

Performance comparison of Artificial Intelligence models with IHACRES model in streamflow modeling of the Gamasiab River catchment

Sadegh Momeneh ^{1*} 

¹ Graduated M.Sc. Student, Department of Civil Engineering, Faculty of Technical Engineering, Razi University, Kermanshah, Iran

Abstract

Introduction

Today due to climate change and fluctuations in the intensity and duration of rainfall in most parts of the world, new approaches to streamflow modeling have an extraordinary role in managing water resources and reducing the risks of floods. Since in some catchments, it is not feasible to measure all the observed quantities required for modeling the streamflow process, it is necessary to choose a simple model that can accurately predict rainfall-runoff using minimal information. Artificial intelligence (AI) models have high efficiency, especially when the accurate estimation of processes is more important than understanding the mechanisms and relationships that create them. Therefore, the AI models and semi-conceptual IHACRES models are used for streamflow modeling and compared with each other. In this study, streamflow modeling for the Gamasiab River, located in western Iran, is presented.

Materials and Methods

For rainfall-runoff modeling, artificial intelligence (AI) models include artificial neural network (ANN) models of type multi-layer perceptron (MLP), radial basis function neural network (RBF), and long short-term memory model (LSTM) are used. In addition, to better evaluate the AI models, a specialized semi-conceptual rainfall-runoff model called IHACRES is used. The data used in this study include daily data of flow discharge, precipitation, and average temperature for 31 years (September 23, 1986 - September 22, 2017), which is a time series of delayed data and as an input signal used to models. To evaluate the performance of the models, some criteria including Nash-Sutcliffe efficiency coefficient (NSE), root mean square error (RMSE), and correlation coefficient (R) were used.

Results and Discussion

The results show better performance of ANN, RBF, and LSTM models than the IHACRES model, especially at the peak flow rate, in modeling daily streamflow for the study area. The IHACRES model has performed well in calm and medium flows but has not performed well at flow peaks. In addition, the LSTM model performed better than the other models in estimating the flow rate during the verification period, while the ANN and RBF models performed better than the other models in the calibration phase. Overall, the results indicate that the best data-based model (i.e., LSTM model) has more than twice as good performance in streamflow modeling as the semi-conceptual IHACRES model based on RMSE criteria. In general, the results showed that artificial intelligence models are valuable tools for modeling streamflow fluctuations.

Conclusion

The AI models including, ANN, RBF, and LSTM models, especially in estimating flow peaks, were significantly better than the IHACRES model. The IHACRES model has performed well in calm river streamflow and low and medium discharge but has not performed well at flow peaks. In general, is recommended the LSTM model for modeling the daily streamflow of the study area due to better performance. AI models can model the streamflow more accurately and provide more efficient management of water resources in different regions. In general, the results showed that various AI models are a suitable tool in streamflow modeling, and it suggested that they be more utilized in future research.

Keywords: Artificial intelligence; Artificial neural network; IHACRES model; Gamasiab watershed; Streamflow modeling.

Article Type: Research Article

*Corresponding Author, E-mail: sadeghmomeneh@gmail.com

Citation: Momeneh, S. (2022). Performance comparison of Artificial Intelligence models with IHACRES model in daily streamflow modeling. *Water and Soil Management and Modeling*, 2(3), 1-16.

DOI: 10.22098/MMWS.2022.9972.1076

DOR: 20.1001.1.27832546.1401.2.3.1.0

Received: 09 December 2021, Received in revised form: 15 January 2022, Accepted: 20 January 2022, Published online: 30 March 2022

Water and Soil Management and Modeling, Year 2022, Vol. 2, No. 3, pp. 1-16

Publisher: University of Mohaghegh Ardabili

© Author(s)





مقایسه عملکرد مدل‌های هوش مصنوعی با مدل IHACRES در مدل‌سازی جریان حوضه آبریز رودخانه گاماسیاب

صادق مؤمنه^{*۱}

^۱ دانش‌آموخته کارشناسی ارشد مهندسی عمران، گرایش مهندسی و مدیریت منابع آب، دانشکده فنی مهندسی، دانشگاه رازی، کرمانشاه، ایران

چکیده

امروزه رویکردهای جدید مدل‌سازی جریان به دلیل تغییرات اقلیمی و نوسانات شدت و مدت بارش در اکثر مناطق جهان، برای مدیریت منابع آب و کاهش خطرات ناشی از بروز سیلاب نقش فوق‌العاده‌ای دارند. در این پژوهش، به مدل‌سازی جریان برای حوضه آبریز رودخانه گاماسیاب، واقع در غرب ایران، پرداخته شده است. برای این منظور از مدل‌های هوش مصنوعی (AI) شامل، مدل‌های شبکه عصبی مصنوعی (ANN) از نوع پرسپترون چندلایه (MLP)، شبکه عصبی تابع پایه شعاعی (RBF) و مدل حافظه طولانی کوتاه-مدت (LSTM) استفاده شده است. علاوه بر این برای ارزیابی بهتر مدل‌های AI از یک مدل تخصصی نیمه مفهومی بارش-رواناب نیز با عنوان IHACRES بهره گرفته شد. داده‌های مورد استفاده شامل، داده‌های دبی جریان، بارش و متوسط دمای روزانه برای یک دوره زمانی ۳۱ سال (۱ مهر ۱۳۶۵-۳۱ شهریور ۱۳۹۶) که به صورت سری زمانی داده‌های با تأخیر و به‌عنوان سیگنال ورودی به مدل‌ها استفاده شده است. جهت ارزیابی عملکرد مدل‌ها از معیار ضریب کارایی نش-ساتکلیف (NSE)، مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) استفاده شد. نتایج به‌دست‌آمده براساس معیار NSE برای مدل‌های LSTM، RBF، ANN و IHACRES در دوره صحت‌سنجی به ترتیب برابر مقادیر ۰/۹۳۰، ۰/۹۰۷، ۰/۹۰۳ و ۰/۵۱۲ است. بنابراین، مدل LSTM عملکرد بهتری در دوره صحت‌سنجی نسبت به سایر مدل‌ها در تخمین دبی جریان ارائه کرد. در ضمن، نتایج به‌دست آمده هر چهار مدل به کار گرفته شده رضایت‌بخش است. نتایج حاکی از عملکرد بهتر مدل‌های ANN، RBF و LSTM به‌ویژه در نقاط اوج جریان نسبت به IHACRES در مدل‌سازی جریان برای منطقه مورد مطالعه است. در کل، نتایج نشان داد که مدل‌های AI، ابزار مفید برای مدل‌سازی نوسانات جریان هستند و توصیه می‌شود در مطالعات آتی، این ابزار بیش‌تر مورد استفاده قرار گیرد.

واژه‌های کلیدی: هوش مصنوعی، شبکه عصبی مصنوعی، مدل IHACRES، حوضه رودخانه گاماسیاب، مدل‌سازی جریان.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: sadeghmomeneh@gmail.com

استناد: مؤمنه، ص. (۱۴۰۱). مقایسه عملکرد مدل‌های هوش مصنوعی با مدل IHACRES در مدل‌سازی جریان روزانه. *مدل‌سازی و مدیریت آب و خاک*، ۳(۳)، ۱-۱۶.

DOI: 10.22098/MMWS.2022.9972.1076
DOR: 20.1001.1.27832546.1401.2.3.1.0

تاریخ دریافت: ۱۴۰۰/۰۹/۱۸، تاریخ بازنگری: ۱۴۰۰/۱۰/۲۵، تاریخ پذیرش: ۱۴۰۰/۱۰/۳۰، تاریخ انتشار: ۱۴۰۱/۰۱/۱۰

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۱، دوره ۲، شماره ۳، صفحه ۱ تا ۱۶

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

مدیریت و مدل‌سازی فرآیندهای هیدرولوژیکی و پیچیدگی‌های حاکم بر آن‌ها یکی از مسائل اساسی در مناطق مختلف جغرافیایی است. مدل‌سازی و پیش‌بینی جریان رودخانه‌ها به دلایل مختلفی از جمله کمک به برنامه‌ریزی و بهینه‌سازی سامانه‌های منابع آب و همچنین کاهش خطرات ناشی از طغیان رودخانه‌ها و بروز سیل، نقش مهمی در تدوین استراتژی‌ها و مدیریت پایدار منابع آب دارد. پیش‌بینی جریان دقیق و قابل‌اعتماد به دلیل ساختار محیطی و ماهیت متناوب جریان رودخانه‌ها به‌ویژه در حوضه‌های آبخیز نیمه‌خشک بسیار مهم است. با وجود شرایط اقلیمی، مانند بارش‌های فصلی و نرخ تبخیر بالا در حوضه‌های آبریز خشک و نیمه‌خشک، مانند آنچه در اغلب مناطق ایران است، پرداختن به این‌گونه مناطق از اهمیت به‌سزایی برخوردار است. اغلب رودخانه‌های جاری در این مناطق به‌صورت پرنوسان، فصلی و غیردائم هستند که نقش حیاتی در تأمین تقاضای آب ایفا می‌کنند. از طرفی در حوضه‌های آبریز امکان اندازه‌گیری تمام کمیت‌های مشاهداتی مورد نیاز جهت مدل‌سازی و تحلیل جریان وجود ندارد، از این رو انتخاب مدلی که بتواند در عین سادگی ساختار و با استفاده از حداقل عوامل، رواناب حاصل از بارندگی در حوضه را با دقت بالا پیش‌بینی کند، امری ضروری است.

برای مدل‌سازی جریان رودخانه‌ها سه رویکرد شامل رویکردهای فیزیکی (فرآیند محور)، تجربی (مبتنی بر داده و آمار) و مفهومی (بر اساس فرضیات) وجود دارد (Beck, 1991; Ahooghalandari et al., 2016). مدل‌های فیزیکی و مفهومی اغلب به ورودی زیادی شامل انواع داده‌های هیدرولوژیکی، فیزیکی و اقلیمی حوضه نیاز دارند. علاوه بر این، واسنجی این دست از مدل‌ها بسیار دشوار و زمان‌بر است (Panda et al., 2010; Arnold et al., 2012). اگر داده‌های ورودی کافی در دسترس نباشد مدل‌های تجربی (مبتنی بر داده) عملکرد بهتر و قابل‌اعتمادتری نسبت به مدل‌های مفهومی دارند (Carcano et al., 2008). چندین مطالعه مدل‌های فیزیکی و مفهومی رایج از جمله مدل‌های SWAT، IHACRES، HEC-HMS و MIKE 11 را با مدل‌های مبتنی بر داده، مانند شبکه‌های عصبی مصنوعی¹ (ANN) برای پیش‌بینی جریان مقایسه کرده‌اند و اغلب دریافتند که مدل‌های ANN پیش‌بینی‌های بهتری ارائه می‌دهند (برای مثال Carcano et al., 2008; Panda et al., 2010; Kim and Pachepsky, 2010; Rezaeianzadeh et al., 2013; Ahooghalandari et al., 2016; Young et al., 2017; Jimeno-Saez et al.,

2018; Ahmadi et al., 2019; Wagena et al., 2020). با این‌وجود مدل نیمه‌مفهومی IHACRES که تخمین‌گری بسیار پرکاربرد است و می‌تواند در عین سادگی عملکرد مناسب‌تری نسبت به دیگر مدل‌های پیچیده داشته باشد (Carcano et al., 2010; Vaze et al., 2008). مدل IHACRES به‌طور گسترده‌ای در انواع حوضه‌های آبریز در سراسر جهان برای تجزیه و تحلیل هیدرولوژیکی و مطالعات شناخت الگو بارش-رواناب و جریان رودخانه‌ها به‌کار گرفته شده است و نتایج قابل قبول ارائه شده است (برای مثال، Ye, 1993; Jakeman et al., 1997; Letcher et al., 2001; Taesombat and Sriwongsitanon, 2010; Kim and Lee, 2014; Kim, 2015; Kim et al., 2018; Onyutha, 2019; Mubialiwo et al., 2021).

