

Evaluation of combined models Wavelet-ARIMA-ANN and Wavelet-ARIMA-LSTM using SRGI index simulation in enhancing drought monitoring

Mohammad Reza Sharifi^{1*} , Mahtab Nouri² , Md. Munir Hayet Khan³ 

¹Associate Professor, Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

²M.Sc., Department of Hydrology and Water Resources, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

³Associate Professor, Faculty of Engineering & Quantity Surveying (FEQS), INTI International University (INTI-IU), Persiaran Perdana BBN, Nilai 71800, Negri Sembilan, Malaysia

Extended Abstract

Introduction

Drought monitoring entails the simulation of indices, which are categorized into single and combined types. Historically, simulations have predominantly relied on single indices, including the Standardized Precipitation Index (SPI) and Standardized Runoff Index (SRI), resulting in limited research on drought simulation using combined indices (i.e., MSPI and SPTI), particularly in conjunction with combined models. Over the years, several single models have been developed for simulating individual drought indices. For instance, the Autoregressive Integrated Moving Average (ARIMA) model has been applied to simulate drought indices like the Standardized Precipitation Index (SPI) and Standard Index of Annual Precipitation (SIAP). Additionally, models such as Artificial Neural Networks (ANN) and Long Short-Term Memory (LSTM) have been used for simulating indices like SPI, DI, SIAP, and SHDI. Recent studies suggest that combined models outperform single models. Wavelet ARIMA ANN (W-2A) and Wavelet ANFIS combined models were used to simulate the single drought index SPEI. Other researchers have developed combined models such as ARIMA-LSTM, Wavelet-ARIMA-LSTM, Wavelet-ARIMA-ANN, and LSTM-CM to simulate single drought indices SPI, DI, and SIAP. Despite the progress in developing drought simulation models, including single models and particularly combined models, their application has primarily focused on individual indices. Historically, simulations have predominantly relied on single indices, resulting in limited research on drought simulation using combined indices, particularly in conjunction with combined models. This study has combined the strengths of the Wavelet transformation, Autoregressive Integrated Moving Average (ARIMA), Artificial Neural Network (ANN), and Long Short-Term Memory (LSTM) to test new methods of hybrid models for their ability to perform drought simulations based on the new combined index SRGI, employing the combined models W-AL and W-2A.

Materials and Methods

Drought was simulated in the Alashtar sub-basin between 48, 15 east longitudes and 33, 54 north latitudes, covering an area of 811 square kilometers from 1991 to 2020, utilizing individual indices such as SPI, SRI, SGI, and the combined index SRGI. The study area encompasses the Karkheh River basin. Both single models (ARIMA, LSTM, ANN) and combined models (W-AL and W-2A) were employed for this purpose. Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Error (ME) were used to evaluate the performance of the models. Also, relative frequency and error distribution charts were used to evaluate and compare the results of the models.

Individual indices were calculated based on fitting the best cumulative probability function to monthly precipitation, monthly discharge, and monthly water table data, respectively, for indices SPI, SRI, and SGI, and then inversely transforming them to an $N(0,1)$. The SRGI index is a combination of two drought indices, SGI and SRI (Feng et al., 2020). For this purpose, the copula function is used to obtain the best joint probability distribution function governing precipitation and water table data. The selection of the best copula function was done through the Kolmogorov-Smirnov (K-S) test at a significance level of 5%. In the current research, four copula functions —Frank, Clayton, Gamble, and Joe—were used. The process of building the combined models includes the analysis of the time series of the studied drought index, using DWT, and decomposing it into two series, named approximate and detailed. Then, the approximate and detailed series are modeled by ARIMA and ANN, respectively, in the W-2A and by ARIMA and LSTM models, in the W-AL model.

Results and Discussion

The results demonstrate that the combined models W-AL and W-2A exhibit higher accuracy across all indices, both individual and combined, compared to single models ARIMA, LSTM, and ANN. The RMSE ranges for the combined models were 0.44 to 0.71, while for single models, they ranged from 0.47 to 1.54. Specifically, model W-AL displayed superior accuracy across all individual indices, with RMSEs of 0.44, 0.62, and 0.59, in contrast to model W-2A, which yielded RMSEs of 0.49, 0.71, and 0.63. However, W-AL's performance lagged behind W-2A for the combined SRGI index, with respective RMSEs of 0.64 and 0.61. Thus, the simpler model yielded more acceptable results in simulating the composite index.

Conclusion

Among all the combined and individual models, the combined models perform better in simulating drought, based on all indices, compared to the individual models. Therefore, it can be said that combined models are more suitable for simulating and monitoring drought compared to individual models. However, the performance of the two combined models, W-2A and W-AL, in simulating the combined SRGI index is different. The performance of the simpler W-2A model is better than the more complex W-AL model, with RMSE values of 0.61 and 0.64, respectively. Therefore, in combined indices, despite the complexity of their computational process, there is not necessarily a need to use a more complex combined model. Overall, the use of combined models is recommended for monitoring various types of indices, especially drought, based on combined indices such as SRGI. The major objectives of this study are: (1) to use hybrid models Wavelet-ARIMA-LSTM (W-AL) and Wavelet-ARIMA-ANN (W-2A) to predict monthly drought. (2) To analyze drought characteristics in the Alashtar basin based on the new combined drought index, SRGI. It is expected that the research results will help to provide decision support, which in turn will help in planning adaptive measures to reduce drought impacts and provide decision support for disaster prevention.

Keywords: Combined index, hybrid models, deep learning, neural network, Alashtar basin.

Article Type: Research Article

Acknowledgment

The article's authors express their gratitude and appreciation for the support of the Shahid Chamran University of Ahvaz through a research grant (SCU.WH1403.26878).

Conflicts of interest

The authors of this article declare that there are no conflicts of interest regarding the writing and publication of the contents and results of this research.

Data Availability Statement

The datasets are available upon reasonable request from the corresponding author.

Authors' contribution

Mohammad Reza Sharifi, conceptualization, editing, and revision of the article; **Mahtab Nouri**: Performed software/statistical analyses, and wrote the initial version of the article; **Md. Munir Hayet Khan**: Consulting and reviewing the text of the article

*Corresponding Author, E-mail: msharifi@scu.ac.ir

Citation: Sharifi, M.R., Nouri, M., & Hayet Khan, M.M. (2025). Evaluation of combined models Wavelet-ARIMA-ANN and Wavelet-ARIMA-LSTM using SRGI index simulation in enhancing drought monitoring . *Water and Soil Management and Modeling*, 5(3), 88-103.

doi: 10.22098/mmws.2025.16471.1536

Received: 01 January 2025., Received in revised form: 29 April 2025., Accepted: 02 May 2025, Published online: 23 September 2025.

Water and Soil Management and Modeling, Year 2025, Vol. 5, No. 3, pp. 88-103

Publisher: University of Mohaghegh Ardabili

© Author(s)





ارزیابی عملکرد مدل های ترکیبی Wavelet-ARIMA-ANN و Wavelet-ARIMA-SRGI در شبیه سازی خشکسالی مبتنی بر شاخص ترکیبی SRGI

محمدرضا شریفی^{۱*}، مهتاب نوری^۲، مانیر حیات خان^۳

^۱دانشیار، گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران
^۲دانش آموخته کارشناسی ارشد، گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران
^۳دانشیار، دانشکده مهندسی و بررسی کمیت، دانشگاه بین المللی INTI، پرسیاران پردانا، نیلای ۷۱۸۰۰، نگری سمیلان، مالزی

