \bar{F})^2} \quad \text{رابطه ۴}$$

$$Bias = \frac{\sum_{i=1}^N (F_i - O_i)}{\sum_{i=1}^N O_i} \quad \text{رابطه ۵}$$

در رابطه ۲ تا ۵،  $F_i$ : مقدار پیش‌بینی شده متغیر جریان،  $O_i$ : مقدار مشاهداتی متناظر با آن و  $N$ : تعداد جامعه آماری می‌باشد. در شکل ۳ نیز روندنمای مربوط به روش‌شناسی انجام این مطالعه ارائه شده است.



شکل ۴. روندنمای مربوط به مراحل مختلف انجام تحقیق

## نتایج و بحث

### سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)

در این بخش قبل از مدل‌سازی، ابتدا جهت انتخاب ورودی‌های مناسب از الگوریتم جنگل تصادفی استفاده شد. لازم به ذکر است که برای مدل‌سازی هر افق پیش‌بینی، چهار متغیر اولی که توسط الگوریتم جنگل تصادفی به عنوان متغیرهای پیش‌بینی کننده از بیشترین تاثیرگذاری تا کمترین تاثیرگذاری مرتب شده بودند، به عنوان متغیرهای ورودی پیش‌بینی کننده انتخاب شدند که نتایج آن در جدول ۴ ارائه شده است.

جدول ۴. متغیرهای پیش‌بینی کننده منتخب برای مخزن سیمره

افق پیش‌بینی (روز)	متغیر انتخاب شده توسط RF	افق پیش‌بینی (روز)	متغیر انتخاب شده توسط RF
۱	$Q_{t-1}$	۵	$Q_{t-2}$
	$P_{t-3}$		$T2_{t-2}$
	$P.st4_{t-3}$		

P.st5 <sub>t-1</sub>		P.st5 <sub>t-1</sub>	
Q <sub>t-1</sub>		Q <sub>t-1</sub>	
T2 <sub>t-3</sub>	۶	Q <sub>t-2</sub>	۲
P.st5 <sub>t-1</sub>		P.st5 <sub>t-1</sub>	
Pr <sub>t-1</sub>		Pr <sub>t-4</sub>	
Q <sub>t-2</sub>		Q <sub>t-1</sub>	
Tmin <sub>t-2</sub>	۷	Tmin <sub>t-3</sub>	۳
Pr <sub>t-1</sub>		P.st4 <sub>t-2</sub>	
T2 <sub>t-1</sub>		T2 <sub>t-2</sub>	
		Q <sub>t-1</sub>	
		P.st3 <sub>t-3</sub>	۴
		Pr <sub>t-3</sub>	
		Tmax <sub>t-2</sub>	

Q: جریان، P.sti: بارش ایستگاه، T2: دما در ارتفاع دو متری از سطح زمین، Tmax: دمای بیشینه، Tmin: دمای کمینه، Pr: بارش پایگاه داده





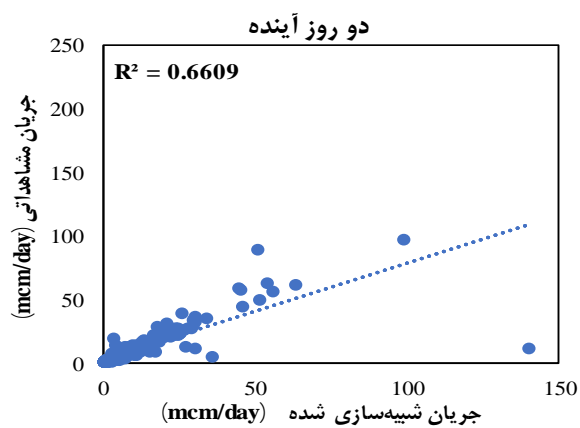

برای داشتن مدل سازی مناسب باید تک تک توابع عضویت را با سعی و خطا مورد بررسی قرار داد و با توجه به معیارهای ارزیابی مدل بهترین مدل را انتخاب نمود. با بررسی ترکیب های مختلف مدل عصبی فازی و انتخاب هر یک از انواع تابع های عضویت مربوط به پارامترهای ورودی و خروجی، در نهایت مشخصات (نوع توابع عضویت) و نتایج شاخص های ارزیابی مدل های انتخابی ANFIS برای افق پیش بینی یک تا هفت روز آینده در دو مرحله آموزش و آزمایش در جدول ۵ ارائه شده است.


جدول ۵. نتایج مدل های انتخابی ANFIS برای افق پیش بینی ۱ تا ۷ روز آینده

مقدار بایاس (mcm/day)	جذرمیانگین مربعات خطا (mcm/day)	ضریب همبستگی	ضریب نش	مرحله	تابع عضویت خروجی	تابع عضویت ورودی	افق پیش بینی
-۱۶/۹	۳/۱	۰/۹۵۰	۰/۸۸۷	آموزش			
-۱۹	۵/۳۳	۰/۹۰۲	۰/۸۵۸	آزمایش	constant	Trapmf	یک روز
۲/۹	۵/۷	۰/۹۱۱	۰/۸۲۷	آموزش			
۶/۸	۶/۹۰۴	۰/۸۱۳	۰/۶۴۶	آزمایش	constant	Gauss2mf	دو روز
۱۱/۱	۷/۷۳۶	۰/۸۴۰	۰/۶۸۹	آموزش			
۲۵/۱	۶/۳۸۸	۰/۷۶۶	۰/۶۴۶	آزمایش	constant	gbellmf	سه روز
۸/۶	۷/۷۱۱	۰/۸۲۸	۰/۶۸۰	آموزش			
۹	۸/۲۱۸	۰/۷۳۰	۰/۵۲۵	آزمایش	constant	Trapmf	چهار روز
۲۸/۸	۸/۹۸۹	۰/۷۷۶	۰/۵۷۶	آموزش			
۳۶/۶	۷/۸۷۲	۰/۷۵۰	۰/۴۹۷	آزمایش	constant	Trimf	پنج روز
۳/۲	۸/۷۴۳	۰/۷۶۸	۰/۵۸۹	آموزش			
۵/۶	۸/۸۹۹	۰/۶۷۴	۰/۴۴۵	آزمایش	constant	psigmf	شش روز
-۱۳/۸	۹/۵۹۱	۰/۶۷۷	۰/۴۵۱	آموزش			
-۹/۷	۱۱/۴۳۴	۰/۶۲۹	۰/۳۹۳	آزمایش	constant	gauss2mf	هفت روز