در مواردی که به‌دست آوردن تخمین دقیق، مهم‌تر از درک فرآیند و شناخت سازوکارهای ایجادکننده باشد، مدل‌های ساده مبتنی بر داده می‌تواند جایگزین مناسب باشد (Ebrahimi and Rajaei, 2017; Jha and Sahoo, 2015). در برنامه‌های پیش‌بینی جریان، روش‌های هیدرولوژیکی مبتنی بر داده به‌دلیل زمان توسعه سریع و حداقل اطلاعات مورد نیاز، به‌طور فزاینده‌ای محبوب و مورد استفاده قرار گرفته‌اند. رویکرد مبتنی بر داده شامل معادلات ریاضی است که نه از فرآیند فیزیکی حوضه، بلکه از تجزیه و تحلیل سری‌های زمانی گرفته شده است (Solomatine and Ostfeld, 2008). به‌بیان‌دیگر، مدل‌های مبتنی بر داده می‌توانند روندها را بر اساس روابط عملکردی در داده‌ها یاد بگیرند و تعمیم دهند (Coulibaly, 2001; Zhang et al., 2000). این مدل‌ها رابطه بین داده‌های مشاهداتی ورودی و خروجی، توسط الگوریتم‌های توسعه‌یافته استخراج می‌کنند. هنگامی که داده‌های میدانی کافی نیستند و برآورد دقیق از درک فیزیک مهم‌تر است، یک جعبه سیاه یا مدل داده محور می‌تواند عملکرد مناسبی داشته باشند. اگرچه آن‌ها ممکن است توانایی ارائه تفسیر فیزیکی و درک در مورد فرآیندهای حوضه آبریز را نداشته باشند، با این‌وجود قادر به پیش‌بینی جریان نسبتاً دقیق هستند. در پیش‌بینی جریان مبتنی بر داده، به‌طور سنتی از مدل‌های خطی مانند رگرسیون خطی چندگانه² (MLR) و خود همبسته میانگین متحرک³ (ARMA) برای پیش‌بینی جریان‌ها استفاده می‌شوند. مدل‌های خطی دارای محدودیت‌های هستند و هنگام مدل‌سازی سری زمانی هیدرولوژیکی که غالباً غیرخطی هستند و رفتار دینامیکی سیستم هیدرولوژیکی با زمان تغییر می‌کند، عملکرد خوب و کافی ندارند (Nourani et al., 2014). در سال‌های

² Multiple linear regression³ Autoregressive moving average¹ Artificial neural network

شبهه سازی رواناب عملکرد موفقیت آمیز و مفید دارد. Ahmadi et al. (2019) به مقایسه سه مدل SWAT، IHACRES و ANN پرداختند و دریافتند که عملکرد مدل ANN بهتر از مدل های دیگر استفاده شده برای شبهه سازی بارش-رواناب است. با این وجود، نتایج حاکی از عملکرد قابل قبول مدل های SWAT، IHACRES در شبهه سازی رواناب حاصل از بارش است. Zhu et al. (2020) مدل LSTM را برای پیش بینی سری های زمانی جریان روزانه بررسی نمودند و نتایج نشان داد که عملکرد مدل پیشنهادی رضایت بخش است.

در این مطالعه، برای مدل سازی دبی جریان از مدل های مختلف داده محور و نیمه مفهومی استفاده شده است. برای این منظور مدل های AI شامل ANN، RBF و LSTM به کار گرفته شدند. در جهت اثبات کارایی مدل ها، مقایسه ای بین عملکرد مدل ها با یکدیگر برای مدل سازی جریان روزانه در حوضه رودخانه گاماسیاب واقع در حوضه آبریز با اقلیم نیمه خشک در غرب ایران، صورت پذیرفته است. همچنین عملکرد این مدل ها با عملکرد مدل نیمه مفهومی IHACRES که یک مدل تخصصی بارش-رواناب است نیز در مدل سازی جریان روزانه منطقه، مورد ارزیابی و مقایسه قرار گرفته است. تاکنون در منطقه مورد مطالعه و به طور کلی در دیگر مطالعات از چند مدل AI مختلف برای بررسی و مدل سازی جریان استفاده نشده است. حوضه های آبریز رودخانه گاماسیاب به دلیل وابستگی به بارش ها و دارای رفتار طغیانی است و این امر بر اهمیت مدل سازی جریان منطقه مورد مطالعه به جهت کاهش خطرات سیل می افزاید.

۲- مواد و روش ها

۲-۱- منطقه مورد مطالعه

در این مطالعه به بررسی جریان در حوضه آبریز رودخانه گاماسیاب واقع در غرب ایران پرداخته شده است (شکل ۱). این حوضه با مساحت ۱۰۹۳۵ کیلومتر مربع، دارای آب و هوایی نیمه خشک و در بخش های مرتفع پیرامونی دارای اقلیم نیمه مرطوب است. این حوضه در محدوده جغرافیایی با مختصات به عرض جغرافیایی ۳۳°۴۹' تا ۳۴°۵۷' و طول جغرافیایی ۴۷°۰۶' تا ۴۹°۱۰' واقع است. حداکثر، متوسط و حداقل ارتفاع از سطح متوسط دریا (aml) این منطقه به ترتیب ۱۸۷۳، ۳۴۵۰ و ۱۲۷۲ متر است. محیط حوضه ۶۳۶ کیلومتر هست و ضریب فشردگی (روش گراولیوس^۴) آن برابر ۱/۷ هست و تقریباً شکل حوضه به صورت کشیده است. شیب متوسط حوضه آبریز ۷/۹۶٪ است.

بعد، مدل های غیرخطی و مبتنی بر داده های هوش مصنوعی (AI) مانند ANN برای کاربردهای پیش بینی جریان معرفی شدند. Hsu et al. (1995) و Kang et al. (1993) جزء اولین به کارگیرندگان برنامه های ANN در پیش بینی جریان رودخانه هستند و مقایسه ای بین مدل ANN و مدل های خطی ارائه دادند. آن ها دریافتند که از ANN برای پیش بینی جریان رودخانه کاربردی و مناسب است. از آن زمان، مطالعات زیادی کارایی و مفید بودن مدل های ANN در پیش بینی جریان رودخانه را تأیید کرده اند. رفته رفته مدل های AI از جمله مدل های ANN، شبکه پایه تابع شعاعی^۱ (RBF)، مدل حافظه طولانی کوتاه-مدت^۲ (LSTM) و سیستم استنتاج عصبی-فازی تطبیقی^۳ (ANFIS) و سایر مدل های AI، برای پیدا کردن روابط طبیعی و شناسایی الگوهای موجود در یک سیستم پیچیده بین جریان رودخانه و متغیرهای هیدرولوژیکی مختلف بدون نیاز به ساختن مدل مفهومی، درک مکانیسم فیزیکی در سیستم و روابط پیچیده به کار گرفته شدند.

در دهه های اخیر، مدل های AI به عنوان ابزاری کارآمد برای مدل سازی سامانه های پیچیده هیدرولوژیکی پذیرفته شده اند و به طور مؤثر و گسترده ای برای پیش بینی جریان مورد استفاده قرار گرفته است. برای مثال، Tokar and Johnson (1999) از مدل ANN برای پیش بینی بارش-رواناب روزانه برای حوضه آبخیز رودخانه ای در مرینند استفاده کردند و نتایج حاکی از کارایی قابل قبول این مدل در پیش بینی جریان است Kumar et al. (2004) پیش بینی یک سری زمانی هیدرولوژیکی به دلیل گستره وسیع داده ها، عدم قطعیت در پارامترهای مؤثر بر سری زمانی و همچنین به دلیل در دسترس نبودن داده های کافی، یکی از پیچیده ترین کارها بوده است. آن ها از مدل ANN برای غلبه بر این محدودیت ها و به عنوان ابزاری مفید برای پیش بینی جریان رودخانه توصیه نمودند. Pramanik and Panda (2009) توانایی پیش بینی مدل های ANN و ANFIS را برای تخمین جریان حوضه رودخانه ماهانتی در هند مورد بررسی قرار دادند. نتایج نشان داد که مدل ها عملکرد خوبی در تخمین جریان دارند. Kagoda et al. (2010) از شبکه عصبی RBF برای پیش بینی یک روزه جریان تعدادی از حوضه های آبریز در آفریقای جنوبی استفاده کردند و در مطالعاتشان عملکرد مناسب مدل RBF نشان دادند. Meng et al. (2015) یک مدل ANN برای شبهه سازی و پیش بینی جریان روزانه در حوضه های آبخیز کارستی در چین به کار بردند و دریافتند که مدل ANN در