چکیده

پایش خشکسالی مستلزم شبیه سازی شاخص هایی است که به دو دسته تکی و ترکیبی دسته بندی می شوند. شبیه سازی ها عمدتاً مبتنی بر شاخص های تکی بوده اند. از این رو مطالعه خاصی در زمینه شبیه سازی خشکسالی مبتنی بر شاخص های ترکیبی، خصوصاً شبیه سازی با مدل های ترکیبی انجام نشده است. در این پژوهش به شبیه سازی خشکسالی مبتنی بر شاخص ترکیبی SRGI، با استفاده از مدل های ترکیبی Wavelet-ARIMA-ANN و Wavelet-ARIMA-SRGI اقدام شده است. برای این منظور، خشکسالی زیر حوزه آبخیز الشتر در بازه زمانی ۲۰۲۰-۱۹۹۱، مبتنی بر شاخص های تکی شامل SRI، SPI و SGI و شاخص ترکیبی SRGI، با مدل های تکی ARIMA، LSTM و ANN و نیز مدل های ترکیبی W-AL و W-2A و مقایسه عملکردهای آنها با یکدیگر، شبیه سازی شد. نتایج نشان داد مدل های ترکیبی W-2A و W-AL در مقایسه با مدل های تکی ARIMA، LSTM و ANN برای کلیه شاخص ها اعم از تکی و ترکیبی صحت بیش تری دارند. به طوری که دامنه RMSE برای مدل های ترکیبی در مقایسه با مدل های تکی، به ترتیب ۰/۷۱-۰/۴۴ و ۰/۴۷-۰/۵۴ به دست آمد. از سویی دیگر، مقایسه دو مدل ترکیبی W-AL و W-2A نشان داد مدل W-AL در همه شاخص های تکی با RMSE ۰/۴۴، ۰/۶۲، ۰/۵۹، صحیح تر از مدل W-2A با RMSE ۰/۴۹، ۰/۷۱، ۰/۶۳ به دست آمد. این در حالی است که عملکرد W-AL در شاخص ترکیبی SRGI، با RMSE ۰/۶۴، صحت کم تری از مدل W-2A با RMSE ۰/۶۱ داشته است.

واژه های کلیدی: نمایه ترکیبی، مدل های هیبریدی، یادگیری عمیق، شبکه عصبی، حوضه الشتر.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: msharifi@scu.ac.ir

استناد: شریفی، محمدرضا، نوری، مهتاب و حیات خان، مانیر (۱۴۰۴). ارزیابی عملکرد مدل های ترکیبی Wavelet-ARIMA-ANN و Wavelet-ARIMA-SRGI در شبیه سازی خشکسالی مبتنی بر شاخص ترکیبی SRGI. مدل سازی و مدیریت آب و خاک، ۵(۳)، ۸۸-۱۰۳. doi: 10.22098/mmws.2025.16471.1536

تاریخ دریافت: ۱۴۰۳/۱۰/۱۲، تاریخ بازنگری: ۱۴۰۴/۰۲/۰۹، تاریخ پذیرش: ۱۴۰۴/۰۲/۱۲، تاریخ انتشار: ۱۴۰۴/۰۷/۰۱

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۴، دوره ۵، شماره ۳، صفحه ۸۸ تا ۱۰۳.

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

خشکسالی آثار زیان باری بر اقتصاد، آب و امنیت غذایی دارد (Shukla and Wood, 2008; Van Loon, 2015; Williams et al., 2020; Li et al., 2021). پیش بینی های صحیح بارش برای برآورد صحیح خشکسالی در یک منطقه مورد نیاز است (Ndlovu and Demlie, 2020). برای شبیه سازی خشکسالی از شاخص های مختلفی، استفاده می شود. به دلیل تعدد عوامل مؤثر بر خشکسالی، پایش خشکسالی براساس شاخص های تکی، کافی نمی باشد (Hao and Aghakouchak, 2013; Yisehak and Zenebe, 2021).

از این رو پژوهش گران، به منظور پایش صحیح تر خشکسالی، اقدام به توسعه شاخص های ترکیبی نموده اند (Kao and Govindaraju, 2010; Hao and Aghakouchak, 2013; Hao and Aghakouchak, 2013). به این ترتیب، شاخص های مزبور به دو دسته شاخص های تکی و ترکیبی، تقسیم می شوند. شاخص های تکی، نظیر شاخص های SPI، SRI و SGI (McKee et al., 1993; Shukla and Wood, 2008; Bloomfield and Marchand, 2013) و شاخص ترکیبی مانند SRGI (Hao and Aghakouchak, 2013) می باشند. مرور منابع نشان می دهد مدل های خشکسالی، اعم از تکی و ترکیبی، عمدتاً برای شبیه سازی شاخص های خشکسالی تکی، به کار رفته اند. مدل های تکی متعددی در طول سال ها برای شبیه سازی شاخص های خشکسالی توسعه داده شده اند. به عنوان نمونه از مدل تکی ARIMA برای شبیه سازی شاخص های خشکسالی SPI و SIAP (Belayneh et al., 2015; Karimi et al., 2019; Wu et al., 2021) و نیز به منظور شبیه سازی شاخص های خشکسالی DI و SHDI از مدل های تکی ANN و LSTM، استفاده شده است (Dehghani et al., 2017; Mehdizadeh et al., 2019). مطالعه های اخیر نشان می دهند ترکیب مدل های تکی از جمله ARIMA و ANN یا LSTM با یکدیگر و با کمک تبدیل موجک Wavelet تحت عنوان مدل های ترکیبی، امکان استفاده از مزایای هر یک از مدل های تکی را با هدف شبیه سازی سری های زمانی غیر خطی مانند خشکسالی، فراهم می آورد (Zhang et al., 2017; Khan et al., 2020; Wu et al., 2021; Adnan et al., 2021). در راستای توسعه مدل های ترکیبی (Soh et al., 2018)، برای شبیه سازی شاخص خشکسالی تکی SPEI از مدل های ترکیبی WA-ANN و WANFIS و نیز (Mohamadi et al., 2020) از مدل های ترکیبی، ANFIS-NPA و MLP-NPA برای شبیه سازی شاخص خشکسالی تکی SPI استفاده کردند. به همین

ترتیب سایر پژوهش گران اقدام به توسعه مدل های ترکیبی Wavelet-ARIMA-LSTM، ARIMA-LSTM و LSTM-CM، برای شبیه سازی شاخص های خشکسالی تکی SPEI، SPI، DI، SIAP و SPI نموده اند (Zhang et al., 2017; Adnan et al., 2021; Xu et al., 2022; Wu et al., 2022).

با توجه به مطالب فوق، مدل های توسعه داده شده برای شبیه سازی خشکسالی، اعم از مدل های تکی و خصوصاً مدل های ترکیبی، صرفاً در شبیه سازی شاخص های تکی به کار رفته اند. این در حالی است که مرور منابع نشان می دهد، صرفاً در دو مورد، شاخص های ترکیبی MSPI و JDI، آن هم با مدل های تکی MLP (Aghelpour et al., 2021) و ANFIS (Aghelpour and Varshavian, 2020) شبیه سازی شده اند. این مطالعه، نقاط قوت تبدیل موجک، میانگین متحرک یکپارچه اتورگرسیو (ARIMA)، شبکه عصبی مصنوعی (ANN) و حافظه کوتاه بلندمدت (LSTM) را در غالب دو مدل ترکیبی جدید برای شبیه سازی خشکسالی، بر اساس شاخص ترکیبی جدیدی به کار برده است. بنابراین، با توجه به اهمیت کاربرد مدل های ترکیبی از یک سو و شاخص های خشکسالی ترکیبی از سوی دیگر، در پژوهش حاضر، اقدام به ارزیابی عملکرد دو مدل ترکیبی جدید (W-AL) Wavelet-ARIMA- و (W-2A) Wavelet-ARIMA-ANN در مدل سازی خشکسالی مبتنی بر شاخص ترکیبی SRGI در حوضه الشتر، به عنوان یکی از زیر حوضه های حوزه آبخیز کرخه، شده است.