همان طور که در جدول مشخص است شاخص های ارزیابی ضریب نش، ضریب همبستگی، جذر میانگین مربعات خطا و مقدار سوگیری برای مدل های انتخابی در افق های پیش بینی یک تا هفت روز آینده ارائه شده است. بیشترین مقدار ضریب نش در مرحله آزمایش، مربوط به مدل انتخابی در افق پیش بینی یک روز آینده با مقدار ۰/۸۵۸ و کمترین مقدار آن مربوط به مدل انتخابی در افق پیش بینی هفت روز آینده با مقدار ۰/۳۹۳ می باشد. همچنین کمترین مقدار شاخص جذر میانگین مربعات خطا مربوط به افق پیش بینی یک روز آینده و برابر ۵/۳۳ میلیون مترمکعب در روز و بیشترین مقدار آن مربوط به افق پیش بینی هفت روز آینده با مقدار ۱۱،۴۳۴ میلیون مترمکعب در روز می باشد. به طور کلی هرچقدر که افق پیش بینی جلوتر می رود شاخص های ارزیابی نش و ضریب همبستگی کمتر و شاخص های جذر میانگین مربعات خطا و مقدار سوگیری بیشتر می شود و از دقت مدل ها کاسته می شود. در شکل ۵ مقایسه نتایج شبیه سازی مدل ANFIS با مقادیر مشاهداتی در مرحله آزمایش در افق های مختلف بررسی شده است و ضریب تبیین برای هر افق ارائه شده است. مطابق نمودارهای ارائه شده هرچقدر افق پیش بینی جلوتر می رود مقدار ضریب تبیین

کاسته می‌شود و عملکرد مدل در شبیه‌سازی مقادیر جریان فرارمال با خط همراه می‌شود و تعداد داده‌های پرت شبیه‌سازی شده بیشتر می‌شود.





شکل ۵. مقایسه نتایج مدل ANFIS با مقادیر مشاهداتی در مرحله آزمایش.

### نتایج حافظه کوتاه و بلند مدت (LSTM)

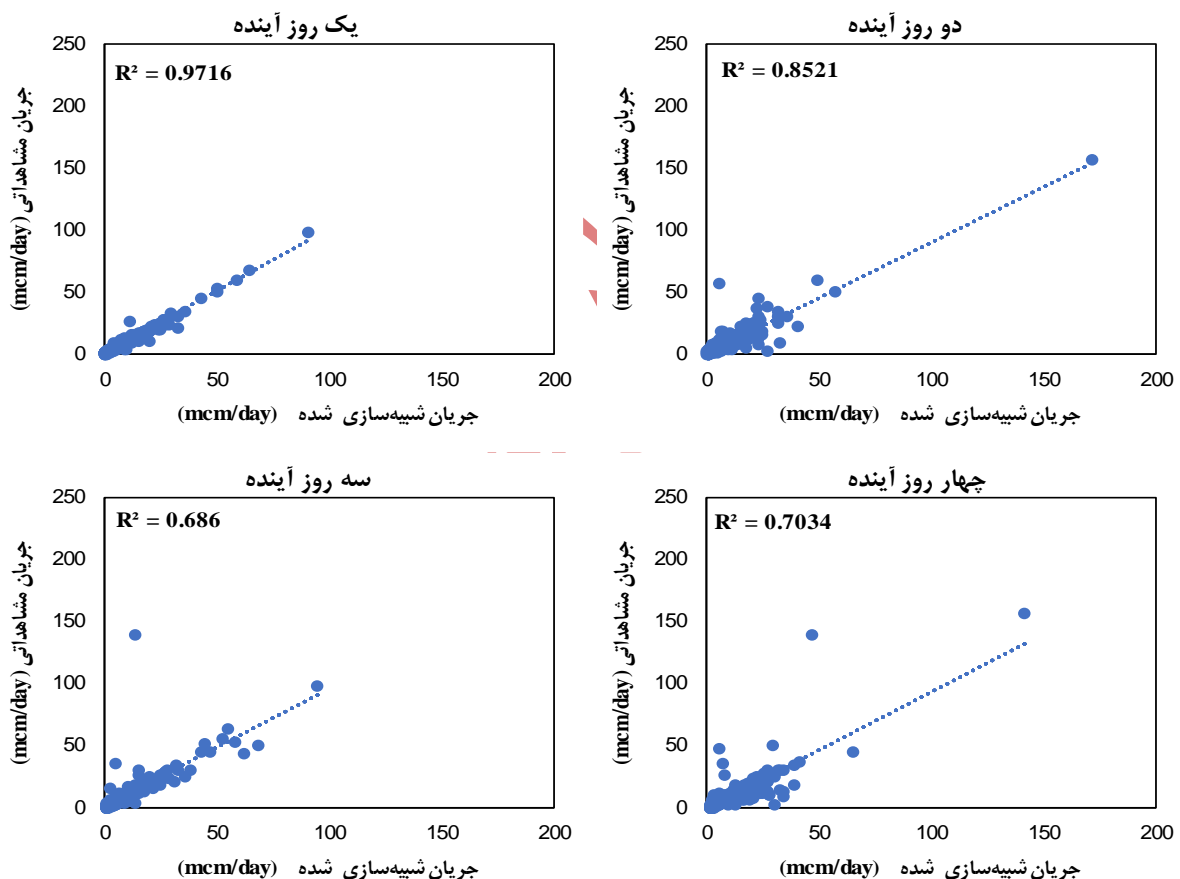
همان‌طور که قبلاً بیان شد مدل LSTM برای مدل‌سازی پتانسیل خوبی دارد و مانند مدل ANFIS جهت انتخاب ورودی‌های مدل نیاز به استفاده از الگوریتم خاصی ندارد. بلکه ماهیت این مدل طوری است که با توجه به معماری خاص و وجود پنجره‌های متحرک در آن، خود قادر است بهترین ورودی‌ها را برای هر مرحله انتخاب کند. برای پیش‌بینی جریان طولانی‌مدت (چند گام جلوتر)، روش پیش‌بینی بازگشتی، که آخرین پیش‌بینی یک گام جلوتر را به عنوان ورودی جدید برای پیش‌بینی گام بعدی می‌گیرد، در مدل پیش‌بینی LSTM استفاده می‌شود. در این مدل تأثیر سه پارامتر تعداد نرون‌ها (neroun)، تعداد دوره‌ها (Epochs) و تعداد دسته‌ها (Bach size) بررسی شده‌اند و با توجه به جایگشت‌های مختلف این سه پارامتر در هر بار مدل‌سازی، بصورت سعی و خطا معماری‌های مختلف مورد بررسی قرار گرفتند. به طوری که برای معماری‌های مختلف شبکه، تعداد نرون در هر لایه شامل مقادیر ۳، ۵، ۱۰ و ۱۵، تعداد دوره‌ها (Epochs) شامل مقادیر ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ و تعداد دسته‌ها شامل مقادیر ۵، ۱۰، ۲۰ و ۳۰ می‌باشد. در جدول ۶ مشخصات و معیارهای ارزیابی مدل‌های انتخابی LSTM برای افق پیس بینی ۱ تا ۷ روز آینده ارائه شده است.