¹Radial basis function

²Long short-term memory

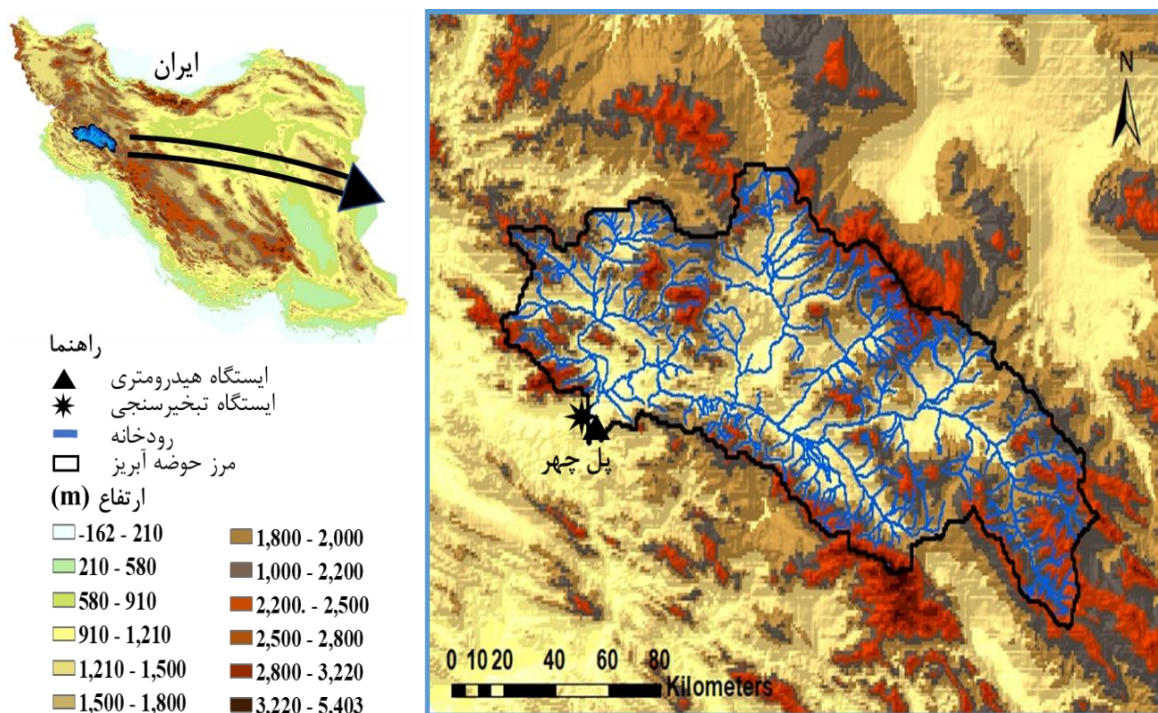
³Adaptive neural-fuzzy inference system

⁴Gravelius

کیلومتر است. متوسط دبی سالانه (آبدهی) ایستگاه پل چهر ۲۵/۹ مترمکعب بر ثانیه و حداکثر دبی ثبت شده دوره بلندمدت ۷۹۶ مترمکعب بر ثانیه است. حداکثر دبی‌های ثبت شده اغلب در ماه‌های نوامبر تا مه که عمده بارش‌ها در این ماه‌ها صورت گرفته است. حداکثر دمای متوسط ماهانه و حداقل دمای ماهانه در ایستگاه پل چهر به ترتیب در ماه‌های مرداد و بهمن به ترتیب ۳۸/۷۷ درجه سانتی‌گراد و ۳/۷۵- درجه سانتی‌گراد است. متوسط بارندگی سالانه در این دوره نیز ۳۸۴ میلی‌متر است و نزدیک به ۹۷/۳٪ از کل بارش سالانه در بین ماه‌های آبان تا اردیبهشت رخ می‌دهد.

حوضه مورد مطالعه توسط ارتفاعات رشته‌کوه‌های زاگرس احاطه شده است و قسمت‌های میانی متشکل از تپه‌ماهور و دشت است. آبی که در یک حوضه آبریز جریان دارد در نهایت توسط محل خروجی در قسمت جنوب غربی حوضه تخلیه می‌شود.

مختصات ایستگاه‌های هیدرومتری و تبخیرسنجی پل چهر با عرض جغرافیایی ۳۴°۲۰' و طول جغرافیایی ۴۷°۲۶' و ارتفاع این ایستگاه ۱۲۸۰ متر است و در خروجی حوضه بر روی رودخانه گاماسیاب واقع در استان کرمانشاه در غرب ایران قرار دارد. این رودخانه از نظر حوزه آبریز، بخشی از سرشاخه‌های حوزه رودخانه کرخه و بخشی از حوضه آبریز خلیج فارس و دریای عمان محسوب می‌شود. طول بلندترین آبراهه اصلی ۲۲۱



شکل ۱- موقعیت حوضه آبریز رودخانه گاماسیاب و ایستگاه‌های پایش آن در ایران

Figure 1- Location map of Gamasiab River catchment and its monitoring stations in the Iran

۳-۲- معیارهای ارزیابی عملکرد مدل‌ها

ارزیابی عملکرد یک مدل هیدرولوژیکی معمولاً از طریق مقایسه مقادیر اختلاف بین متغیرهای مشاهده شده و شبیه‌سازی شده انجام و توصیف می‌شود. در این مطالعه، برای کلیه مدل‌های از معیارهای آماری از جمله ضریب همبستگی^۱ (R) و ضریب کارایی نش-ساتکلیف^۲ (NSE) و ریشه میانگین مربعات خطا^۳ (RMSE) به ترتیب برای ارزیابی ارتباط آماری بین مقدار پیش‌بینی شده و

۲-۲- داده‌های استفاده شده

در این مطالعه برای مدل‌های AI و IHACRES از ۳۱ سال داده روزانه اندازه‌گیری شده در ایستگاه پل چهر شامل، داده‌های جریان، بارش و دما (۱ مهر ۱۳۶۵-۳۱ شهریور ۱۳۹۶) حوضه آبریز استفاده شد که از بایگانی داده و اطلاعات شرکت آب منطقه‌ای کرمانشاه به‌دست آمد. در این مطالعه، کل داده‌ها به مجموعه‌های واسنجی (آموزش) و صحت‌سنجی (آزمون) تقسیم شده است. ۷۹۲۶ نمونه اول (۷۰٪ از کل مجموعه داده‌ها) برای توسعه مدل (آموزش) و ۳۳۹۷ نمونه باقیمانده (۳۰٪ از کل مجموعه داده‌ها) برای ارزیابی (آزمون) مدل‌ها استفاده شده است.

¹ Correlation coefficient

² Nash-Sutcliffe efficiency coefficient

³ Root mean square error

جایی که n تعداد مجموعه داده‌ها باشد، m تعداد سلول‌های عصبی در لایه پنهان است؛ w_{jk} ، w_{ij} = وزنی که نورون‌ها به ترتیب در لایه‌های ورودی و خروجی دارند؛ w_{bk} ، w_{bj} = اریبی به ترتیب در لایه‌های پنهان و خروجی؛ f_o ، f_h = عملکرد فعال سازی نورون^۵ها در لایه‌های پنهان و خروجی؛ $x_i(t)$ ، $y_k(t)$ = به ترتیب متغیرهای ورودی i ام و متغیرهای خروجی k ام (Kim and Valdes, 2003).

در این مطالعه، نتایج اولیه نشان داد که یک لایه پنهان برای تقریبی رابطه بین جریان مشاهده شده و مدل سازی کافی است. تعداد مطلوب سلول‌های عصبی در لایه‌های پنهان با استفاده از روش آزمون و خطا تعیین شد. تعداد لایه‌ها و نورون‌ها با کمترین مقادیر معیار RMSE به عنوان تعداد مناسب لایه‌ها و نورون‌ها انتخاب شدند. بهترین تعداد نورون‌ها در لایه پنهان یعنی ۵ نورون (گره) برای مدل ANN تعیین و به منظور مدل سازی جریان استفاده شده است. مجموعه داده‌های بارش، دما و جریان به دو زیرمجموعه تقسیم می‌شوند. زیرمجموعه اول مجموعه داده‌های آموزشی است که برای محاسبه گرادیان خطا و به روزرسانی وزن و اریبی نورون‌ها در لایه‌های مختلف شبکه استفاده می‌شود. زیرمجموعه دوم مجموعه آزمون است که یک مجموعه داده مستقل است که برای بررسی کارایی و عملکرد مدل استفاده می‌شود. از الگوریتم آموزش تنظیم ساز بی‌زی به دلیل عملکرد مناسب در آموزش شبکه عصبی، استفاده شد.

شایان ذکر است که، برای تمامی مدل‌های AI در لایه خروجی شبکه یک نورون و سه نرون برابر تعداد سری زمانی در لایه ورودی قرار داده شد. برای به کارگیری مدل‌های AI از کدهای منبع باز در نرم افزار MATLAB 2018a استفاده شده است و ساختار شبکه‌های آن‌ها و تنظیم پارامتر با استفاده از روش آزمون و خطا تعیین شد.

۲-۵- مدل شبکه عصبی تابع پایه شعاعی (RBF)

شبکه عصبی تابع پایه شعاعی (RBF) نوعی شبکه عصبی پیش تغذیه‌ای است که برای تقریب عملکرد، پیش‌بینی سری زمانی، کنترل سیستم، طبقه‌بندی، درون‌یابی نویز و منظم سازی استفاده می‌شود (Kegl et al., 2000). آموزش شبکه RBF سریع است و در دام حداقل‌های محلی نمی‌افتد. شبکه RBF دارای یک ساختار سه لایه شامل لایه ورودی (X)، لایه پنهان (H) و لایه خروجی (Y) است. معماری اصلی شبکه عصبی RBF سه لایه در شکل ۳ نشان داده شده است. لایه ورودی شامل گره‌های منبع است که شبکه را به محیط آن متصل می‌کند و سپس

مقدار مشاهده شده، ارزیابی قدرت پیش‌بینی مدل و اندازه‌گیری واریانس خطا استفاده شدند.

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O}) \times (F_i - \bar{F})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \times (F_i - \bar{F})^2}} \quad (۱)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۲)$$

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

در جایی که N تعداد نقاط داده مورد استفاده است، F_i مقادیر پیش‌بینی شده، O_i داده‌های مشاهده شده و \bar{F} و \bar{O} به ترتیب میانگین مقادیر F_i و O_i است. بهترین تناسب بین مقدار پیش‌بینی شده و مقدار مشاهده شده هنگامی رخ می‌دهد که مقادیر حاصل از این روابط (روابط ۱-۳) به ترتیب R و NSE به عدد یک و $RMSE$ به عدد صفر برسند و یا نزدیک شوند (Ahmadi et al., 2019; Gong et al., 2016).