۲- مواد و روش

۲-۱- محدوده مورد مطالعه

زیر حوضه الشتر واقع بین ۴۸ درجه و ۳ دقیقه تا ۴۸ درجه و ۳۰ دقیقه طول شرقی و ۳۳ درجه و ۴۵ دقیقه تا ۳۴ درجه عرض شمالی با مساحت ۸۱۱ کیلومتر مربع و ارتفاع ۱۵۸۰ متر از سطح آزاد دریا، بارندگی متوسط سالانه ۵۵۴ میلی متر و دمای متوسط سالانه ۸/۸ درجه سانتی گراد است. اقلیم محدوده با در نظر گرفتن سیستم اقلیمی آمبرژه دارای اقلیم نیمه خشک سرد می باشد (Kalirad et al., 2013). محدوده مورد مطالعه، از زیر حوضه های حوزه آبخیز کرخه، می باشد. شکل ۱، محدوده مورد مطالعه، آبراهه اصلی، ایستگاه هیدرومتری و نیز ایستگاه باران سنجی را نشان می دهد. رودخانه الشتر یک رودخانه دائمی که از دامنه های جنوبی رشته ارتفاعات گرین، یکی از کانون های آبیگری دائمی لرستان، سرچشمه گرفته و با نام کهمان، ابتدا به غرب جریان یافته و از میان

ایستگاه‌های سراب صید علی و سطح ایستابی ۱۳ چاه مشاهداتی در دوره آماری ۳۰ ساله (۱۹۹۱ تا ۲۰۲۰) که از آب منطقه‌ای لرستان اخذ شد، استفاده شده است.

دره تنگی عبور می‌کند (Chamanpira et al., 2014). سفره آب زیرزمینی در محدوده مورد مطالعه، بانام دشت الشتر، از نوع آزاد و شامل رسوبات آبرفتی می‌باشد. به‌منظور محاسبه شاخص‌های خشکسالی، از اطلاعات آب‌سنجی، باران‌سنجی مربوط به



شکل ۱- محدوده مورد مطالعه، حوضه کرخه، زیر حوضه الشتر و موقعیت ایستگاه‌های هیدرومتری، هواشناسی و چاه‌های مشاهده‌ای

Figure 1. Study area, Karkheh basin, Alashtar sub-basin, and hydrometric, rain gauge stations, observation wells

مرطوب است. SRI و SGI شاخص‌های استاندارد خشکسالی، به‌ترتیب برای ارزیابی خشکسالی هیدرولوژیکی و آب زیرزمینی می‌باشند که توسط Shukla and Wood (2008) و Bloomfield and Marchant (2013) پیشنهاد شدند. SRI و SGI با استفاده از روشی مشابه با شاخص SPI محاسبه می‌شوند (Shukla and Wood, 2008).

۲-۳- محاسبه شاخص SRGI

شاخص چند متغیره SRGI ترکیبی از دو شاخص خشکی آب زیرزمینی SGI و آب سطحی SRI می‌باشد (Feng et al., 2020). به‌منظور محاسبه شاخص مزبور، نیاز به استخراج تابع احتمالاتی مشترک دو شاخص SGI و SRI با استفاده از ویژگی توابع کاپولا می‌باشد (Feng et al., 2020). بدین ترتیب که با داشتن توابع

۲-۲- محاسبه SPI، SRI و SGI

خشکسالی هواشناسی، با استفاده از شاخص ماهانه SPI، محاسبه می‌شود (McKee et al., 1993; Mishra and Disai, 2005). رابطه ۱، محاسبه شاخص SPI را نشان می‌دهد (Tsakiris and Vangelis, 2004). برای این منظور، توزیع احتمال بهترین برازش بارش ماهانه و احتمال توزیع تجمعی انتخابی، محاسبه می‌شود. مقادیر SPI با استفاده از کوانتایل توزیع $N(0,1)$ ، در ازای مقادیر احتمال تجمعی به‌دست می‌آیند

$$SPI_i = F_1^{-1}(P_i) \quad (1)$$

که در آن SPI_i خشکسالی هواشناسی (بدون بعد)، F_1^{-1} کوانتایل بهترین برازش احتمال توزیع تجمعی بارش ماهانه و P_i احتمال تجمعی مربوط به بارش در ماه i است. مقادیر منفی SPI بیان‌گر وضعیت خشکسالی است. مقدار SPI مثبت بیان‌گر شرایط

پارامترهای هر یک را نشان می‌دهد. برازش تابع کاپولای پیشنهادی با کمک کد نویسی در نرم افزار R و انجام آزمون K-S در سطح معنادار ۵ درصد، انجام گرفت ($p \text{ value} > 0.05$). سپس تابع پیشنهادی کاپولا با دو ملاک RMSE و AIC، مورد ارزیابی نهایی قرار گرفت. با دستیابی تابع توزیع احتمال اشتراکی، مقادیر احتمال تجمعی متناظر با هر یک از مقادیر SGI و SRI، تعیین می‌شود. سپس با استفاده از نگاشت معکوس تابع توزیع نرمال استاندارد، مطابق با رابطه ۳، اقدام به محاسبه شاخص SRGI شد. که در آن φ تابع توزیع نرمال استاندارد است.

$$SRGI = \varphi^{-1}(P) \quad (3)$$

توزیع احتمالی SRI و SGI به عنوان توابع حاشیه‌ای، توزیع مشترک با احتمال تجمعی P را می‌توان با تابع کاپولای مناسب C از رابطه ۲ محاسبه نمود (Zhang and Singh, 2019).

$$P(X \leq x, Y \leq y) = C[F(X), G(Y)] = P \quad (2)$$

که در آن C بهترین تابع کاپولا و $F(X)$ و $G(Y)$ به ترتیب، توابع توزیع تجمعی و حاشیه‌ای هستند. به منظور دستیابی به تابع کاپولای قابل برازش به متغیرهای حاشیه‌ای، نیاز به بررسی و آزمون نمودن توابع کاپولای پیشنهادی می‌باشد (Feng et al., 2020). در پژوهش حاضر از چهار تابع کاپولای فرانک، کلایتون، گامبل و جو استفاده شد. جدول ۱ توابع کاپولا و دامنه تغییرات

جدول ۱- اسامی توابع کاپولای بررسی شده (Feng et al., 2020)

Table 1. Names of the studied copula functions (Feng et al., 2020)


Copula	Function	Parameter Space
Frank	$C(u, v) = -\frac{1}{\theta} \ln \left[1 + \frac{(e^{-\theta u} - 1)(e^{-\theta v} - 1)}{e^{-\theta} - 1} \right]$	$\theta \in R/0$
Clayton	$C(u, v) = \max(u^{-\theta} + v^{-\theta} - 1, 0)^{-\frac{1}{\theta}}$	$\theta \in [-1, \infty)/0$
Gumbel	$C(u, v) = \exp \left\{ -[(-\ln(u))^{\theta} + (-\ln(v))^{\theta}]^{\frac{1}{\theta}} \right\}$	$\theta \in [1, \infty)$
Joe	$CDF = -1[(1-u)^{\theta} + (1-v)^{\theta} - (1-u)^{\theta} + (1-v)^{\theta}]^{\frac{1}{\theta}}$	$\theta \in [1, \infty)$

۲-۴- مدل‌ها

۲-۴-۱- مدل ANN

Haykin (1999) یک شبکه عصبی مصنوعی (ANN) را به عنوان گروهی از واحدهای پردازش ساده توصیف کرد. بزرگ‌ترین امتیاز شبکه عصبی، توانایی آن در مدل سازی داده‌های سری زمانی غیرخطی پیچیده می‌باشد. این مدل معمولاً دارای سه لایه می‌باشد. لایه اول، لایه ورودی است که داده را به شبکه معرفی می‌کند. لایه دوم بنام لایه پنهان است که داده‌ها درون آن پردازش می‌شوند. لایه آخر تحت عنوان لایه خروجی، نتایج داده ورودی در آن تولید می‌شود. لایه یا لایه‌های پنهان به منظور حل مسائل غیرخطی اضافه می‌شوند (Demuth and Beale, 2000). شبکه‌های عصبی جلو رونده تک لایه پنهانی، پرکاربردترین شکل مدل شبکه عصبی برای مدل سازی و شبیه سازی سری‌های زمانی است. نوروهای لایه