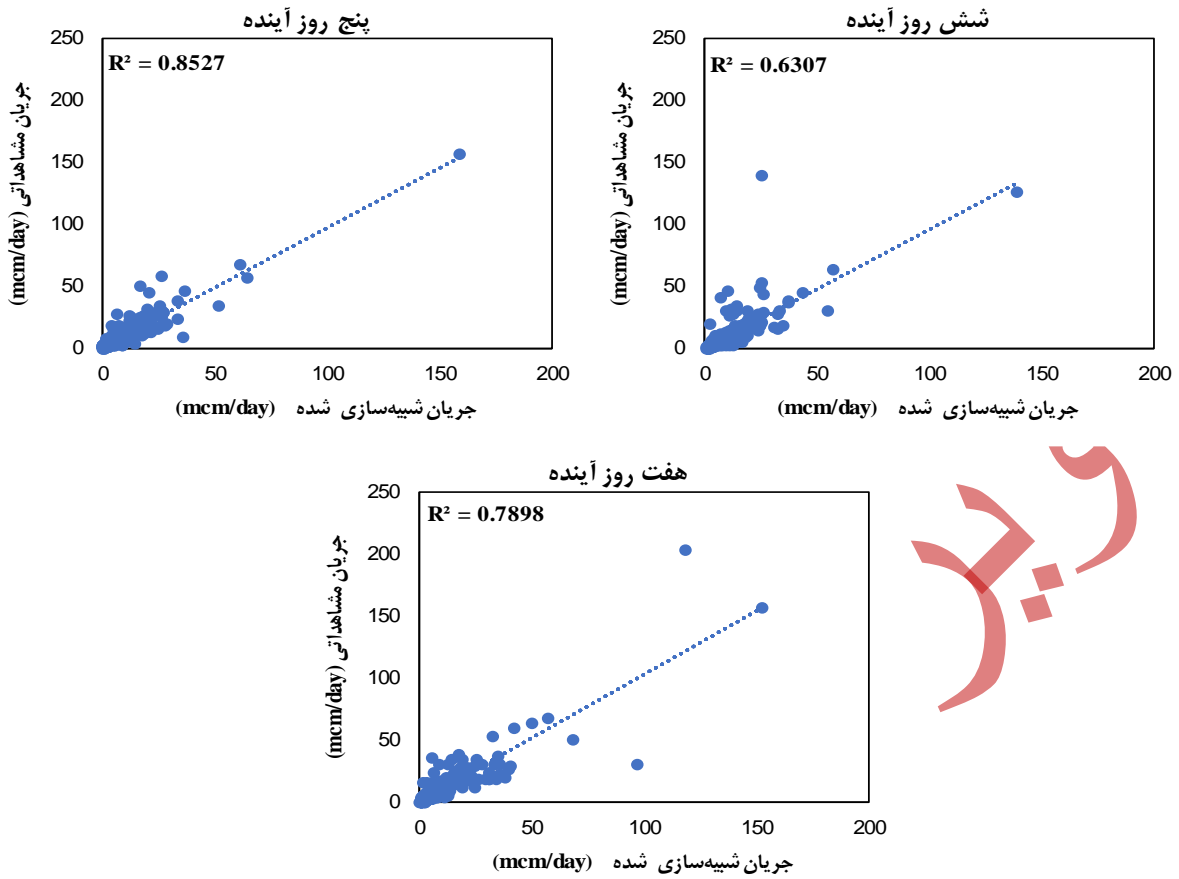
جدول ۶. مشخصات و معیارهای ارزیابی مدل‌های انتخابی LSTM برای افق پیس بینی ۱ تا ۷ روز آینده

مقدار بایاس (mcm/day)	جذر میانگین مربعات خطا (mcm/day)	ضریب همبستگی	ضریب نش	مرحله	Epoch	Bach size	تعداد نرون لایه دوم	تعداد نرون لایه اول	افق پیش‌بینی
-۳/۷	۲/۳۹۸	۰/۹۸۶	۰/۹۷۱	آموزش	۲۰۰	۱۰	۳	۱۵	یک روز
-۳/۵	۱/۵۷۳	۰/۹۸۶	۰/۹۷۱	آزمایش					
-۵/۶	۵/۶۸۰	۰/۹۱۴	۰/۸۳۲	آموزش	۲۰۰	۵	۳	۱۵	دو روز
۱/۸	۴/۳۰۶	۰/۹۲۳	۰/۸۳۹	آزمایش					
-۵/۵	۵/۱۴۷	۰/۹۳۲	۰/۸۵۹	آموزش	۲۰۰	۵	۱۰	۱۰	سه روز
-۳/۱	۶/۵۱۸	۰/۸۲۸	۰/۶۸۴	آزمایش					
۱۹/۱	۵/۰۲۸	۰/۹۳۹	۰/۸۶۴	آموزش	۲۰۰	۳۰	۱۵	۱۵	چهار روز
۲۱	۶/۷۰۴	۰/۸۳۹	۰/۶۸۴	آزمایش					
-۱۱/۹	۵/۱۶۶	۰/۹۳۳	۰/۸۶۰	آموزش	۱۵۰	۵	۱۰	۱۵	پنج روز
-۱۲/۵	۴/۳۸۳	۰/۹۲۳	۰/۸۴۴	آزمایش					
۸/۴	۴/۸۳۳	۰/۹۳۷	۰/۸۷۵	آموزش	۲۰۰	۲۰	۱۵	۱۵	شش روز
۵/۹	۷/۲۸۴	۰/۷۹۴	۰/۶۲۸	آزمایش					
-۱۰/۵	۵/۹۰۱	۰/۸۹۳	۰/۷۹۲	آموزش	۱۰۰	۵	۱۰	۱۵	هفت روز
-۷/۲	۶/۷۵۷	۰/۸۸۹	۰/۷۸۸	آزمایش					