۲-۴- مدل شبکه عصبی مصنوعی (ANN)

در دهه‌های اخیر، رویکرد تخمین ANN به عنوان یک مدل جعبه سیاه مورد توجه بسیاری از محققان قرار گرفته است و به طور گسترده‌ای در سراسر جهان و در زمینه‌های مختلف مانند پیش‌بینی سری‌های زمانی، شناسایی الگو و توالی، پردازش و استخراج داده‌ها و سیستم شناسایی و کنترل مورد استفاده قرار گرفته است (Nayak et al., 2006). ANN از چندین سلول عصبی مصنوعی تشکیل شده است که مطابق با ساختار خاص شبکه در چندین لایه به هم پیوسته‌اند. از ANN می‌توان برای پیش‌بینی مقادیر آینده سری‌های زمانی حاوی نویز^۱ (نوفه) بر اساس تاریخ گذشته استفاده کرد (Adamowski and Chan, 2011). شبکه‌های ANN در تقریب عملکرد ورودی و خروجی از قبیل پیش‌بینی عملکرد خوبی داشته‌اند، از این رو برای مدل سازی و پرسپترون چندلایه^۲ (MLP) یکی از شبکه‌های عصبی پرکاربرد برای مدل سازی هیدرولوژیکی است که می‌تواند الگوهای پنهان و غیرخطی را تشخیص دهد (Nayak et al., 2006; Principe et al., 1999). معماری یک شبکه ANN معمولی با یک لایه پنهان که در آن تابع فعال سازی لجستیک^۳ (سیگموئید^۴) و یک تابع خطی در لایه خروجی در شکل ۲ نشان داده شده است. رویکرد ANN به بیان ریاضی به شرح زیر است:

$$y_k(t) = f_o \left[\sum_{j=1}^m w_{jk} f_h \left(\sum_{i=1}^n w_{ij} x_i(t) + w_{bj} \right) + w_{bk} \right] \quad (۴)$$

¹ Noise

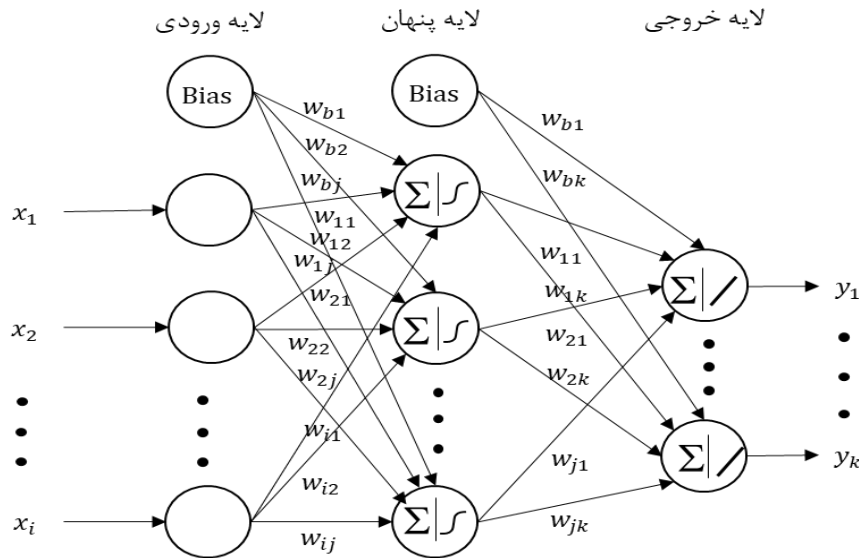
² Multi-layer perceptron

³ Logistic

⁴ Sigmoid

⁵ Neuron

⁶ Bayesian regularization



شکل ۲- ساختار شبکه سه لایه ANN
Figure 2- ANN three-layer network structure

پنهان؛ یعنی ۱۰۰ نرون تعیین و برای مدل‌سازی دبی جریان استفاده شد. مدل RBF با حداقل خطا و بیش‌ترین کارایی به‌عنوان شبکه بهینه انتخاب شدند.

۲-۶- مدل حافظه طولانی کوتاه‌مدت (LSTM)

شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی توالی‌ها در اواخر قرن بیستم توسعه یافتند. در سال‌های اخیر، این مدل به‌دلیل توانایی بالایی که در حل مشکلات یادگیری ماشین دارد، بسیار محبوب شده است. شبکه LSTM به‌دلیل ترکیب توابع دروازه با پویایی حالت ارتقا یافته از شبکه عصبی بازگشتی^۱ (RNN) است. این بهبود ساختاری، محدودیت پایداری (به‌عنوان مثال، مشکل گرادیان ناپدید شدن)، حذف شده است. شبکه LSTM یاد می‌گیرد که در طول فرآیند آموزشی چه اطلاعاتی را حذف (فراموش) یا ذخیره کند (Hochreiter and Schmidhuber, 1997). یک شبکه LSTM از چندین بلوک حافظه تشکیل شده است که از طریق لایه‌ها به هم متصل می‌شوند. هر لایه از مجموعه‌ای از سلول‌های حافظه به هم پیوسته تشکیل شده است. سلول‌ها نیز حاوی دروازه‌های ورودی، فراموشی و خروجی هستند (Wu et al., 2021). ساختار هر دروازه از تابع فعال‌سازی، وزن اتصال و اربابی تشکیل شده است. در دروازه ورودی، مقادیر اضافه شده به حالت سلول توسط توابع سیگموئید تنظیم و کنترل می‌شوند. سپس اطلاعاتی به حالت سلول اضافه می‌شود. با استفاده از یک فیلتر ضرب، در فرآیند حافظه، دروازه فراموشی^۲ یاد می‌گیرد که

ورودی‌ها را بدون اعمال وزن به لایه پنهان منتقل می‌کند. در لایه پنهان، وزن با استفاده از عملکرد غیرخطی توابع هسته متقارن شعاعی به داده‌ها اختصاص می‌یابد. لایه پنهان از تعدادی نرون (گره) و یک بردار پارامتر به نام مرکز تشکیل شده است. گره‌های موجود در لایه پنهان هرکدام دارای یک تابع فعال‌سازی هستند که سیگنال ورودی (داده‌ها) را از نظر وزنی تغییر می‌دهد. تابع فعال‌سازی فاصله اقلیدسی بین بردار ورودی و مرکز واحد پنهان در شبکه را محاسبه می‌کند. سرانجام، لایه خروجی یک واحد جمع‌بندی است و به‌صورت خطی عمل می‌کند (Chen et al., 2010).

$$\Phi_i(X) = \Phi_i(\|X - c_i\|); \quad i = 1, 2, \dots, h \quad (5)$$

$$\Phi(X) = \exp\left[-\frac{\|X - c\|^2}{2\beta^2}\right] \quad (6)$$

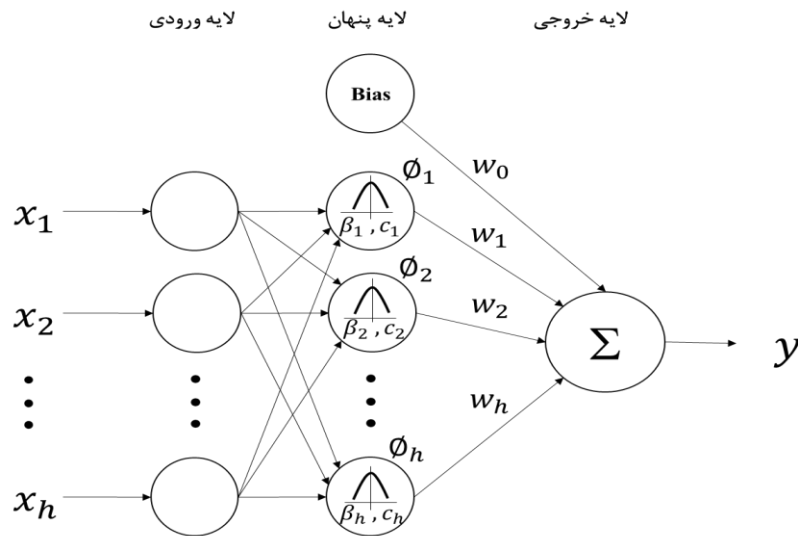
$$y_i = w_0 + \sum_{i=1}^h w_{ij}\Phi_i(X); \quad i = 1, 2, \dots, h \quad (7)$$

جایی که داده ورودی X یک بردار N بعدی باشد، همان ابعاد نورون در لایه پنهان است، بردار ورودی $X = [x_1, x_2, \dots, x_n]^T$ ؛ c_i = بردار مرکز نرون i ام در لایه پنهان؛ $\|$ نشانگر هنجار اقلیدسی است؛ h = تعداد سلول‌های عصبی در لایه پنهان؛ β = عرض مرکز؛ $\Phi_i(X)$ = پاسخ گره پنهان حاصل از تمام داده‌های ورودی؛ w_{ji} = اتصال وزن بین گره i ام در لایه پنهان و گره j ام در لایه خروجی؛ w_0 = اربابی (ASCE, 2000).

در این مطالعه، عملکرد فعال‌سازی نورون‌ها در فضای ورودی متقارن است و اشکال مختلفی دارد. بیش‌ترین کاربرد تابع فعال‌سازی به شکل تابع گوسی است. توابع گوسی توسط معادله توصیف شده است. به‌عنوان توابع انتقال (فعال‌سازی) در سلول‌های عصبی لایه‌های پنهان استفاده شد. بهترین تعداد نورون‌ها مدل RBF با به‌کارگیری روش آزمون و خطا در لایه

¹ Recurrent neural network

² Forget gate



شکل ۳- پیکربندی مدل RBF
Figure 3- RBF model configuration

به روز می کند (Sen and Ozkurt, 2020). معماری شبکه و تنظیم پارامتر با استفاده از روش آزمون و خطا تعیین شد. در لایه خروجی شبکه فقط یک نورون و سه نورون برابر تعداد سری زمانی در لایه ورودی قرار داده شد. بهترین تعداد نورون‌ها در لایه پنهان ۲۵۰ نورون برای مدل LSTM به عنوان شبکه بهینه انتخاب شد.