ورودی از طریق وزن‌های w_{ji} به لایه‌های میانی و نوروها در سطح میانی از طریق توده‌های w_{ki} به سطح‌های خروجی یا لایه‌های نهایی متصل می‌شوند. نمادهای i^{th} ، j^{th} ، k^{th} یا i ، j و k به ترتیب نشان‌دهنده نوروها در لایه‌های ورودی، پنهان و خروجی هستند. آموزش یک شبکه، یک مرحله ضروری برای موفقیت شبکه‌های عصبی می‌باشد. برای کالیبراسیون مدل، وزن‌های ANN آماده و به صورت تکراری تنظیم می‌شوند (Bishop, 1995). از الگوریتم پس انتشار Levenberg-Marquardt (LM) و معماری پرسپترون چندلایه پیشرو (MLP) برای آموزش استفاده شد. MLP ها، به دلیل سادگی اغلب در شبیه سازی‌های هیدرولوژیکی مورد استفاده قرار می‌گیرند. شکل ۲ ساختار شبکه عصبی را نشان می‌دهد (Khan et al., 2020)




شکل ۲- ساختار شبکه عصبی

Figure 2. The structure of a neural network

دو خروجی است. ورودی‌ها: x_t مقدار ورودی است که وارد لایه می‌شود، c_t حافظه واحد فعلی و c_{t-1} حافظه واحد قبلی است. خروجی‌ها: h_{t-1} خروجی آخرین واحد LSTM، h_t خروجی شبکه جاری است. مدل LSTM قادر به حذف و اضافه کردن اطلاعات به سلول، توسط ساختاری به نام دروازه f_t است (Khan et al., 2020).

۲-۴-۲- مدل LSTM

حافظه کوتاه پایدار (LSTM) نوعی شبکه عصبی چرخه‌ای زمان است که به‌طور خاص برای حل مشکل همبستگی بلندمدت RNN عمومی استفاده می‌شود. حافظه کوتاه ابتدا در زمینه یادگیری عمیق مورد استفاده قرار گرفت. سپس توسط پژوهش‌گران در کارهای بعدی رواج یافت (Mbatha and Bencherif, 2020) همان‌طور که در شکل ۳ نشان داده شده، شبکه دارای سه ورودی و



شکل ۳- ساختار مدل LSTM

Figure 3. The structure of the LSTM model

صحت پیش‌بینی سری زمانی شاخص‌های تک متغیره و ارزیابی کاربرد آن در شاخص چند متغیره خشکسالی استفاده شد.

با توجه به موفقیت‌های چشم‌گیر شبکه LSTM در سری‌های زمانی تک متغیره از شبکه LSTM عمیق با سه لایه برای ارتقاء

۲-۴-۳- مدل ARIMA

به ترتیب ۲ و ۱ است. رابطه ۱۱، حداقل سطح تجزیه (L) را نشان می دهد

$$L = \text{int}(\log N_s) \quad (11)$$

که در آن، N_s تعداد داده های سری زمانی است.

۲-۴-۵- مدل های ترکیبی

علی رغم کاربرد مدل های ترکیبی در شبیه سازی متغیرهایی نظیر بارش، به دلیل ماهیت استوکاستیکی و حالت نایستایی و نیز پیچیدگی موجود در علل پژوهش مقادیر مختلف متغیرهای مزبور، به منظور دست یابی صحت بیش تر در شبیه سازی، نیاز به پردازش اولیه داده ها و دستیابی حداکثری به چگونگی ساختار تولید داده های متغیر مورد مطالعه، می باشد (Zubaidi et al., 2018; Nourani et al., 2019). انجام پیش پردازش مزبور و سپس شبیه سازی داده های پردازش شده، در قالب مدل هایی تحت عنوان مدل های ترکیبی یا هیبریدی صورت می گیرد (Zubaidi et al., 2018). بسیاری از پژوهش گران استفاده از این گونه مدل ها را برای دستیابی به صحت بیش تر پیش بینی ها، توصیه نموده اند (Zhang et al., 2017; Khan et al., 2020; Adnan et al., 2021). نقاط قوت تبدیل موجک، میانگین متحرک یکپارچه اتورگرسیو (ARIMA)، شبکه عصبی مصنوعی (ANN) و حافظه کوتاه بلندمدت (LSTM) را در غالب دو مدل ترکیبی جدید W-2A و W-AL برای شبیه سازی خشکسالی بر اساس شاخص ترکیبی جدیدی به کار برده است. لذا به دلیل استفاده هم زمان از برتری سه مدل مشهور Wavelet، ANN و LSTM که در نتایج پژوهش (Khan et al., 2020) آورده شده است. دو مدل W-2A و W-AL در پژوهش نسبت به سایر مدل های ترکیبی، انتخاب شدند. در ادامه مدل ترکیبی استفاده شده در پژوهش حاضر ارائه می گردد.

۲-۴-۵-۱- مدل W-2A

فرایند ساخت مدل ترکیبی W-2A (Wavelet ARIMA ANN) مشتمل بر تجزیه سری زمانی داده ها به دو سری، تحت عناوین تقریب A و بسته به سطح تجزیه، سری جزئی D_1, D_2, D_3 ، می باشد. تجزیه سری، با استفاده از تبدیل موجک گسسته DWT و با کمک کد دستوری نوشته شده در محیط R، انجام می شود. پس از تجزیه، سیگنال های فرکانس پایین (تقریبی) تخمین زده شده توسط یک مدل پیش بینی ARIMA استفاده می شود. سیگنال های جزئیات (دقیق) به تنهایی با یک شبکه عصبی آموزش داده می شوند. هر یک از سری ها، به ترتیب، با مدل ARIMA و مدل ANN،

مدل ARIMA (Box et al., 2015)، در بسیاری از زمینه ها از انعطاف پذیری بالایی برخوردار است (Hernandez et al., 2020; Khan et al., 2020; Wu et al., 2021). ARIMA یک مدل خودرگرسیون تصادفی برای پیش بینی آینده استفاده می شود. مدل ARIMA به طور عمومی ترکیبی از اتورگرسیو (AR)، درجه نایستایی (I) و میانگین متحرک (MA)، به ترتیب، پارامترهای d, p, q ، تشکیل شده است. شکل عمومی مدل به صورت ARIMA (p, d, q) شناخته می شود. فرایند مدل سازی ARIMA از سه مرحله تشخیص، تخمین پارامترها و اعتبارسنجی تشکیل شده است (Khan et al., 2020). در پژوهش حاضر مدل سازی ARIMA با کمک کتابخانه های مرتبط در محیط برنامه نویسی R انجام شده است. در این مدل ابتدا به بررسی وجود مؤلفه های روند یا فصلی پرداخته شد که اگر این مقادیر وجود داشته باشند، باید آن ها را به کمک تکنیک های استاندارد حذف نمود. سپس توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) برای شناسایی مدل AR و MA رسم شد. پس از آن درجه مدل ARIMA انتخاب شد و سپس با محاسبه معیارهای نیکویی برازش مانند RMSE، MSE و ME بهترین مدل ARIMA برای شاخص های خشکسالی انتخاب شد.