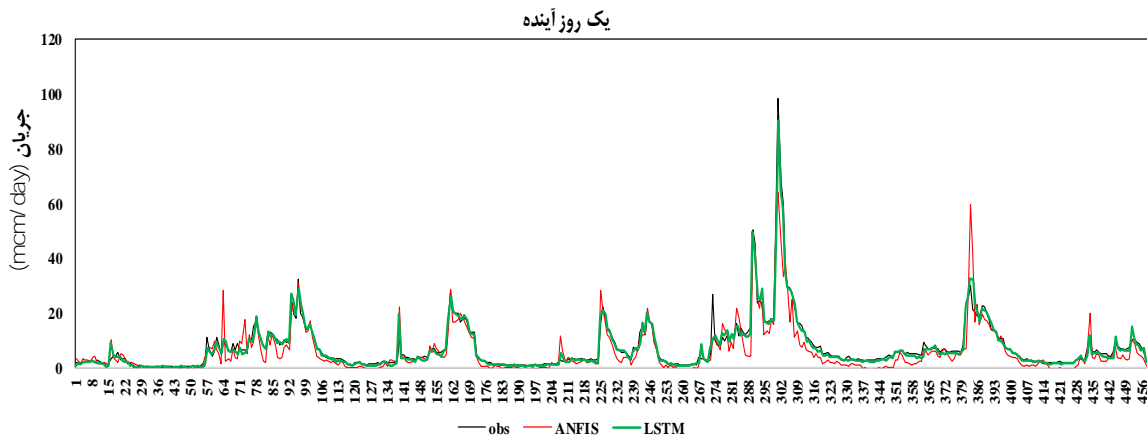
در جدول ۵ شاخص‌های ارزیابی ضریب نش، ضریب همبستگی، جذر میانگین مربعات خطا و مقدار سوگیری برای مدل‌های انتخابی در افق‌های پیش‌بینی یک تا هفت روز آینده ارائه شده است. بیشترین مقدار ضریب نش در مرحله آزمایش، مربوط به مدل انتخابی در افق پیش‌بینی یک روز آینده با مقدار ۰/۹۷۱ و کمترین مقدار آن مربوط به مدل انتخابی در افق پیش‌بینی شش روز آینده با مقدار ۰/۶۲۸ می‌باشد. همچنین کمترین مقدار شاخص جذر میانگین مربعات خطا مربوط به افق پیش‌بینی یک روز آینده و برابر ۱/۵۷ میلیون مترمکعب در روز و بیشترین مقدار آن مربوط به افق پیش‌بینی شش روز آینده با مقدار ۷/۲۸۴ میلیون مترمکعب در روز می‌باشد. عملکرد خوب LSTM حاکی از پتانسیل بالای مدل در شبیه‌سازی و پیش‌بینی جریان در گام‌های زمانی روبه‌جلو، به دلیل ماهیت آن و وجود پنجره‌های متحرک جهت انتخاب داده‌های ورودی مؤثر در هر مرحله مدل‌سازی می‌باشد.

در شکل ۶ مقایسه نتایج شبیه‌سازی مدل LSTM با مقادیر مشاهداتی در مرحله آزمایش در افق‌های مختلف بررسی شده است و ضریب تبیین برای هر افق پیش‌بینی ارائه شده است. مطابق نمودارهای ارائه شده مقادیر ضریب تبیین از روند خاصی پیروی نمی‌کند. عملکرد مدل‌ها در افق یک، دو و پنج روز آینده نسبت به سایر افق‌ها بهتر بوده است و در شبیه‌سازی مقادیر جریان فراتر مال به خوبی عمل کرده است. به‌طور کلی در تمامی افق‌های پیش‌بینی تعداد داده‌های پرت شبیه‌سازی شده قابل توجه نیست.







شکل ۶. مقایسه نتایج مدل LSTM با مقادیر مشاهده‌اتی در مرحله آزمایش پس از انتخاب بهترین مدل برای افق‌های پیش‌بینی یک تا هفت روز آینده، نتایج حاصل از جریان شبیه‌سازی شده در مرحله آزمایش توسط مدل‌های ANFIS و LSTM و جریان مشاهده‌اتی در افق‌های پیش‌بینی مختلف در شکل ۷ نشان داده شده است.