۷-۲- مدل IHACRES

مدل IHACRES یک مدل شبیه سازی مداوم و نیمه مفهومی بارش-رواناب است که به دلیل نیاز به مقدار کمی داده، دقت و عملکرد شبیه سازی قابل قبول نسبت به مدل های پیچیده، صرف وقت و هزینه کم و کاربری ساده، در بسیاری از حوضه های آبخیز با شرایط مختلف آب و هوایی و هم با شرایط دائمی و رودخانه های موقت کاربردهای بسیاری دارد (Croke and Jakeman, 2007). یکی از مهم ترین مزیت این مدل نسبت به سایر مدل های بارش-رواناب آن است که این مدل به داده های ورودی کمی احتیاج دارد؛ بنابراین، می تواند در بسیاری از حوزه های آبخیز با مساحت ها و شرایط اقلیمی مختلف مورد استفاده قرار گیرد که داده کم یا هیچ داده ای وجود ندارد. الگوی IHACRES به طور کلی از دو قسمت تشکیل شده است: ابتدا بخشی که بارندگی ناخالص را به بارش مؤثر تبدیل می کند و اثرات تبخیر را تقریب زده، که در واقع جمع بارش است که از طریق رودخانه حرکت می کند و در نهایت با تبخیر و تعرق از بین می رود. سپس یک تابع تحول خطی که بارندگی مؤثر را به یک

در زمان های مناسب خود را بازنشانی کند. به عبارت دیگر، دروازه فراموش می داند که چه اطلاعاتی را حذف یا ذخیره کند (به عنوان مثال، حالت های سلولی به آرامی محو می شوند). دروازه خروجی اطلاعات مفید را از وضعیت سلول جریان انتخاب می کند، سپس آن را به عنوان خروجی مشخص می کند، آن را به سلول بعدی منتقل می کند. ساختار سلولی و معماری کلی مدل LSTM در شکل ۴ نشان داده شده است.

$$i_t = \sigma(w_i x_t + R_i h_{t-1} + b_i) \quad (8)$$

$$f_t = \sigma(w_f x_t + R_f h_{t-1} + b_f) \quad (9)$$

$$y_t = \sigma(w_y x_t + R_y h_{t-1} + b_y) \quad (10)$$

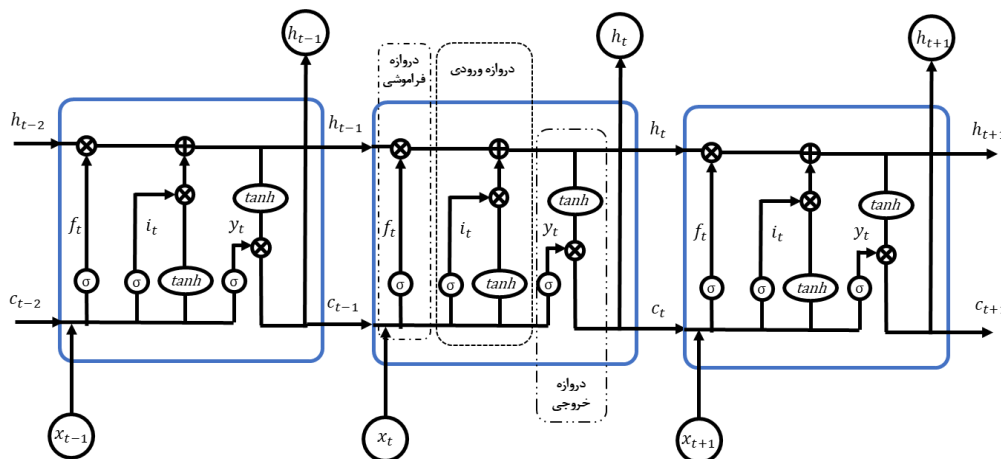
$$c_t = f_t c_{t-1} + i_t \bar{c}_t \quad (11)$$

$$\bar{c}_t = \tanh(w_c x_t + R_c h_{t-1} + b_c) \quad (12)$$

$$h_t = y_t \tanh(c_t) \quad (13)$$

جایی که i_t و f_t و y_t به ترتیب دروازه های ورودی، فراموشی و خروجی هستند. x_t نشان دهنده بردار ورودی است. (وزن های ورودی: w_c, w_y, w_f, w_i ؛ وزن های بازگشتی: R_c, R_f, R_i, R_y ؛ و وزن های آریبی: b_c, b_f, b_i, b_y) مجموعه ای از ماتریس قابل یادگیری را تعریف می کنند. وزنه ها c_t و h_t به ترتیب بردار وضعیت سلول و خروجی هستند. c_{t-1} و h_{t-1} به ترتیب حالت سلول قبلی و بردار خروجی قبلی هستند. حالت سلولی بالقوه را نشان می دهد. $\sigma(\cdot)$ و $\tanh(\cdot)$ به ترتیب تابع سیگموئید لجستیک و مماس هذلولی هستند.

در تحقیق حاضر از بهینه ساز Adam در شبکه LSTM استفاده شده است. الگوریتم Adam به دلیل سادگی و کارایی در محاسبات بسیار کاربردی است. این الگوریتم بر اساس گرادینان تطبیقی عمل می کند و شبکه را با استفاده از گرادینان های قبلی

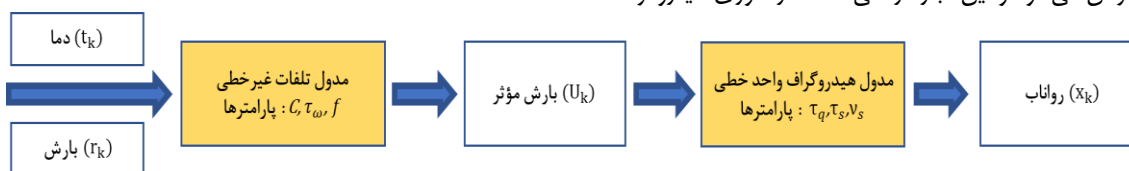


شکل ۴- معماری شبکه LSTM
Figure 4- LSTM network architecture

واحد استفاده شود. در ضمن، گام زمانی داده معمولاً برای بارندگی و جریان و دما یا تبخیر، سری زمانی روزانه یا ماهانه انتخاب می‌شود. دو جز مؤلفه در ماژول (جریان سریع و جریان آهسته) می‌توانند به صورت موازی یا سری متصل شوند. شکل ۵ فرآیند این مدل را نشان می‌دهد.

در مرحله واسنجی برای افزایش کارایی مدل IHACRES از بازه‌های مختلفی برای مدل‌سازی جریان استفاده گردید و بهترین بازه زمانی (یعنی بازه زمانی نمونه‌های ۳۱۵۰-۷۹۲۶) با توجه به عملکرد مدل بر اساس معیارهای R، RMSE و NSE انتخاب شد؛ اما در مرحله صحت‌سنجی برای مقایسه عادلانه‌تر از همان بازه داده‌های ورودی و همچنین زمان تأخیر مدل‌های AI (یعنی، تأخیر یک روزه) برای مدل IHACRES نیز معرفی شده است. تعیین دوره واسنجی و تنظیم پارامترها با استفاده از روش آزمون و خطا تعیین شد. برای مدل IHACRES از نرم‌افزار IHACRES v.2.1.2 استفاده گردید.

جریان مدل شده تبدیل می‌کند. مدل IHACRES دارای شش پارامتر است که سه پارامتر مربوط به تابع غیرخطی و سه پارامتر مربوط به تابع تبدیل خطی است (Ye et al., 1997; Zareian et al., 2017) (شکل ۵). مدل IHACRES دارای شش پارامتر است که سه پارامتر آن مربوط به بخش تلفات غیرخطی است، ظرفیت نگهداشت رطوبت حوضه (میلی‌متر)، τ_{ω} زمان خشک شدن حوضه (روز)، f فاکتور تعدیل دما حوضه $(1/0^C)$ و سه پارامتر دیگر مربوط به هیدروگراف واحد یا تابع تعدیل است، τ_q زمان فروکش جریان سریع (روز)، τ_s زمان فروکش جریان آهسته (روز) و v_s حجم جریان آهسته مؤثر بر ایجاد رواناب است. سازوکار حاکم بر مدل به صورت است که با استفاده از پارامترهای دما، بارش و سطح حوضه، بارش-رواناب را شبیه‌سازی می‌کند. پیکربندی این روش بر اساس مدول (واحد) تلفات غیرخطی و مدول هیدروگراف واحد خطی است. مدول غیرخطی بارندگی (τ_k) و دما (t_k) را در هر مرحله زمان k ، به میزان بارندگی مؤثر (U_k) تبدیل می‌کند. یک رابطه خطی بین بارندگی مؤثر (U_k) و جریان فرض می‌شود و این اجازه را می‌دهد تا از تئوری هیدروگراف



شکل ۵- فرآیند مدل‌سازی بارش-رواناب مدل IHACRES
Figure 5- Rainfall-runoff modeling process of IHACRES model

تخصصی بارش-رواناب با عنوان IHACRES برای مقایسه و بررسی کارایی بهتر این مدل‌ها استفاده شد. پس از انتخاب بهترین ساختار کلیه مدل و تنظیم پارامترهای مربوطه، از آن‌ها برای مدل‌سازی نرخ جریان استفاده شد. شایان ذکر است که زمانی مدل‌سازی جریان هنگامی رضایت‌بخش است که مقدار $NSE < 0.5$ باشد (Moriasi et al.,

۳- نتایج و بحث

هدف اصلی مطالعه حاضر، استفاده از مدل‌های مختلف هوش مصنوعی (AI) شامل مدل‌های ANN، RBF و LSTM برای مدل‌سازی دقیق دبی جریان روزانه یک حوضه آبریز طی یک دوره ۳۱ ساله در غرب ایران است. علاوه بر این با یک مدل

غرب تهران مقایسه نمودند و نتایج این مطالعه حاکی از عملکرد بهتر مدل‌های ANN نسبت به مدل IHACRES است. (Carcano et al., 2008) عملکرد نوعی از مدل ANN را با مدل IHACRES در مدل‌سازی جریان روزانه دو حوضه کوچک در ایتالیا مقایسه کردند و نتایج مطالعه آن‌ها نشان داد که مدل ANN خطای مدل‌سازی کم‌تری نسبت به مدل IHACRES دارد. این نتایج در مقایسه میان مدل‌های AI با مدل IHACRES با نتایج مطالعه حاضر مطابقت دارد (جدول ۲).

در ضمن، به‌منظور مقایسه عادلانه‌تر و بهتر بین مدل IHACRES و مدل‌های AI، دورهٔ صحت‌سنجی، ترکیب داده‌ها، نوع داده‌ها (یعنی داده‌های بارش، دما و نرخ جریان) و تأخیر (یعنی، یک گام زمانی) در داده‌های مورد استفاده یکسان در نظر گرفته شده است. در ادامه نتایج به‌دست‌آمده ارائه و به تجزیه و تحلیل آن‌ها پرداخته شده است.

۳-۱- نتایج مدل IHACRES

همان‌طور که در بخش قبلی ذکر شد، داده‌ها به دوره‌های واسنجی و صحت‌سنجی تقسیم شدند و مدل IHACRES برای مدل‌سازی جریان مورد بررسی قرار گرفت. مقادیر بهینه پارامترهای خطی و غیرخطی مدل IHACRES در دورهٔ واسنجی در جدول ۱ ارائه شده است. این پارامترها برخی از ویژگی‌ها و ارتباطات جریان و حوضه را بیان می‌کند.

(2007). به بیان دیگر در شبیه‌سازی‌ها اگر مقدار $NSE < 0.75$ به‌دست‌آید نتایج خوب و مقدار $0.36 < NSE < 0.75$ حاصل شود، نتایج رضایت‌بخش ارزیابی می‌شود (Motovilov et al., 1999). با توجه به نتایج به‌دست آمده در مطالعه حاضر، همهٔ چهار مدل مورد استفاده در محدوده رضایت‌بخش قرار دارند (جدول ۲).