۲-۴-۴- تبدیل گسسته موجک DWT

تحلیل موجک به دو نوع تبدیل موجک پیوسته (CWT) و گسسته (DWT) طبقه بندی شود. تبدیل موجک پیوسته (CWT) به دلیل محاسبات پیچیده و نیاز به زمان برای پردازش، به طور تصادفی برای پیش بینی ها استفاده نمی شوند. تبدیل موجک گسسته اغلب در کاربردهای پیش بینی استفاده می شود زیرا به زمان محاسبات کمتری نیاز داشته و کاربرد آن ساده تر است. در شبیه سازی متغیرهای مرسوم در منابع آب، معمولاً از تبدیل موجک گسسته (DWT) استفاده می شود. در پژوهش حاضر از تبدیل موجک گسسته (DWT) استفاده شده است. سری های زمانی گسسته منحصر به فرد را می توان با استفاده از DWT معکوس به یک سری سیگنال های تقریبی و جزئیات تجزیه کرد. DWT با رابطه زیر تعریف می شود.

$$\Psi_{m,n}(t) = \frac{1}{\sqrt{s_0^m}} \psi \left\{ \frac{t - n\tau_0 s_0^m}{s_0^m} \right\} \quad (10)$$


که در آن m و n اعداد صحیحی هستند که مقیاس و زمان را کنترل می کنند. $\Psi(t)$ موجک مادر، τ_0 نشان دهنده یک متغیر موقعیت با مقدار بیش تر از صفر، s_0 نشان دهنده یک مرحله تأخیر با مقدار ثابت بزرگ تر از ۱ است. بیش ترین انتخاب برای پارامترهای τ_0 و s_0

گسسته است. سپس سری تقریب که خطی فرض می‌شود، با استفاده از مدل ARIMA و سری‌های جزئی که غیرخطی هستند، با استفاده از مدل LSTM شبیه‌سازی می‌شوند. سرانجام سری مدل شده تقریب و سری مدل شده جزئی، استفاده از تبدیل معکوس موجک، ترکیب شده و بدین ترتیب سری مدل شده نهایی به‌دست می‌آید (Wu et al., 2021). شکل ۴ فلوچارت مدل‌سازی دو مدل ترکیبی W-2A و W-AL را نشان می‌دهد.

شبیه‌سازی می‌شوند. در پایان، با استفاده از تبدیل معکوس موجک، سری نهایی شبیه‌سازی شده، از ترکیب سری‌های مدل شده، به‌دست می‌آید (Khan et al., 2020).

۲-۵-۴-۲- مدل W-AL

فرایند ساخت مدل ترکیبی W-AL (Wavelet ARIMA LSTM) مشابه با مدل W-2A، عبارت از تجزیه سری زمانی داده‌ها به دو سری تقریب و جزئی، با استفاده از تبدیل موجک



شکل ۴- فرایند مفهومی مدل‌های ترکیبی W-2A و W-AL مبتنی بر موجک

Figure 4- Conceptual process of wavelet-based W-2A and W-AL hybrid models

۲-۶- معیارهای ارزیابی مدل‌ها

برای ارزیابی عملکرد مدل‌ها از ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) و میانگین خطا (ME) استفاده شد. معیارهای ME, RMSE و MAE به شرح زیر تعریف می‌شوند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [y_i - \hat{y}_i]^2} \quad (12)$$

$$ME = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (13)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (14)$$

که در آن y_i ، $\hat{y}_i$ به ترتیب تعداد داده ها، داده مشاهده شده و شبیه سازی شده هستند.

۳- نتایج و بحث

استفاده از ANN و LSTM، به طور منفرد، به دلیل محدودیت های مزبور، عملکرد مناسبی در شبیه سازی متغیرهای غیرخطی، نظیر شاخص خشکسالی نشان نمی دهد (Khan et al., 2020; Wu et al., 2021). از سوی دیگر، تبدیل موجک برای تحلیل روندهای سری های زمانی، به ویژه تغییرات و تناوب ها به یک تکنیک پذیرفته شده تبدیل شده است (Seo et al., 2019; Gu et al., 2020). تبدیل موجک به دلیل قابلیتی که در تفکیک دو مؤلفه تصادفی و معین مربوط به متغیر مورد مطالعه دارد، برای شبیه سازی داده های غیر ایستا استفاده می شود. (Khan et al., 2020; Wu et al., 2021). تبدیل موجک سیگنال ورودی را به فرکانس های مختلف تجزیه می کند (Belayneh et al., 2016) بنابراین خروجی صحیح تری برای مدل های داده محور ارائه می کنند (Seo et al., 2019). اخیراً روش های ترکیبی مورد توجه پژوهشگران قرار گرفته است به طوری که مدل های ترکیبی برتری چندین مدل مورد استفاده برای داده های سری زمانی را برای غلبه بر کاستی های هر مدل و بهبود صحت پیش بینی ترکیب می کنند (Khan et al., 2020; Wu et al., 2021). استفاده از روش شبکه عصبی، تحت عنوان روش ترکیبی موجک-عصبی، از جمله روش های ترکیبی است. به طوری که در روش مزبور، نقطه ضعف روش شبکه عصبی، مبنی بر ناتوانی آن ها برکنار آمدن با داده نالیستا، برطرف می شود (Belayneh et al., 2016; Seo et al., 2019).

در بیش تر موارد، مدل های ترکیبی به پیش بینی صحیح تری، نسبت به سایر مدل ها دست می یابند (Khan et al., 2020). همچنین، (Khan et al., 2020)، نقاط قوت موجک، میانگین متحرک (ARIMA) و شبکه عصبی مصنوعی (ANN) را به عنوان نمونه جدیدی از مدل ترکیبی برای پیش بینی واقعی تر خشکسالی ارائه دادند. آن ها نشان دادند که مدل ترکیبی Wavelet-ARIMA-ANN (W-2A) از هر یک از مدل های ANN و Wavelet-ANN بهتر عمل می کند و قابل اعتمادتر است. Wu et al (2021) در مطالعه ای با استفاده از نقاط قوت ARIMA، WT و LSTM، مدل ترکیبی جدید Wavelet-ARIMA-LSTM را برای پیش بینی بارندگی ماهانه ارائه نمودند. آن ها نشان دادند مدل Wavelet-ARIMA-LSTM در پیش بینی بارش ماهانه، نسبت به ARIMA و LSTM صحیح تر است.

۳-۱- نتایج مدل سازی ARIMA

بهترین مدل ARIMA برای هر یک از شاخص های خشکسالی SPI، SRI، SGI و SRGI با توجه به معیارهای ارزیابی در جدول ۲ نشان داده شده است.

جدول ۲- نتایج بهترین مدل ARIMA برای شاخص های

خشکسالی در مرحله آزمون

Table 2. Results of the best ARIMA model for drought indices in the test step

Index	ARIMA	ME	MAE	RMSE
SPI	(0,1,4)	-0.15	0.59	0.83
SRI	(3,0,3)	-0.13	0.68	0.88
SGI	(0,1,1)	-0.46	0.59	0.70
SRGI	(2,0,2)	-0.04	0.78	0.98

بهترین مدل ARIMA برای شاخص SPI مدل (۴.۱.۰) با RMSE ۰.۸۳، شاخص SRI مدل (۳.۰.۳) با RMSE ۰.۸۸، شاخص SGI مدل (۱.۱.۰) با RMSE ۰.۷ و شاخص SRGI مدل (۲.۰.۲) با RMSE ۰.۹۸ می باشد. نتایج مزبور با نتایج حاصل از مدل های ترکیبی، قابل مقایسه خواهد بود. همچنین ملاحظه می شود که عملکرد مدل تکی ARIMA، در شبیه سازی شاخص ترکیبی SRGI، در مقایسه با سه شاخص تکی دیگر، ضعیف تر است.

۳-۲- نتایج مدل W-2A

جدول ۳ همبستگی سری های جزئی D_1 ، D_2 و D_3 را با شاخص SRI را نشان می دهد. سری های D_2 و D_3 ، به ترتیب با ۰/۶۵ و ۰/۴۷ همبستگی بالاتری از میانگین نشان می دهند. از این رو بر اساس تحلیل های همبستگی، مؤلفه های D_2 و D_3 ، هر یک به تفکیک، برای ورودی به مدل ANN انتخاب شدند. از سوی دیگر، مؤلفه سری تقریبی غالب A_3 برای مدل سازی با مدل ARIMA، انتخاب شد.