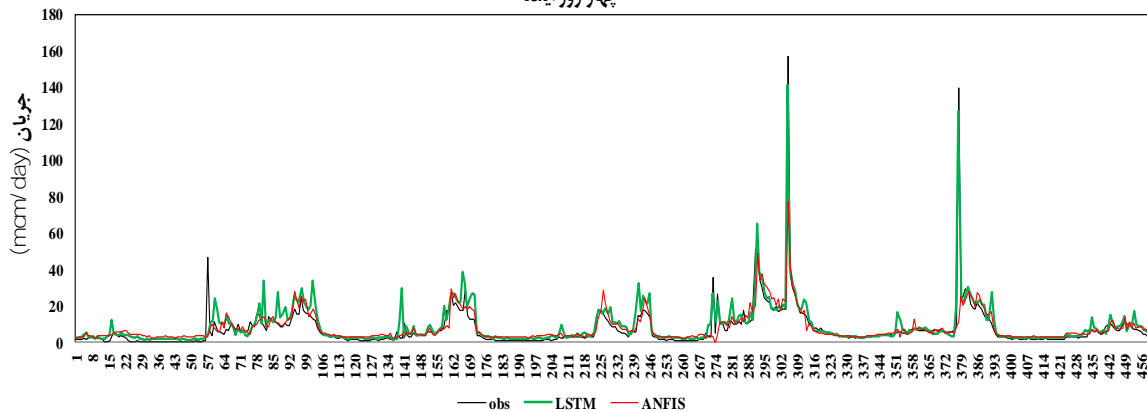
دو روز آینده




سه روز آینده

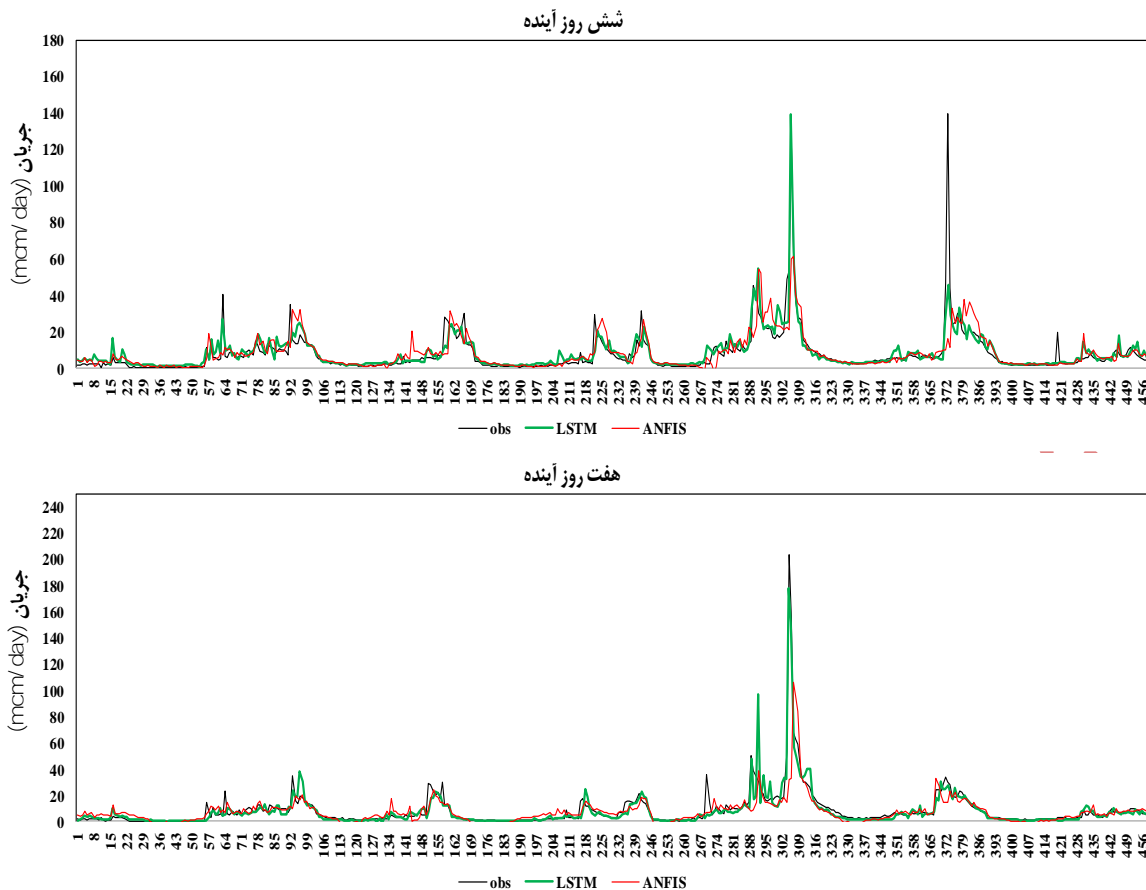


چهار روز آینده



پنج روز آینده





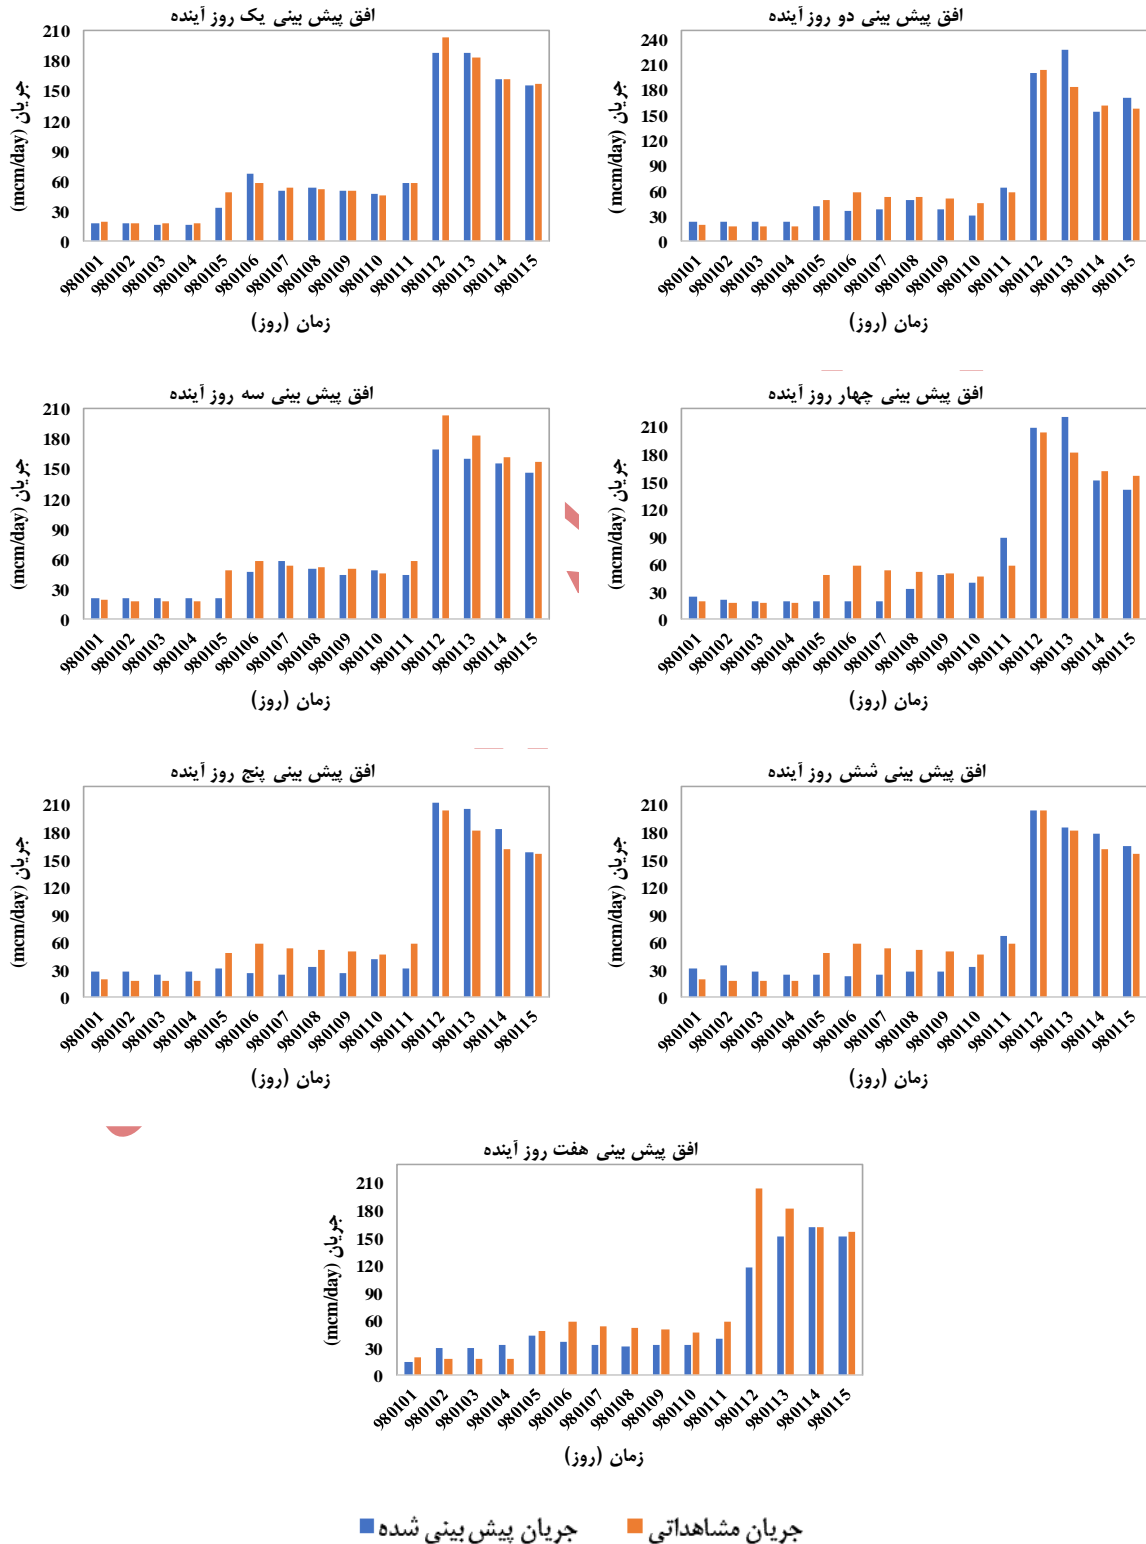
شکل ۷. جریان شبیه‌سازی شده توسط مدل‌های ANFIS و LSTM و جریان مشاهداتی در افق پیش‌بینی یک تا هفت روز آینده- مرحله آزمایش