بر اساس نتایج به‌دست آمده برای عملکرد مدل IHACRES با نتایج پژوهش دیگر محققان مطابق دارد. یک عامل اصلی در ضعف شبیه‌سازی نقاط اوج جریان به‌دلیل عدم توانایی کافی مدل IHACRES در شبیه‌سازی فرآیند ذوب برف است و به موجب آن، دبی‌های اوج که اغلب در فصل بهار اتفاق می‌افتند و ذوب برف هم در آن دخیل است را به خوبی مدل‌سازی نمی‌کند. این نتایج و عوامل آن در مطالعات (Zeinoddini et al., 2018) جریان ورودی به مخزن سد ستارخان و Amiri and Roudbari (2017) در شبیه‌سازی دبی روزانهٔ رودخانه‌های پل‌رود و سلمان‌رود در استان گیلان، نیز اشاره شده است. در ضمن پژوهش مشابه در شبیه‌سازی رواناب در منطقهٔ مورد مطالعه؛ یعنی حوضهٔ گاماسیاب توسط (Zarezade Mehrizi et al., 2018) صورت گرفته و عوامل مشابه‌ای در شبیه‌سازی جریان منطقه ذکر شده است.

Ahmadi et al. (2017) در تحقیقات خود کارایی مدل ANN ($NSE = 0.86$) را نسبت به مدل IHACRES ($NSE = 0.57$) در مدل‌سازی بارش-رواناب برای حوضه واقع در

جدول ۱. مقادیر بهینه پارامترهای مهم خطی و غیرخطی مدل IHACRES در دورهٔ واسنجی

Table 1- Optimal values of important linear and nonlinear parameters of the IHACRES model in the calibration period

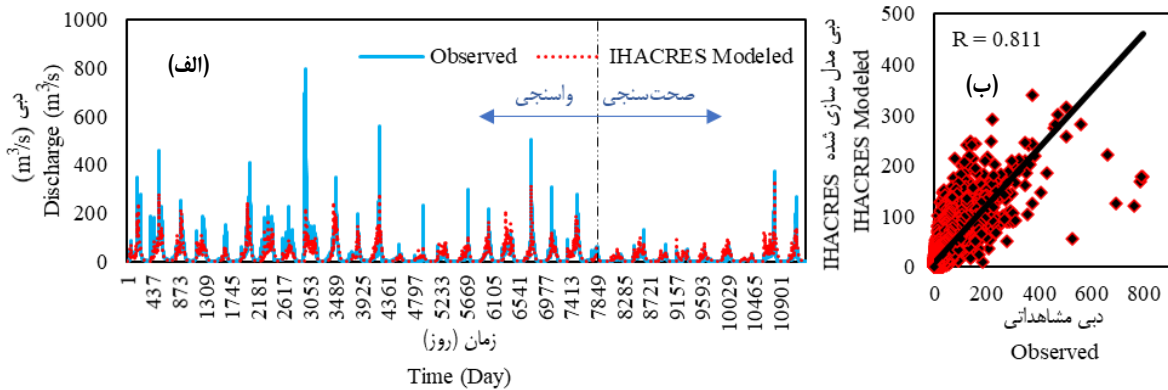
مقدار	پارامتر مدول خطی	مقدار	پارامتر مدول غیرخطی
0.851	V_s حجم جریان آهسته مؤثر بر ایجاد رواناب (روز)	0.001326	C ظرفیت نگهداشت رطوبت حوضه (mm)
27.335	T_s زمان فروکش جریان آهسته (روز)	7.00	t_w زمان خشک شدن حوضه (روز)
2.248	T_q زمان فروکش جریان سریع (روز)	4.00	f فاکتور تعدیل دما ($^{\circ}C^{-1}$)

نسبتاً خوب است که شکل ۶ به‌وضوح این امر را نشان می‌دهد. به‌طورکلی، نتایج مدل‌سازی جریان مدل IHACRES بر اساس مقادیر R، RMSE و NSE دارای عملکرد قابل‌قبول و رضایت‌بخش است.

۳-۲- نتایج مدل‌های هوش مصنوعی (AI)

پس از تعیین معماری مناسب مدل‌های AI مطابق با معیارهای عملکرد، واسنجی خاتمه یافت و وزن‌ها در شبکه ایجاد شده، ذخیره می‌شود تا در مرحله صحت‌سنجی اعمال شود. مقادیر معیارهای عملکردی R، RMSE و NSE برای دوره‌های واسنجی (آموزش) و صحت‌سنجی (آزمون) بهترین مدل‌های ANN، RBF و LSTM در جدول ۲ ارائه شده است. برای مثال

نتایج نشان از ظرفیت مناسب مدل نیمه مفهومی IHACRES، برای مدل‌سازی روزانه جریان با خطای نسبتاً کم و همبستگی مناسب دارد. مقادیر R، RMSE و NSE مدل IHACRES برای تخمین نرخ دبی در جدول ۲ ارائه شده است. همان‌گونه که در جدول ۲ ارائه شده است، مقادیر بر اساس معیارهای R، RMSE و NSE مدل IHACRES در مرحله صحت‌سنجی به‌ترتیب برابر 0.771 ، $16/97$ (m^3/s) و 0.512 است. روند کلی مدل‌سازی در شکل ۶ نمایش داده شده است. در همین حال، نتایج به‌دست‌آمده حاکی از کم‌ترین دقت مدل‌سازی نسبت به دیگر مدل‌های به‌کار گرفته شده در این مطالعه را دارد. هرچند این مدل عملکرد مناسبی در مدل‌سازی پیک جریان ندارد، اما عملکرد این مدل در بخش‌های با حجم جریان متوسط و کم



شکل ۶- مقایسه جریان مشاهده شده و مدل‌سازی شده با استفاده از مدل IHACRES در طول دوره‌های واسنجی و صحت‌سنجی (الف) و همبستگی بین مقادیر به کار رفته (ب).

Figure 6 - Comparison of observed and modeled streamflow using the IHACRES model during the calibration and verification periods (a) and correlation between the values used (b).

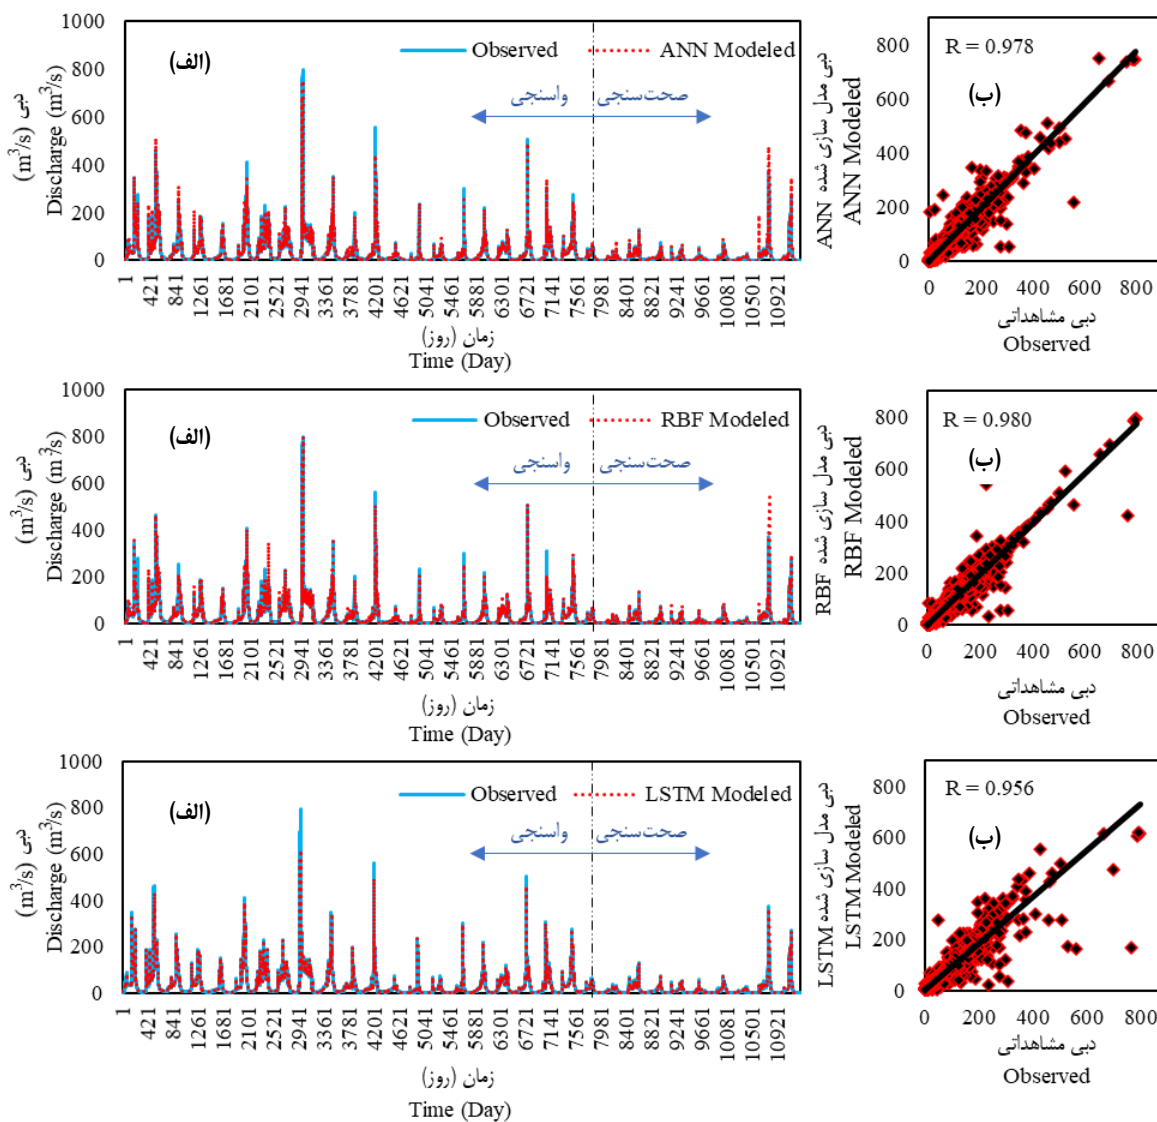
از طرفی، بدیهی است که کارایی مدل‌سازی مدل‌های ANN، RBF و LSTM به‌عنوان رویکرد داده‌محور به کمیت و کیفیت داده‌های استفاده شده بستگی دارد. در حقیقت، بیش‌تر سری‌های زمانی هیدرولوژیکی اندازه‌گیری و مشاهده شده به‌ویژه در جریانات سطحی پویا و غیرخطی هستند. ارقام ذکر شده به‌وضوح توانایی مدل‌های مبتنی بر شبکه عصبی برای یادگیری رابطه غیرخطی بین ورودی‌ها و خروجی را نشان می‌دهد. در مجموع، نتایج مدل‌سازی مدل LSTM در گام‌های زمانی مختلف در دوره صحت‌سنجی نسبتاً از مدل‌های ANN و RBF بهتر است. همگی مدل‌های ANN، RBF و LSTM با دقت بسیار بالایی پیک‌های دبی جریان را تخمین و مدل‌سازی کنند. به‌طورکلی، مدل‌های AI به‌کار گرفته شده توانستند به‌خوبی پیک‌های دبی جریان را مدل‌سازی و شبیه‌سازی نمایند. در کل، نتایج حاکی از پتانسیل مناسب مدل‌های AI در مدل‌سازی جریان است.