جدول ۳- همبستگی سری های جزئی D_1 ، D_2 و D_3 حاصل از

موجک با شاخص SRI

Table 3. Correlation of detailed series D_1 , D_2 and D_3 extracted by wavelet with SRI index

Details	Correlation	Remark
D_1	0.27	Not ok
D_2	0.47	ok
D_3	0.65	ok
Mean	0.46	-

است، مقادیر RMSE بهترین مدل‌های W-2A برای هر یک از شاخص‌های SPI، SRI، SGI و SRGI به ترتیب ۰/۶۳، ۰/۷۱، ۰/۴۹ و ۰/۶۱ است.

بهترین مدل W-2A برای هر یک از شاخص‌های خشکسالی SPI، SRI، SGI و SRGI با توجه به معیارهای ارزیابی در جدول ۴ نشان داده شده است. همان‌طور که در جدول ۴ نشان داده شده

جدول ۴- ملاک‌های ارزیابی بهترین مدل‌های W-2A برای شاخص‌های SPI، SRI، SGI و SRGI



Table 4. Efficiency of the best W-2A models for SPI, SRI, SGI, and SRGI indices

Index	W-2A model			ME	MAE	RMSE
	Wavelet	ARIMA	ANN			
SPI	Lag=2	(2, 1, 2)	lag=2	0.14	0.49	0.63
	LD=1		N=10			
SRI	Lag=2	(2, 1, 3)	lag=3	0	0.53	0.71
	LD=2		N=10			
SGI	Lag=3	(2, 0, 2)	lag=4	0	0.34	0.49
	LD=2		N=15			
SRGI	Lag=3	(2, 0, 2)	lag=4	0	0.50	0.61
	LD=2		N=15			

مقایسه تعداد گام‌های تأخیر در تبدیل موجک و مدل شبکه عصبی است. همان‌گونه که ملاحظه می‌شود تعداد گام تأخیر شبکه عصبی، بزرگتر یا مساوی تعداد گام‌های تأخیر در تبدیل موجک است. از این رو در مدل‌سازی ترکیبی باید به این نکته نیز توجه نمود.


شکل ۶ نمودار مقادیر ماهانه شبیه شده SRGI با مدل W-2A را طی سال‌های ۱۳۹۳ تا ۱۳۹۹ با مقادیر حاصل از برازش توزیع احتمالی مربوطه، نشان می‌دهد. همان‌گونه که ملاحظه می‌شود، مدل ترکیبی W-2A توانسته ضمن ارائه الگوی تغییرات نمودار در نقاط بیشینه و کمینه، با خطای نسبتاً کمی، مقادیر واقعی شاخص مزبور را برآورد نماید.

همان‌طور که مشاهده می‌شود، به جزء SGI، مدل ترکیبی W-2A کم‌ترین مقدار RMSE را برای شاخص ترکیبی SRGI نشان می‌دهد. به‌منظور اطمینان بیش‌تر از عملکرد مدل ترکیبی W-2A در شاخص ترکیبی SRGI نسبت به عملکرد آن در شاخص‌های تکی، اقدام به محاسبه توزیع احتمالی حاکم بر باقی‌مانده‌های مقادیر شبیه‌سازی شده شاخص‌ها و از جمله شاخص SRGI، شد. به‌علت محدودیت صفحات، صرفاً توزیع خطای شاخص شبیه‌سازی شده SRGI در شکل ۵ نشان داده شده است. نرمال بودن توزیع خطاهای تخمین مدل و پراکندگی خطاها در شکل ۵ نشان می‌دهد که عملکرد مدل W-2A در شبیه‌سازی شاخص ترکیبی SRGI نسبت به شاخص‌های تکی مناسب‌تر است. نکته دیگر جدول ۴ عبارت از



شکل ۵- ارزیابی خطاهای SRGI شبیه‌سازی شده با مدل W-2A در مرحله اعتبار سنجی (a) هیستوگرام (b) پراکنش خطاها

Figure 5. Evaluation of errors SRGI simulated by W-2A in test step (a) histogram and (b) error scatter



شکل ۶- مقادیر شبیه‌سازی شده در مقابل داده‌های واقعی شاخص SRGI با مدل W-2A در مرحله آزمون (خط چین قرمز، داده‌های مشاهداتی و خط ممتد مشکی، داده‌های شبیه‌سازی شده)

Figure 6. Simulated values versus actual data of the SRGI index with the W-2A model in the test step (Red dashed line: observed data; solid black line: simulated data)

است. این در حالی است که مدل ترکیبی W-2A در شاخص ترکیبی SRGI عملکرد بهتری داشته است (جدول ۵). به نظر می‌رسد به دلیل پیچیده‌تر بودن مدل W-AL نسبت به مدل W-2A که به واسطه ترم LSTM ایجاد شده است، آموزش مدل W-AL نسبت به مدل W-2A از عدم قطعیت بیشتری برخوردار بوده است. از این رو نتایج ضعیف‌تری در شبیه‌سازی SRGI در مقایسه با مدل W-2A از خود نشان داده است. در شکل‌های ۷ و ۸ مقادیر شبیه‌سازی شده در مقایسه با مقادیر واقعی، نمودار پراکندگی و هیستوگرام خطا برای بهترین مدل ترکیبی W-AL برای شاخص خشکسالی SRGI در مرحله آزمایش نشان داده شده است.


۳-۳- نتایج مدل W-AL

بهترین مدل W-AL برای هر شاخص خشکسالی SPI، SRI، SGI و SRGI بر اساس معیارهای ارزیابی در جدول ۵ نشان داده شده است. همان‌طور که در جدول ۵ نشان داده شده است، مقادیر RMSE بهترین مدل W-AL برای شاخص‌های SPI، SRI، SGI و SRGI، به ترتیب ۰/۵۹، ۰/۶۲، ۰/۴۴ و ۰/۶۴ به دست آمده است. بدین ترتیب عملکرد مدل ترکیبی W-AL در مقایسه با مدل ترکیبی ARIMA جدول ۳ برای همه شاخص‌ها بهتر می‌باشد. این در حالی است که عملکرد مدل W-AL در مورد شبیه‌سازی شاخص ترکیبی SRGI در مقایسه با شاخص‌های ترکیبی ضعیف‌تر به دست آمده


جدول ۵- ملاک‌های ارزیابی بهترین مدل‌های W-AL برای شاخص‌های SPI، SRI، SGI و SRGI

Table 5. Efficiency of the best W-AL models for SPI, SRI, SGI, and SRGI indices

Index	W-AL			ME	MAE	RMSE
	Wavelet	ARIMA(A)	LSTM(D)			
SPI	Lag=2, LD=1	(2,1,2)	lag=2	0.28	0.45	0.59
SRI	Lag=3, LD=1	(1,0,1)	lag=3	0.22	0.49	0.62
SGI	Lag=3, LD=2	(1,0,2)	lag=3	-0.15	0.34	0.44
SRGI	Lag=4, LD=3	(2,1,4)	lag=4	0.05	0.50	0.64



شکل ۷- ارزیابی خطاهای SRGI شبیه‌سازی شده با مدل W-2A در مرحله اعتبار سنجی (a) هیستوگرام (b) پراکنش خطاها
Figure 7. Evaluation of errors SRGI simulated by W-AL in test step (a) histogram and (b) error scatter



شکل ۸- مقادیر شبیه‌سازی شده در مقابل داده‌های واقعی شاخص SRGI با مدل W-AL در مرحله آزمون (خط چین قرمز، داده‌های مشاهداتی و خط ممتد مشکی، داده‌های شبیه‌سازی شده)
Figure 8. Simulated values versus actual data of the SRGI index with the W-AL model in the test step (Red dashed line: observed data; solid black line: simulated data)

جدول ۶- ارزیابی مدل‌های ترکیبی ANN، ARIMA، و LSTM در شبیه‌سازی شاخص‌های SPI، SRI، SGI و SRGI