مطابق شکل ۷ جریان شبیه‌سازی شده توسط مدل ANFIS در افق پیش‌بینی یک و دو روز آینده در چند مورد بیش برآورد بوده است. در افق پیش‌بینی سه روز آینده برای مقادیر جریان پایین، بیش برآورد و برای مقادیر جریان بالا، کم برآورد بوده است. در افق‌های پیش‌بینی چهار، پنج، شش و هفت روز آینده برای جریان‌های فرانرمال کم برآورد بود است. به‌طور کلی هرچقدر افق جلوتر می‌رود دقت شبیه‌سازی کاسته می‌شود. همچنین جریان شبیه‌سازی شده توسط مدل LSTM در افق پیش‌بینی یک و دو روز آینده به‌خوبی شبیه‌سازی شده اما در بعضی موارد اندکی بیش برآورد است. در افق پیش‌بینی سه، پنج، شش و هفت روز آینده نسبت چهار روز آینده بهتر شبیه‌سازی شده است. همچنین در همه‌ی افق‌های پیش‌بینی، مقادیر بیشینه جریان با دقت بیشتری نسبت به ANFIS شبیه‌سازی شده است. در خصوص جریان شبیه‌سازی شده با مدل LSTM در این مورد مطالعاتی، نمی‌توان گفت که هرچقدر افق جلوتر می‌رود دقت شبیه‌سازی کاسته می‌شود. به‌طوری‌که در افق پیش‌بینی هفت روز آینده شبیه‌سازی جریان بهتر از افق شش روز آینده شده است. به‌طور کلی مدل LSTM در شبیه‌سازی جریان‌های فرانرمال و سیلابی عملکرد خوبی دارد. در نهایت می‌توان نتیجه گرفت که عملکرد مدل LSTM در افق‌های پیش‌بینی چند گام روبه‌جلو نسبت به ANFIS بهتر است و برای پیش‌بینی‌های عملیاتی و استفاده از نتایج آن جهت برنامه‌ریزی و مدیریت بهره‌برداری از مخازن در شرایط بحرانی مانند سیلاب بهتر است که از آن استفاده شود. به همین دلیل جهت بررسی دقیق‌تر عملکرد مدل LSTM و ثابت کردن این ادعا که این مدل برای پیش‌بینی در شرایط سیلابی مناسب است یا خیر؟ عملکرد مدل‌های انتخابی برای افق‌های پیش‌بینی یک تا هفت روز آینده برای پیش‌بینی جریان ورودی به سد سیمره و مقایسه آن با جریان‌های ثبت‌شده آن در سیلاب فروردین ۹۸ مورد ارزیابی قرار گرفت.



## ارزیابی عملکرد مدل انتخابی در سیلاب ۹۸

در این بخش عملکرد مدل LSTM در شرایط سیلابی و فرانرمال سنجیده می‌شود. از این رو با توجه به اینکه در نیمه اول فروردین ۹۸ در حوضه آبریز کرخه سیلاب بزرگی رخ داده است، مقدار جریان ورودی به مخزن سیمره در بازه اول تا ۱۵ فروردین ماه با استفاده از مدل LSTM پیش‌بینی شد و با جریان ثبت‌شده در این ۱۵ روز مقایسه شده است و نتایج آن به صورت نمودار میله‌ای در شکل ۸ ارائه شده است.



همان‌طور که در شکل ۸ مشخص است، مدل LSTM با دقت قابل قبولی تا ۷ روز آینده، جریان‌های سیلابی و فرارمال را به مخزن سیمره پیش‌بینی کرده است و پتانسیل خود را به‌خوبی نشان داده است. در افق پیش‌بینی یک روز آینده جریان‌های سیلابی با دقت بیشتری پیش‌بینی شده‌اند. در افق پیش‌بینی دو روز آینده هم جریان‌های سیلابی با دقت بالایی پیش‌بینی شده‌اند فقط در روز سیزدهم اندکی مدل بیش برآورد بوده است. در افق پیش‌بینی هفت روز آینده در طول ۱۵ روز اول فروردین مدل کم برآورد بوده است. بر اساس مطالعات انجام‌شده انتظار می‌رود که هرچقدر که افق پیش‌بینی جلوتر رود دقت برآورد جریان کاهش یابد ولی با توجه ماهیت مدل LSTM و وجود پنجره‌های متحرک در آن، این کاهش دقت چشم‌گیر نیست و مدل توانایی پیش‌بینی خود را تا ۷ روز آینده به‌خوبی نشان داده است.

## نتیجه‌گیری

در این مطالعه استفاده از روش‌های یادگیری ماشین برای پیش‌بینی جریان ورودی روزانه به مخزن با تأکید بر پیشرفت‌های اخیر در این حوزه بررسی شده است. این روش‌ها به‌عنوان ابزارهای مؤثری در بهره‌برداری بهینه از منابع آب و مدیریت مخازن مورد استفاده قرار می‌گیرند و می‌توانند بهبود قابل توجهی در عملکرد بهره‌برداری از مخازن ایجاد کنند. از این رو قابلیت‌های پیش‌بینی چند گام جلوتر در مدل‌های LSTM و ANFIS در مقیاس روزانه بررسی شد. تأثیر انتخاب پارامترها (تعداد نرون‌ها در هر لایه، تعداد دوره‌ها و تعداد دسته‌ها) و (نوع توابع عضویت ورودی و خروجی) به ترتیب بر عملکرد مدل‌ها نیز در مدل‌سازی LSTM و ANFIS بررسی شده است. مدل‌های پیشنهادی برای مخزن سیمره واقع در حوضه آبریز کرخه و عملکرد مدل انتخابی جهت پیش‌بینی در سیلاب ۹۸ بررسی شد. به‌طور کلی، نتایج نشان می‌دهد که روش LSTM در شبیه‌سازی جریان روزانه ورودی به مخزن سیمره برای افق پیش‌بینی چند گام جلوتر برتر از روش ANFIS است. به‌طوری‌که بیشینه و کمینه مقدار ضریب نش در افق پیش‌بینی تا هفت روز آینده به ترتیب برای مدل LSTM برابر ۰/۹۷۱ و ۰/۶۲۸ و برای مدل ANFIS برابر ۰/۸۵۸ و ۰/۳۹۳ می‌باشد. ماهیت مدل LSTM طوری است که تا چند گام زمانی جلوتر را با دقت خوبی پیش‌بینی کند، به‌طوری‌که شاخص‌های ارزیابی نش، ضریب همبستگی و ضریب تبیین در گام‌های زمانی جلوتر افت چندانی نداشته‌اند. در پیش‌بینی جریان روزانه ورودی به مخزن سیمره تا افق پیش‌بینی هفت روز آینده در بازه سیلاب ۹۸، مدل LSTM عملکرد خوبی دارد و جریان پیش‌بینی شده توسط آن تطابق نسبتاً خوبی با جریان مشاهداتی، به‌ویژه برای جریان‌های فرارمال و سیلابی به دست می‌آورد. تعداد نرون‌ها در هر لایه، تعداد دوره‌ها و تعداد دسته‌ها تأثیر زیادی بر عملکرد پیش‌بینی مدل LSTM در مقیاس‌های روزانه دارد. این نشان می‌دهد که انتخاب پارامترهای مؤثر، می‌تواند برای افزایش دقت پیش‌بینی طولانی‌مدت مدل‌های یادگیری ماشین مؤثر باشد. نتایج مطالعه حاضر با سایر مطالعاتی که در زمینه پیش‌بینی جریان ورودی به سد و رواناب در حوضه‌های آبریز با استفاده از مدل LSTM انجام شده، مطابقت دارد (Man et al., 2023; Khorram and Jehbez, 2023; Han et al., 2021; Lee and Kim, 2021; Qi et al., 2019). به‌طوری‌که نتایج این مطالعات به پتانسیل بالای LSTM در پیش‌بینی جریان اشاره داشته است. این مطالعه می‌تواند به مدیران منابع آب بینشی برای مدیریت کارآمد و برنامه‌ریزی و تخلیه روزانه مخزن در بهره‌برداری در زمان واقعی از مخازن ارائه دهد. پیشنهاد می‌شود عملکرد مدل LSTM در این زمینه، برای افق‌های پیش‌بینی طولانی‌تر ارزیابی و با سایر مدل‌های یادگیری ماشین مقایسه شود.