مقدار RMSE برای مدل‌های ANN، RBF و LSTM در مرحله صحت‌سنجی به‌ترتیب $0.7/56$ (m^3/s)، $0.7/39$ (m^3/s) و $0.6/41$ (m^3/s) است. معمولاً خطای آزمایش از خطای آموزش عینی‌تر است، زیرا از مقادیر ناشناخته برای شبکه برای ارزیابی آن استفاده می‌شود؛ اما گاهی ممکن است الگوهای و رفتارهای مختلف جریان در طول دوره‌ها با ناهمگونی نوسانات ارتباط داشته باشد. نتایج حاصل از مدل LSTM ممکن است به‌علت نقاط اوج کوتاه‌تر در طول دوره صحت‌سنجی، عملکرد بهتری از دوره واسنجی مطابق معیارهای R، RMSE و NSE داشته است. برای مثال، در مدل LSTM در دوره واسنجی و صحت‌سنجی به‌ترتیب برای معیار RMSE برابر $15/73$ (m^3/s) و $0.6/41$ (m^3/s) برای معیار R برابر 0.953 و 0.965 و برای معیار NSE برابر 0.930 و 0.909 است. شکل ۷ نتایج برای مدل‌های AI نشان می‌دهد و عملکرد این مدل‌ها را در طول دوره‌های واسنجی و صحت‌سنجی و هم‌چنین میزان همبستگی بین داده‌های مشاهده شده و مدل‌سازی شده را نمایش می‌دهد.

جدول ۲- نتایج مدل‌های ANN، RBF، LSTM و IHACRES بر اساس معیارهای عملکردی در دوره‌های واسنجی و صحت‌سنجی

Table 2- Results of the ANN, RBF, LSTM, and IHACRES models and based on the performance criteria in calibration and verification periods.

NSE		RMSE		R		مدل‌ها
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی	
0.512	0.637	16.97	31.41	0.771	0.820	IHACRES
0.903	0.959	7.56	10.54	0.958	0.979	ANN
0.907	0.962	7.39	10.12	0.959	0.981	RBF
0.930	0.909	6.41	15.73	0.965	0.953	LSTM



شکل ۷- مقایسه جریان مشاهده شده و مدل‌سازی شده با استفاده از مدل‌های ANN، RBF و LSTM در طول دوره‌های واسنجی و صحت‌سنجی (الف) و همبستگی بین مقادیر به کار رفته (ب)

Figure 7- Comparison of observed and modeled streamflow using the ANN, RBF, and LSTM models model during the calibration and verification periods (a) and correlation between the values used (b)

مدل IHACRES بودند. نتایج نشان می‌دهد که مقادیر R، RMSE و NSE برای مدل‌سازی جریان روزانه مدل LSTM در طی دوره صحت‌سنجی نسبتاً بهتر از مدل‌های ANN، RBF است و همچنین بسیار بهتر از مدل IHACRES است. در حالی که مدل‌های ANN، RBF در مرحله واسنجی عملکرد بهتری از دیگر مدل‌ها داشته‌اند. نتایج به دست آمده مطابق نتایج مطالعات Carcano et al. (2008) و Ahmadi et al. (2019) است. مدل IHACRES در جریان آرام رودخانه و دبی‌های کم عملکرد مناسبی داشته است، اما این مدل در پیک‌های جریان عملکرد مناسبی از خود نشان نداده است. با ذکر این نکته که دقت مدل‌سازی همه مدل‌ها در حد قابل قبول قرار دارد (Moriassi et al., 2007; Motovilov et al., 1999). برای مثال، مقدار

۴- نتیجه‌گیری

هدف از این مطالعه ارزیابی عملکرد مدل‌های داده محور هوش مصنوعی (AI) شامل مدل‌های ANN، RBF و LSTM در مقایسه با عملکرد مدل نیمه مفهومی IHACRES است و برای مدل‌سازی جریان روزانه در حوضه آبریز رودخانه گاماسیاب در غرب ایران استفاده شدند. در مطالعه حاضر، به منظور مقایسه مناسب بین مدل‌ها، دوره‌های صحت‌سنجی مدل‌های AI همان دوره مربوط به مدل IHACRES تعیین شد. نتایج مقایسه این دو نوع مدل مختلف نشان داد که مدل‌های AI می‌تواند شبیه‌سازی منطبق‌تر و بهتری از جریان روزانه را نسبت به مدل نیمه مفهومی IHACRES ارائه دهند. به طور کلی، مدل‌های AI به‌ویژه در تخمین پیک‌های جریان به‌طور قابل توجهی بهتر از

نیمه مفهومی IHACRES بر اساس معیار RMSE دارد. در مجموع، مدل LSTM را برای مدل‌سازی جریان روزانه منطقه مورد مطالعه پیشنهاد می‌شود. در ضمن، نحو واسنجی مدل IHACRES نسبت به مدل‌های AI برای شبیه‌سازی دبی جریان آن زمان برتر و پیچیده‌تر است. مدل‌های داده محور مانند مدل‌های AI، معمولاً به داده‌ها و تلاش کم‌تری نسبت به مدل‌های دیگر نیاز دارند؛ بنابراین، مدل‌های داده محور می‌توانند با مدل‌سازی و پیش‌بینی دقیق‌تر و ساده‌تر جریان را ارائه دهند و برای برنامه‌ریزی و مدیریت کارآمد منابع آب در مناطق مختلف به کار گرفته شوند. در کل، نتایج نشان داد که مدل‌های مختلف AI ابزاری مناسب در مدل‌سازی جریان هستند و پیشنهاد می‌شود در پژوهش‌های آتی بیش‌تر مورد استفاده قرار گیرند.

حوضه آبریز گاماسیاب. مرتع و آبخیزداری، مجله منابع طبیعی ایران، ۷۰(۴)، ۸۸۱-۸۹۳.
 زین‌الدینی، س.، انوری، ص.، و زحمتکش، ز. (۱۳۹۷). کاربرد رویکردهای شبیه‌سازی-بهبینه‌سازی جهت ارزیابی گزینه‌های مختلف اقلیمی و مدیریتی در یک سامانه منابع آب. تحقیقات منابع آب ایران، ۱۴(۵)، ۲۹۵-۳۱۰.

References

- Adamowski, J., & Chan, H.F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407, 28-40. doi:10.1016/j.jhydrol.2011.06.013.
- Ahmadi, M., Moeini, A., Ahmadi, H., Motamedvaziri, B., & Zehtabiyani, G.R. (2019). Comparison of the performance of SWAT, IHACRES and artificial neural networks models in rainfall-runoff simulation (case study: Kan watershed, Iran). *Physics and Chemistry of the Earth*, 111, 65-77. doi:10.1016/j.pce.2019.05.002.
- Ahooghalandari, M., Khiadani, M., & Kothapalli, G., (2016). Assessment of Artificial Neural Networks and IHACRES models for simulating streamflow in Marillana catchment in the Pilbara, Western Australia. *Australian Journal of Water Resources*, 19, 116-126. doi:10.1080/13241583.2015.1116183.
- Amiri, E., Roudbari Mousavi, M.M. (2016). Evaluation of IHACRES hydrological model for simulation of daily flow (case study Polrood and Shalmanrood rivers). *Iranian Journal of Eco Hydrology*, 3(4), 533-543 (in Persian).
- Arnold, J.G., Moriasi, D.N., Gassman, P.W., Abbaspour, K.C., White, M.J., Srinivasan, R.,

RMSE برای مدل‌های IHACRES، ANN، RBF و LSTM در مرحله صحت‌سنجی به ترتیب $۱۶/۹۷$ (m^3/s)، $۷/۵۶$ (m^3/s) و $۷/۳۹$ (m^3/s) جهت مدل‌سازی جریان به دست آمد. برای انتخاب بهترین مدل باید به این نکته توجه کرد که معیارهای عملکرد مدل در مرحله واسنجی و مرحله صحت‌سنجی متعادل باشد. اگرچه که نتایج مدل‌های بسیار به یکدیگر نزدیک است با این‌وجود مدل LSTM با کم‌ترین مقادیر RMSE و بیش‌ترین مقادیر R و NSE در مرحله صحت‌سنجی و با توجه به متعادل بودن این مقادیر در هر دو مرحله واسنجی و صحت‌سنجی به‌عنوان مدل برگزیده انتخاب گردید. نتایج حاکی از آن است که بهترین مدل داده محور توسعه‌یافته (یعنی مدل LSTM) عملکرد بیش از ۲ برابر بهتر در مدل‌سازی جریان روزانه نسبت به مدل

منابع

- امیری، ا.، و رودباری موسوی، م.م. (۱۳۹۵). ارزیابی مدل هیدرولوژی IHACRES در شبیه‌سازی دبی روزانه (مطالعه موردی رودخانه‌های پلرود و شلمانرود). *اکوهیدرولوژی*، ۳(۴)، ۵۳۳-۵۴۳.
- زارع‌زاده مهریزی، ش.، خورانی، ا.، بذرافشان، ج.، و بذرافشان، ا. (۱۳۹۶). ارزیابی کارایی مدل SWAT در شبیه‌سازی رواناب
- Santhi, C., Harmel, R.D., Van Griensven, A., Van Liew, M.W., Kannan, N., & Jha, M.K. (2012). SWAT: Model use, calibration, and validation. *Transactions of the ASABE*, 55, 1491-1508.
- ASCE, (2000). Artificial Neural Networks in Hydrology II: Hydrologic Applications. *Journal of Hydrologic Engineering*, 5, 124-137. doi:10840699/00/0002-01240137.
- Beck, M.B. (1991). Forecasting environmental change. *Journal of Forecasting*, 10, 3-19. doi:10.1002/for.3980100103.
- Carcano, E.C., Bartolini, P., Muselli, M., & Piroddi, L. (2008). Jordan recurrent neural network versus IHACRES in modelling daily streamflows. *Journal of Hydrology*, 362, 291-307. doi:10.1016/j.jhydrol.2008.08.026.
- Chen, L.H., Chen, C.T., & Pan, Y.G. (2010). Groundwater Level Prediction Using SOM-RBFN Multisite Model. *Journal of Hydrologic Engineering*, 15, 624-631. doi:10.1061/(asce)he.1943-5584.0000218.
- Coulbaly, P., Anctil, F., & Bobee, B. (2000). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230, 244-257. doi:10.1016/S0022-1694(00)00214-6.
- Croke, B.F.W., & Jakeman, A.J. (2007). Use of the IHACRES rainfall-runoff model in arid and