Table 6. Evaluation of single models ANN, ARIMA, and LSTM in simulation of SPI, SRI, SGI, and SRGI				
Index	Evaluation criteria	ANN	ARIMA	LSTM
SPI	ME	0.05	0.15	0.05
	MAE	0.06	0.59	0.98
	RMSE	0.78	0.83	1.36
SRI	ME	0.03	0.13	0.22
	MAE	0.57	0.68	1.13
	RMSE	0.78	0.88	1.47
SGI	ME	0.17	0.46	-0.16
	MAE	0.34	0.59	0.47
	RMSE	0.54	0.70	0.65
SRGI	ME	-0.1	-0.04	0.63
	MAE	0.84	0.78	1.23
	RMSE	1.06	0.98	1.46

پایش دقیق تر خشکسالی بواسطه استفاده از مدل‌های برتر و شاخص ترکیبی که در برگیرنده تعداد عوامل بیش‌تر موثر در وقوع خشکسالی هستند، تاثیر داشته باشد

سیاسگزاری

بدینوسیله نویسندگان مقاله از حمایت دانشگاه شهید چمران اهواز از طریق پژوهانه (SCU.WH1403.26878) قدردانی و سپاس خود را اعلام می‌دارند

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

محمدرضا شریفی: راهنمایی، مفهوم‌سازی، ارائه روش، تحلیل، ویرایش و بازبینی مقاله؛ **مهتاب نوری:** محاسبات نرم‌افزاری/آمار، نگارش نسخه اولیه مقاله؛ **مانیر حیات خان:** مشاوره و بازبینی متن مقاله.

منابع

چمن پیرا، غلامرضا، زهتابیان، غلامرضا، احمدی، حسن و ملکیان، آرشد (۱۳۹۳). بررسی تأثیر خشکسالی بر منابع آب زیرزمینی به‌منظور مدیریت بهینه بهره‌برداری، مطالعه موردی: دشت الشتر. مهندسی و مدیریت آب/بخش، ۶ (۱)، ۲۰-۱۰. doi: 10.22092/ijwmse.2014.101733
کالیراد، زهرا، ملکیان، آرشد و معتمد وزیری، بهارک (۱۳۹۲). تعیین الگوی توزیع منابع آب زیرزمینی (مطالعه موردی: حوزه آبخیز الشتر، استان لرستان)، پژوهشنامه مدیریت حوزه آبخیز، ۴ (۷)، ۵۷-۶۹.
<https://jwmr.sanru.ac.ir/article-1-236-fa.html>

References

Adnan, R., Mostafa, R., Islam, A., Gorgij, A., Kuriqi, A. & Kisi, O. (2021). Improving drought modeling using hybrid random vector functional link methods, *Water*, 13(23), 1-22. doi: 10.3390/w13233379

۳-۴- مدل‌های ترکیبی ANN، ARIMA و LSTM

جدول ۶ نتایج بهترین مدل‌های ترکیبی غیرخطی LSTM، ANN و ARIMA را برای شاخص‌های ترکیبی SGI، SPI و SRI و نیز شاخص ترکیبی SRGI نشان می‌دهد. همان‌گونه که ملاحظه می‌شود معیارهای ارزیابی ME، MAE و RMSE برای شبیه‌سازی شاخص‌های ترکیبی، با استفاده از مدل‌های ترکیبی، در مقایسه با شاخص ترکیبی SRGI، عملکرد بهتری نشان می‌دهد. به‌طوری‌که به‌عنوان نمونه مقدار RMSE شاخص‌های ترکیبی SGI، SPI و SRI در دامنه ۰/۵۷ تا ۱/۴۷ می‌باشد. این در حالی است که مقدار شاخص مزبور برای شاخص ترکیبی SRGI و به سه مدل ترکیبی، ۰/۹۸ تا ۱/۴۶ به‌دست آمده است. شایان ذکر است عملکرد دو مدل ترکیبی W-2A و W-AL در کلیه شاخص‌ها، اعم از ترکیبی و ترکیبی، نسبت به مدل‌های ترکیبی بسیار بهتر می‌باشد. به‌طوری‌که دامنه RMSE مدل‌های ترکیبی در همه شاخص‌ها، ۰/۴۹ تا ۰/۶۴ به‌دست آمده است. حال آنکه دامنه RMSE مدل‌های ترکیبی در همه شاخص‌ها، ۰/۵۶ تا ۱/۴۷ محاسبه شد.

۴- نتیجه‌گیری

در بین کلیه مدل‌های ترکیبی و ترکیبی، مدل‌های ترکیبی، در مقایسه با مدل‌های ترکیبی، عملکرد بهتری در شبیه‌سازی خشکسالی، مبنی بر همه شاخص‌ها، اعم از ترکیبی و ترکیبی، دارند. لذا می‌توان گفت مدل‌های ترکیبی، برای شبیه‌سازی و پایش خشکسالی، وسیله مناسب‌تری نسبت به مدل‌های ترکیبی هستند. این در حالی است که عملکرد دو مدل ترکیبی W-2A و W-AL، در شبیه‌سازی شاخص ترکیبی SRGI، متفاوت است. به‌طوری‌که عملکرد مدل ساده‌تر W-2A، در مقایسه با مدل پیچیده‌تر W-AL، در شبیه‌سازی SRGI، بهتر است. از این‌رو می‌توان گفت در شاخص‌های ترکیبی، علی‌رغم پیچیده شدن فرایند محاسباتی آن‌ها، ضرورتاً نیاز به استفاده از مدل ترکیبی پیچیده‌تر، نمی‌باشد. به‌طوری‌که مدل ترکیبی پیچیده‌تر W-AL برای شاخص ترکیبی SRGI لزوماً موجب ارتقاء صحت شبیه‌سازی نشد. به‌طورکلی می‌توان استفاده از مدل‌های ترکیبی را در مقایسه با مدل‌های ترکیبی، در پایش انواع خشکسالی، خصوصاً خشکسالی مبتنی بر شاخص‌های ترکیبی، نظیر SRGI توصیه نمود. نتایج پژوهش می‌تواند در راستای کاهش اثرات خشکسالی، از طریق

Aghelpour, P. & Varshavian, V. (2020). Forecasting different types of droughts simultaneously using multivariate standardized precipitation index (MSPI), MLP neural network, and imperialistic *Competitive Algorithm (ICA)*, *Complexity*, 2021, ID: 6610228, pp. 16. doi: 10.1155/2020/6610228