## منابع

صمدی بروجنی، حسین؛ و استادعلی عسکری، منصور. (۱۳۸۷). پیش‌بینی زمان واقعی جریان ورودی روزانه به مخزن سد کارون ۳ با تلفیق روش اتورگرسیو و پیش‌بینی‌های بارندگی. *تحقیقات منابع آب ایران*، ۴(۲)، ۱۴-۲۲.

شاه‌کرمی، نازنین؛ ثانی‌خانی، هادی؛ و مرادی، مجتبی. (۱۳۹۴). پیش‌بینی جریان ورودی به مخزن سد کمال صالح با استفاده از محاسبات نرم. *نشریه علمی پژوهشی مهندسی آبیاری و آب ایران*، ۱۶(۱)، ۴۸-۶۱.

موسوی ندوشنی، سید سعید؛ بنی حبیب، محمد ابراهیم؛ و بندری، ریحانه. (۱۳۹۰). پیش بینی جریان روزانه ورودی به مخزن سد دز با استفاده از مدل های سری زمانی. *یازدهمین سمینار سراسری آبیاری و کاهش تبخیر، کرمان*, <https://civilica.com/doc/157849>

میثاقی، فرهاد. (۱۳۹۵). پیش بینی جریان ورودی به سد علویان با استفاده از سامانه تطبیقی فازی-عصبی بهینه شده. *تحقیقات آب و خاک ایران*, ۴۷(۳), ۴۳۹-۴۴۸.

هیأت ویژه گزارش ملی سیلاب ها. (۱۳۹۸). کارگروه هیدرولوژی و منابع آب، کمیته مدیریت مخازن.

## REFERENCES

- Babaei, M., Moeini, R., & Ehsanzadeh, E. (2019). Artificial neural network and support vector machine models for inflow prediction of dam reservoir (case study: Zayandehroud dam reservoir). *Water Resources Management*, 33, 2203-2218.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24, 123-140.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Cheng, M., Fang, F., Kinouchi, T., Navon, I. M., & Pain, C. C. (2020). Long lead-time daily and monthly streamflow forecasting using machine learning methods. *Journal of Hydrology*, 590, 125376.
- Dehghani, M., Saghafian, B., Rivaz, F., & Khodadadi, A. (2015). Monthly stream flow forecasting via dynamic spatio-temporal models. *Stochastic environmental research and risk assessment*, 29, 861-874.
- Fathian, F., Mehdizadeh, S., Sales, A. K., & Safari, M. J. S. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models. *Journal of Hydrology*, 575, 1200-1213.
- Han, H., Choi, C., Jung, J., & Kim, H. S. (2021). Application of sequence to sequence learning based LSTM model (LSTM-s2s) for forecasting dam inflow. *Journal of Korea Water Resources Association*, 54(3), 157-166.
- Hochreiter, S., Schmidhuber, J., (1997). Long short-term memory. *Neural Comput.* 9, 1735-1780.
- 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.
- Hu, R., Fang, F., Pain, C. C., & Navon, I. M. (2019). Rapid spatio-temporal flood prediction and uncertainty quantification using a deep learning method. *Journal of Hydrology*, 575, 911-920.
- Khorram, S., & Jehbez, N. (2023). A hybrid CNN-LSTM approach for monthly reservoir inflow forecasting. *Water Resources Management*, 37(10), 4097-4121.
- Kişî, Ö. (2009). "Evolutionary fuzzy models for river suspended sediment concentration estimation." *Journal of Hydrology*. 372(1-4): 68-79.
- 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.
- Kumar, S., Tiwari, M. K., Chatterjee, C., & Mishra, A. (2015). Reservoir inflow forecasting using ensemble models based on neural networks, wavelet analysis, and bootstrap method. *Water resources management*, 29(13), 4863-4883.
- Latif, S. D., Ahmed, A. N., Sathiamurthy, E., Huang, Y. F., & El-Shafie, A. (2021). Evaluation of deep learning algorithm for inflow forecasting: a case study of Durian Tunggal Reservoir, Peninsular Malaysia. *Natural Hazards*, 109(1), 351-369.
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Water*, 11(7), 1387.
- Lee, S., & Kim, J. (2021). Predicting inflow rate of the Soyang river dam using deep learning techniques. *Water*, 13(17), 2447.
- Man, Y., Yang, Q., Shao, J., Wang, G., Bai, L., & Xue, Y. (2023). Enhanced LSTM model for daily runoff prediction in the upper Huai River Basin, China. *Engineering*, 24, 229-238.
- Milly, P. C., Dunne, K. A., & Vecchia, A. V. (2005). Global pattern of trends in streamflow and water availability in a changing climate. *Nature*, 438(7066), 347-350.
- Misaghi, F. (2016). Forecasting of the Alavian Dam Inflow Water Using Optimized Adaptive Neuro-Fuzzy Inference System (OANFIS). *Iranian Journal of Soil and Water Research*, 47(3), 439-448. (In Persian).
- Mouatadid, S., Adamowski, J. F., Tiwari, M. K., & Quilty, J. M. (2019). Coupling the maximum overlap discrete wavelet transform and long short-term memory networks for irrigation flow forecasting. *Agricultural Water Management*, 219, 72-85.
- Mousavi Nadushni, S. S., BaniHabib, M. E., & Bandari, R. (2013). prediction of daily inflow Dez dam reservoir using time series models, 11th National Seminar on Irrigation and Evaporation Reduction, Kerman, <https://civilica.com/doc/157849>. (In Persian).
- Mousavi, S. F., & Mahjoobi, J. (2019). Real-time streamflow prediction for optimal water resource management: Challenges and advances. *Journal of Hydrology*, 123(4), 567-581. <https://doi.org/10.1016/j.jhydrol.2019.08.015>