- semi-arid regions. *Hydrological Modelling in Arid and Semi-Arid Areas*, 41-48. doi:10.1017/CBO9780511535734.005.
- Croke, B.F.W., Andrews, F., Jakeman, A.J., Cuddy, S.M., & Luddy, A. (2006). IHACRES Classic Plus: A redesign of the IHACRES rainfall-runoff model. *Environmental Modelling & Software*, 21, 426 - 427.
- Ebrahimi, H., & Rajaei, T. (2017). Simulation of groundwater level variations using wavelet combined with neural network, linear regression and support vector machine. *Global and Planetary Change*, 148, 181-191. doi:10.1016/j.gloplacha.2016.11.014.
- Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A Comparative Study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for Forecasting Groundwater Levels near Lake Okeechobee, Florida. *Water Resources Management*, 30, 375-391. doi:10.1007/s11269-015-1167-8.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Hsu, K.I., Gupta, H.V., Adamowski, J., Fung Chan, H., Prasher, S.O., Ozga-Zielinski, B., & Sliusarieva, A. (1995). Artificial neural network modeling of the rainfall-runoff process that arise and based Background and Scope. *Water Resources Research*, 48, 1-14.
- Jakeman, A., Littlewood, I., & Whitehead, P. (1993). An assessment of the dynamic response characteristics of streamflow in the Balquhider catchments. *Journal of Hydrology*, 145(3), 337-355.
- Jha, M.K., & Sahoo, S. (2015). Efficacy of neural network and genetic algorithm techniques in simulating spatiotemporal fluctuations of groundwater. *Hydrological Processes*, 29, 671-691. doi:10.1002/hyp.10166.
- Jimeno-Saez, P., Senent-Aparicio, J., Perez-Sanchez, J., & Pulido-Velazquez, D. (2018). A comparison of SWAT and ANN models for daily runoff simulation in different climatic zones of peninsular Spain. *Water (Switzerland)*, 10. doi:10.3390/w10020192.
- Kagoda, P.A., Ndiritu, J., Ntuli, C., & Mwaka, B. (2010). Application of radial basis function neural networks to short-term streamflow forecasting. *Physics and Chemistry of the Earth*, 35, 571-581. doi:10.1016/j.pce.2010.07.021.
- Kang, K.W., Kim, J.H., Park, C.Y., & Ham, K. J. (1993). Evaluation of hydrological forecasting system based on neural network model. In: Proceedings of the 25th Congress of the International Association for Hydraulic Research, Delft, Netherlands, Pp. 257-264.
- Kegl, B., Krzyak, A., & Niemann, H. (2000). Radial basis function networks and complexity regularization in function learning and classification. In: Proceedings 15th International Conference on Pattern Recognition. ICPR-2000, IEEE Comput. Soc, Barcelona, Spain, Pp. 81-86. doi:10.1109/ICPR.2000.906022.
- Kim, J.W., & Pachepsky, Y.A. (2010). Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. *Journal of Hydrology*, 394, 305-314. doi:10.1016/j.jhydrol.2010.09.005.
- Kim, H., & Lee, S. (2014). Assessment of a seasonal calibration technique using multiple objectives in rainfall-runoff analysis. *Hydrological Processes*, 28(4), 2159-2173.
- Kim, K.B. (2015). Application of a baseflow filter for evaluating model structure suitability of the IHACRES CMD. *Journal of Hydrology*, 521, 543-555. doi:10.1016/j.jhydrol.2014.12.030.
- Kim, K.B., Kwon, H-H., & Han, D. (2018). Exploration of warm-up period in conceptual hydrological modelling. *Journal of Hydrology*, 556, 194-210. doi:10.1016/j.jhydrol.2017.11.015.
- Kim, T.W., & Valdes, J.B. (2003). Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks. *Journal of Hydrologic Engineering*, 8, 319-328. doi:10.1061/(asce)1084-0699(2003)8:6(319).
- Kumar, D.N., Raju, K.S., & Sathish, T., (2004). River flow forecasting using artificial neural networks. *Water Resources Management*, 2, 143-161, doi:10.1016/j.asoc.2019.04.024.
- Letcher, R., Schreider, S.Y., Jakeman, A., Neal, B., & Nathan, R. (2001). Methods for the analysis of trends in streamflow response due to changes in catchment condition. *Environmetrics*, 12(7), 613-630. doi:10.1002/env.486
- Meng, X., Yin, M., Ning, L., Liu, D., & Xue, X. (2015). A threshold artificial neural network model for improving runoff prediction in a karst watershed. *Environmental Earth Sciences*, 74, 5039-5048. doi:10.1007/s12665-015-4562-9.
- Moriasi, D. N., Arnold, J. G., Van Liew, M.W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900. doi:10.13031/2013.23153.
- Motovilov, Y.G., Gottschalk, L., Engeland, K., & Rodhe, A. (1999). Validation of a distributed hydrological model against spatial observations. *Agricultural and Forest Meteorology*, 98-99,

- 31, 257-277, doi:10.1016/S0168-1923(99)00102-1.
- Mubialiwo, A., Abebe, A., & Onyutha, C. (2021). Performance of rainfall-runoff models in reproducing hydrological extremes: a case of the River Malaba sub-catchment. *SN Applied Sciences*, 3, 515, doi:10.1007/s42452-021-04514-7.
- Nayak, P.C., Satyaji Rao, Y.R., & Sudheer, K.P. (2006). Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management*, 20, 77-90, doi:10.1007/s11269-006-4007-z.
- Nourani, V., Baghanam, A.H., Rahimi, A.Y., & Nejad, F.H. (2014). Evaluation of Wavelet-Based De-noising Approach in Hydrological Models Linked to Artificial Neural Networks. Pp. 209-241, In: Islam, T., Srivastava, P.K., Gupta, M., Zhu, X., & Mukherjee, S. (Eds), *Computational Intelligence Techniques in Earth and Environmental Sciences*, Springer Netherlands, Dordrecht. volume 9789401786, doi:10.1007/978-94-017-8642-3_12.
- Onyutha, C. (2019). Hydrological model supported by a stepwise calibration against sub-flows and validation of extreme flow events. *Water*, 11, 244, <https://doi.org/10.3390/w11020244>.
- Principe, J.C., Euliano, N.R., & Curt Lefebvre, W. (1999). *Neural and Adaptive Systems: Fundamentals through Simulations*. Wiley, 672 pages.
- Panda, R.K., Pramanik, N., & Bala, B., (2010). Simulation of river stage using artificial neural network and MIKE 11 hydrodynamic model. *Computers and Geosciences*, 36, 735-745, doi:10.1016/j.cageo.2009.07.012.
- Pramanik, N., & Panda, R.K. (2009). Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction. *Hydrological Sciences Journal*, 54, 247-260, doi:10.1623/hysj.54.2.247.
- Rezaeianzadeh, M., Stein, A., Tabari, H., Abghari, H., Jalalkamali, N., Hosseinipour, E.Z., & Singh, V.P. (2013). Assessment of a conceptual hydrological model and artificial neural networks for daily outflows forecasting. *International Journal of Environmental Science and Technology*, 10, 1181-1192, doi:10.1007/s13762-013-0209-0.
- Sen, S.Y., & Ozkurt, N. (2020). Convolutional Neural Network Hyperparameter Tuning with Adam Optimizer for ECG Classification. 2020 Innovations in Intelligent Systems and Applications Conference (ASYU), Istanbul, Turkey, 978, Pp. 1-6. doi:10.1109/ASYU50717.2020.9259896.
- Solomatine, D.P., & Ostfeld, A. (2008). Data-driven modelling: some past experiences and new approaches. *Journal of Hydroinformatics*, 10, 3-22, doi:10.2166/hydro.2008.015.
- Taesombat, W., & Sriwongsitanon, N. (2010). Flood investigation in the Upper Ping River Basin using mathematical models. *Kasetsart Journal-Natural Science*, 44, 152-166.
- Tokar, B.A.S., & Johnson, P.A. (1999). Rainfall-Runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4, 232-239.
- Vaze, J., Post, D. A., Chiew, F. H. S., Perraud, J. M., Viney, N. R., & Teng, J. (2010). Climate non-stationarity—validity of calibrated rainfall-runoff models for use in climate change studies. *Journal of Hydrology*, 394(3), 447-457.
- Wagena, M.B., Goering, D., Collick, A.S., Bock, E., Fuka, D.R., Buda, A., & Easton, Z.M. (2020). Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling and Software*, 126, doi:10.1016/j.envsoft.2020.104669.
- Wu, C., Zhang, X., Wang, W., Lu, C., Zhang, Y., & Qin, W., et al. (2021). Groundwater level modeling framework by combining the wavelet transform with a long short-term memory data-driven model. *Science of The Total Environment*, 783, 146948, doi:10.1016/j.scitotenv.2021.146948.
- Ye, W., Bates, B.C., Viney, N.R., Sivapalan, M., & Jakeman, A.J. (1997). Performance of conceptual rainfall-runoff models in low-yielding ephemeral catchments. *Water Resources Research*, 33, 153-166.
- Young, C.C., Liu, W.C., & Wu, M.C. (2017). A physically based and machine learning hybrid approach for accurate rainfall-runoff modeling during extreme typhoon events. *Applied Soft Computing Journal*, 53, 205-216, doi:10.1016/j.asoc.2016.12.052.
- Zareian, M.J., Eslamian, S., Gohari, A., & Adamowski, J.F. (2017). The effect of climate change on watershed water balance. Pp. 215-238, In: *Mathematical Advances towards Sustainable Environmental Systems*, Springer.
- Zarezade Mehrizi, S., Khorani, A., Bazrafshan, J., & Bazrafshan, O. (2018). Assessing the efficiency of SWAT model for runoff simulation in Gamasiyab basin. Rangeland and Watershed Management. *Iranian Journal of Natural Resources*, 70(4), 881-893 (in Persian).
- Zeinoddini, S., Anvari, S., & Zahmatkesh, Z. (2018). Application of Simulation-Optimization Approaches to Assess the Effect of Climate and Management Scenarios on a Water Resource System. *Iran-Water Resources Research*, 14(5), 295-310 (in Persian).
- Zhang, G., Patuwo, B., & Hu, M.Y. (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting. *Computers & Operations Research*, 28, 381-396, doi:10.1016/S0305-0548(99)00123-9.

Zhu, S., Luo, X., Yuan, X., & Xu, Z. (2020). An improved long short-term memory network for streamflow forecasting in the upper Yangtze River. *Stochastic Environmental Research and Risk Assessment*, 34, 1313-1329, doi:10.1007/s00477-020-01766-4.