- Aghelpour, P., Bahrami, H. & Varshavian, V. (2021). Hydrological drought forecasting using multi-scalar stream flow drought index, stochastic models and machine learning approaches, in northern Iran, *Stochastic Environmental Research and Risk Assessment*, 35, 1615-1635. doi: 10.1007/s00477-020-01949-z
- Belayneh, A., Adamowski, J., Khalil, B., & Quilty, J. (2016). Coupling machine learning methods with wavelet transforms and the bootstrap and boosting ensemble approaches for drought prediction. *Atmospheric research*, 172, 37-47. doi: 10.1016/j.atmosres.2015.12.017
- Belayneh, A., Adamowski, J., & Khalil, B. J. S. W. R. M. (2016). Short-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet transforms and machine learning methods. *Sustainable Water Resources Management*, 2(1), 87-101. doi: 10.1007/s40899-015-0040-5
- Bishop, C.M. (1995). *Neural networks for pattern recognition*, Oxford university press, 477 pages.
- Bloomfield, J. P. & Marchant, B. P. (2013). Analysis of groundwater drought building on the standardized precipitation index approach, *Hydrology Earth System Sciences*, 17(12), 4769-4787. doi: 10.5194/hess-17-4769-2013
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*, 5th Edition: John Wiley & Sons, 720 pages.
- Chamanpira, G., Zehtabian, G., Ahmadi, H. & Malekian, A. (2014). Effect of drought on groundwater resources in order to optimize utilization management, case study: Plain Alashtar. *Watershed's Engineering and Management*, 6(1), 10-20. doi: 10.22092/ijwmse.2014.101733 [In Persian]
- Dehghani, M., Saghafian, B., Rivaz, F., & Khodadadi, A. (2017). Evaluation of dynamic regression and artificial neural networks models for real-time hydrological drought forecasting. *Arabian Journal of Geosciences*, 10(12), 1-13. doi: 10.1007/s12517-017-2990-4
- Demuth, H. & Beale, M. (2000). *Neural network toolbox for use with MATLAB*, Sixth edition: MathWorks, 846 pages.
- Feng, K., Su, X., Zhang, G., Javed, T. & Zhang, Z. (2020). Development of a new integrated hydrological drought index (SRGI) and its application in the Heihe River Basin, China, *Theoretical and Applied Climatology*, 141(1), 43-59. doi: 10.1007/s00704-020-03184-6
- Gu, L., Chen, J., Yin, J., Xu, C. Y. & Chen, H. (2020). Drought hazard transferability from meteorological to hydrological propagation. *Journal of Hydrology*, 585, doi: 10.1016/j.jhydrol.2020.124761
- Hao, Z., AghaKouchak, A. (2013). Multivariate standardized drought index: A parametric multi-index model, *Advances in Water Resources*, 57, 12-18. doi: 10.1016/j.advwatres.2013.03.009
- Hernandez, A., Fujita, H., Hayashi, T. & Perez, H. (2020). Forecasting of COVID19 per regions using ARIMA models and polynomial functions. *Applied soft computing*, 96. doi: 10.1016/j.asoc.2020.106610
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*, 2th edition: IEEE, 700 pages.
- Kalirad, Z., Malekian, A. & Motamedvaziri, B. (2013). Determining of groundwater resources distribution pattern (Case Study: Alashtar basin, Lorestan province), *Journal of Watershed Management Research*, 4(7), 57-69, dor: JR_JWMR-4-7_005 [In Persian]
- Kao, S. C. & Govindaraju, R. S. (2010). A copula-based joint deficit index for droughts. *Journal of Hydrology*, 380(1-2), 121-134. doi: 10.1016/j.jhydrol.2009.10.029
- Karimi, M., Melesse, A. M., Khosravi, K., Mamuye, M. & Zhang, J. (2019). Analysis and prediction of meteorological drought using SPI index and ARIMA model in the Karkheh River Basin, Iran. *Extreme Hydrology and Climate Variability*, 343-353. doi: 10.1016/B978-0-12-815998-9.00026-9
- Khan, M. M. H., Muhammad, N. S. & El-Shafie, A. (2020). Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting. *Journal of Hydrology*, 590, doi: 10.1016/j.jhydrol.2020.125380
- Mbatha, N. & Bencherif, H. (2020). Time series analysis and forecasting using a novel hybrid LSTM data-driven model based on empirical wavelet transform applied to total column of ozone at Buenos Aires, Argentina (1966-2017). *Atmosphere*, 11(5), 457. doi: 10.3390/atmos11050457
- Mishra, A.K. & Desai, V.R. (2005). Spatial and temporal drought analysis in the Kansabati river basin, India. *International Journal of River Basin Management*, 3, 31-41. doi: 10.1080/15715124.2005.9635243
- McKee, T. B., Doesken, N. J. & Kleist, J. (1993). The relationship of drought frequency and duration to time scales, 8th Conference on Applied Climatology, Anaheim, California, pp. 179-183.
- Mehdizadeh, S., Fathian, F. & Adamowski, J. F. (2019). Hybrid artificial intelligence-time series models for monthly stream flow modeling. *Applied Soft Computing*, 80, 873-887. doi: 10.1016/j.asoc.2019.03.046
- Mohamadi, S., Sammen, S. S., Panahi, F., Ehteram, M., Kisi, O., Mosavi, A. & Al-Ansari, N. (2020). Zoning map for drought prediction using integrated machine learning models with a nomadic people optimization algorithm. *Natural Hazards*, 104, 537-579. doi: 10.1007/s11069-020-04180-9
- Ndlovu, M.S., & Demlie, M. (2020). Assessment of meteorological drought and wet conditions using two drought indices across KwaZulu-natal province, South Africa. *Atmosphere*, 11(6), 623. doi: 10.3390/atmos11060623

- Nourani, V., Razzaghzadeh, Z., Baghanam, A. H. & Molajou, A. (2019). ANN-based statistical downscaling of climatic parameters using decision tree predictor screening method. *Theoretical and Applied Climatology*, 137, 1729-1746. doi: 10.1007/s00704-018-2686-z
- Seo, J.Y., & Lee, S.I. (2019). Spatio-temporal groundwater drought monitoring using multi-satellite data based on an artificial neural network, *Water*, 11(9), 1953. doi: 10.3390/w11091953
- Shukla, S., & Wood, A.W. (2008). Use of a standardized runoff index for characterizing hydrologic drought. *Geophysical Research Letters*, 35(2). doi: 10.1029/2007GL032487
- Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F. (2018). Application of artificial intelligence models for the prediction of standardized precipitation evapotranspiration index (SPEI) at Langat River Basin, Malaysia. *Computers and Electronics in Agriculture*, 144, 164-173. doi: 10.1016/j.compag.2017.12.002
- Tsakiris, G., & Vangelis, H. (2004). Towards a drought Watch System based on Spatial SPI. *Water Resources Management*, 18, 1-12. doi: 10.1023/B:WARM.0000015410.47014.a4
- Van Loon, A. F. (2015). Hydrological drought explained. *WIREs WATER*, 2(4), 359-392. doi: 10.1002/wat2.1085
- Williams, A. P., Cook, E. R., Smerdon, J. E., Cook, B. I., Abatzoglou, J. T., Bolles, K., Baek, S. H., Badger, A. M. & Livneh, B. (2020). Large contribution from anthropogenic warming to an emerging North American megadrought. *Science*, 368(6488), 314-318. doi: 10.1126/science.aaz9600
- Wu, X., Zhou, J., Yu, H., Liu, D., Xie, K., Chen, Y., Hu, J., Sun, H. & Xing, F. (2021). The Development of a hybrid Wavelet-ARIMA-LSTM model for precipitation amounts and drought analysis. *Atmosphere*, 12, 74. doi: 10.3390/atmos12010074
- Wu, Z., Yin, H., He, H. & Li, Y. (2022). Dynamic-LSTM hybrid models to improve seasonal drought predictions over China. *Journal of Hydrology*, 615, part A, doi: 10.1016/j.jhydrol.2022.128706
- Xu, D., Zhang, Q., Ding, Y. & Zhang, D. (2022). Application of a hybrid ARIMA-LSTM model based on the SPEI for drought forecasting, *Environmental Science and Pollution Research*, 29, 4128-4144. doi: 10.1007/s11356-021-15325-z
- Yisihak, B. & Zenebe, A. (2021). Modeling multivariate standardized drought index based on the drought information from precipitation and runoff: a case study of Hare watershed of Southern Ethiopian Rift Valley Basin. *Modeling Earth Systems and Environment*, 7(2), 1005-1017. doi: 10.1007/s40808-020-00923-6
- Zhang, L. & Singh, V. P. (2019). Copulas and their applications in water resources engineering, 1st edition: Cambridge university press, 616 pages.
- Zhang, Y., Li, W., Chen, Q., Pu, X., & Xiang, L. (2017). Multi-models for SPI drought forecasting in the north of Haihe River Basin, China, Stochastic. *Environmental Research and Risk Assessment*, 31, 2471-2481. doi: 10.1007/s00477-017-1437-5
- Zubaidi, S. L., Dooley, J., Alkhaddar, R. M., Abdellatif, M., Al-Bugharbee, H. & Ortega-Martorell, S. (2018). A Novel approach for predicting monthly water demand by combining singular spectrum analysis with neural networks. *Journal of Hydrology*, 561, 136-145. doi: 10.1016/j.jhydrol.2018.03.047