- National Flood Report Special Committee (2019), Hydrology and Water Resources Working Group, Reservoir Management Committee. (In Persian).
- Nayak, P. C., K. P. Sudheer, D. M. Rangan & K. S. Ramasastri, (2004). "A neuro-fuzzy computing technique for modeling hydrological time series." *Journal of Hydrology* 291(1–2): 52-66.
- Ni, L., Wang, D., Singh, V. P., Wu, J., Wang, Y., Tao, Y., & Zhang, J. (2020). Streamflow and rainfall forecasting by two long short-term memory-based models. *Journal of Hydrology*, 583, 124296.
- Noorbeh, P., Roozbahani, A., & Kardan Moghaddam, H. (2020). Annual and monthly dam inflow prediction using Bayesian networks. *Water Resources Management*, 34, 2933-2951.
- Nourani, V. & M. Komasi (2013). "A geomorphology-based ANFIS model for multi-station modeling of rainfall–runoff process." *Journal of Hydrology* 490: 41-55.
- Nourani, V. (2017). An emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology*, 544, 267-277.
- Nourani, V., & Komasi, M. (2013). A geomorphology-based ANFIS model for multi-station modeling of rainfall–runoff process. *Journal of Hydrology*, 490, 41-55.
- Nourani, V., & Partoviyan, A. (2018). Hybrid denoising-jittering data pre-processing approach to enhance multi-step-ahead rainfall–runoff modeling. *Stochastic environmental research and risk assessment*, 32(2), 545-562.
- Olah, C. (2015). Understanding LSTM Networks Browning KA, Collier CG (1989) Nowcasting of precipitation systems. *Rev Geophys* 27:345– 370. <https://doi.org/10.1029/RG027i003p00345>.
- Qi, Y., Zhou, Z., Yang, L., Quan, Y., & Miao, Q. (2019). A decomposition-ensemble learning model based on LSTM neural network for daily reservoir inflow forecasting. *Water Resources Management*, 33, 4123-4139.
- Ross, T. J. (1995). Fuzzy logic with engineering application. McGraw Hill Inc., USA,.
- Samadi Borojni, H. & Ostad Ali Askari, Mansour. (2008). Real-time forecasting of daily inflow to the reservoir of Karun Dam 3 by combining the autoregressive method and rainfall forecasts. *Iran Water Resources Research*, 4(2), 14-22. (In Persian).
- Shahkarami, N., Sanikhani, H., & Moradi, M. (2016). Prediction of inflow to Kamal Saleh dam reservoir using soft calculations. *Scientific Journal of Irrigation and Water Engineering of Iran*, 6(2), 48-61. (In Persian).
- Sun, F., & Burian, S. J. (2016). Enhancing the accuracy of daily streamflow predictions using machine learning models. *Journal of Hydrology*, 540, 225-237.
- Xiao, Z., Liang, Z., Li, B., Hou, B., Hu, Y., & Wang, J. (2019). New flood early warning and forecasting method based on similarity theory. *Journal of Hydrologic Engineering*, 24(8), 04019023.
- Yaseen, Z. M., El-Shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530, 829-844.
- Zhang, X., Wang, H., Peng, A., Wang, W., Li, B., & Huang, X. (2020). Quantifying the uncertainties in data-driven models for reservoir inflow prediction. *Water Resources Management*, 34(4), 1479-1493.

# Evaluating the Performance of the LSTM Model in Forecasting Daily Inflow the Dam Reservoirs

## Extended Abstract

### Background and purpose

Real-time forecasting of daily inflows to reservoirs with a prediction horizon that extends several steps into the future is crucial for water resource planning and management. Despite numerous studies on inflow prediction using machine learning methods, few have investigated the predictive capabilities of these approaches with long lead time (several steps ahead) or gained insights through systematic comparisons of model predictive performance in the short term. Therefore, in the present study, an advanced type of recurrent neural network called the LSTM model has been introduced to predict the daily inflow to dam reservoirs, addressing the flaws and defects of previously used methods. LSTM is a type of deep learning neural network that uses complex and combined functions instead of simple functions to regulate and strengthen short-term memory. By optimally setting modeling parameters such as the number of neurons in each layer, the number of iterations, and the number of categories, the LSTM model has a high potential for long-term prediction. Therefore, the purpose of this research is to evaluate the efficiency of and compare the machine learning models of the Adaptive Neuro-Fuzzy Inference System (ANFIS) and the Long Short-Term Memory (LSTM) network in predicting the daily inflow to dam reservoirs. Subsequently, the inflow to the Seimareh reservoir is modeled using these methods, with a particular focus on long-term forecasting (7 days ahead). Finally, the superior model is used to predict the inflow to the reservoir under flood conditions.

### Materials and methods

The stages of the research include three main parts: data collection, data pre-processing, and modeling. First, the effectiveness of the Adaptive Neuro-Fuzzy Inference System (ANFIS) model and the Long Short-Term Memory (LSTM) network was evaluated to predict the daily inflow to the Seimareh reservoir in the Karkheh basin, for a forecast horizon of the next 7 days. For this purpose, daily data on precipitation, temperature, and inflow to Seimareh from 2012 to 2018 were used for modeling. Then, using the superior model that is selected based on the evaluation indicators, the daily inflow to the Seimareh reservoir was forecasted for the next 7 days during the flood of 2019.

### Findings

In this section, the evaluation indices of the Nash coefficient, correlation coefficient, root mean square error, and bias value for selected models in the forecast horizons of one to seven days are presented. For the ANFIS model, the further the prediction horizon extends, the lower the value of the explanation coefficient, leading to decreased performance in simulating abnormal flow values and an increase in the number of simulated outliers. Regarding the flow simulated with the LSTM model in this case study, it cannot be said that the accuracy of the simulation decreases as the horizon extends. For instance, in the forecast horizon of the next seven days, the flow simulation is better than that for the next six days, and the performance of the model for one, two, and five days is better than for the other horizons. In general, the LSTM model has performed well in simulating abnormal flow values, and the number of simulated outliers is not significant across all forecast horizons.

### Conclusion

The results showed that the performance of the LSTM model is better than that of ANFIS in daily forecasting several steps ahead. The maximum and minimum values of the Nash coefficient in the forecast horizon for the next seven days were 0.971 and 0.628, respectively, for the LSTM model, and 0.858 and 0.393 for the ANFIS model. The optimal setting of parameters, including the number of neurons in each layer, the number of iterations, and the number of categories in the LSTM model, is key to the model's high potential to predict flow up to the forecast horizon of the next seven days. Finally, the performance of the LSTM model in predicting the inflow to Seimareh during the flood of 2019 was evaluated, and it was found to predict the flood flows with acceptable accuracy up to the forecast horizon of the next 7 days. This study can provide valuable insights to water resource managers for planning and managing daily reservoir discharge in real-time operations. findings show that the LSTM model is suitable for forecasting daily flow. Therefore, it can be used to aid strategic decisions in the management of water resources, especially under flood conditions.

Keywords: *daily reservoir inflow forecast, flood management, long lead-time forecast, machine learning.*