

EXTENDED ABSTRACT

Performance evaluation of ANN-WOA and ANN-BWO simulation-optimization methods in predicting daily runoff (case study: Jelogir station in Karkheh watershed)

E. Merufinia¹, A. Sharafati^{2*}, H. Abghari³ and Y. Hassanzadeh⁴

1- Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2*- Corresponding Author, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran (asharafati@srbiau.ac.ir).

3-Department of Range and Watershed Management, Urmia University, Urmia, Iran.

4-Department of Water Engineering, Center of Excellence, Faculty of Civil Engineering, University of Tabriz -Farazab Consulting Engineers, PMO, Tabriz, Iran .

ARTICLE INFO

Article history:

Received: 11 October 2022

Revised: 16 September 2023

Accepted: 17 September 2023

Keywords:

Black widow algorithm; Rainfall-Runoff prediction; correlation coefficient; Wavelet.

TO CITE THIS ARTICLE:

Merufinia, E., Sharafati, A., Abghari, H., Hassanzadeh, Y. (2024). 'Performance evaluation of ANN-WOA and ANN-BWO simulation-optimization methods in predicting daily runoff (case study: Jelogir station in Karkheh watershed)', *Irrigation Sciences and Engineering*, 47(3), pp. 19-36. doi: 10.22055/jise.2023.42026.2043.

Introduction

The key to social and economic development is water, an essential natural resource. Worldwide, many areas are experiencing water supply and demand mismatches or are under extreme stress due to water shortages. Water resources have been mismanaged or limited due to an increase in demand and limitations in available water supply (Banadkooki et al., 2019). Rainfall and runoff are considered to be the main components of the hydrological cycle. In order to capture the dynamic relationship between rainfall and runoff, engineers need to develop an accurate model (Tikhmarine et al., 2022). Rainfall-runoff modeling is one of the methods of estimating runoff and a suitable tool for studying hydrological processes, evaluating water resources and watershed management (Abrahart and See, 2000). But the complexity and non-linear nature of the rainfall-runoff process and the unknown effect of the factors on each other and finally on the outflow of the basin make modeling more difficult (Moriasi et al., 2007). Therefore, it is necessary to use methods that, in addition to dynamism, have the ability to develop, have a conceptual and user-friendly structure (Shi et al., 2012). The role and importance of the mentioned process in water resources studies has caused this process to be noticed by experts (Guvén, 2009). Therefore, several methods such as artificial neural networks, fuzzy and neuro-fuzzy systems, wavelet analysis, genetic algorithm, genetic programming and stochastic differential equations have been developed to model the rainfall-runoff process (Yaseen et al., 2016; Zhang et al., 2019). The development of rainfall-runoff models using different AI models has been conducted several times in the past two decades, but these models still have several shortcomings. These drawbacks are usually related to overfitting, difficulty in initializing the internal parameters related to these models and proposing the proper input-output architecture of the model (Ahmed et al., 2019).

Methodology

Rainfall measurements are considered a basis for any hydrological modelling. In this research, in order to model the rainfall-runoff process, rainfall and discharge variables at different delays were used as input variables and discharge as output variables. In order to develop the model, the first step is to split the data into different classes to train, validate and test the model performance. The main importance of such step is to assure that the model would perform with consistent level of accuracy in case that the model experienced unseen data rather than those in the training. Debit was used from one day delay to four days delay and precipitation was also used up to six days delay. Then Pearson's correlation coefficient was used to find the relationship between input and output variables. Finally, based on the correlation coefficient, the best input model combination was selected. The time series of the research data is daily and the ten-year discharge and precipitation statistics were used and a radar chart was drawn between the variables. An artificial neural network was used for modeling. In order to find the optimal weight and bias coefficients, meta-heuristic algorithms of black spider and whale were used. Also, to evaluate the model, the indices of RMSE, MAE and PBIAS were used.

To evaluate the accuracy and performance of the model, we use the evaluation criteria according to the equations (31) to (35) as follows:

The Root mean square error (RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{prd} - Q_{obs})^2} \quad (0 < RMSE < \infty) \quad (1)$$

The coefficient of determination (R² score):

$$R^2 = 1 - RSE \quad (0 < R^2 < 1) \quad (2)$$

Mean Absolute Error (MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_{prd} - Q_{obs}| \quad (0 < MAE < \infty) \quad (3)$$

Coefficient of correlation (R):

$$R = \frac{\sum_{i=1}^N (Q_{obs} - \bar{Q}_{obs})(Q_{prd} - \bar{Q}_{prd})}{\sqrt{\sum_{i=1}^N (Q_{obs} - \bar{Q}_{obs})^2 \sum_{i=1}^N (Q_{prd} - \bar{Q}_{prd})^2}} \quad (-1 < R < +1) \quad (4)$$

Results and Discussion

In this research, the correlation coefficient was used to find the relationship between the input and output variables. The results of the research show that the flow rate with a one-day delay had the highest correlation with the output flow rate. Also, after choosing the best combination of the input model from the artificial neural network to predict the process Precipitation-runoff was used and black spider and whale algorithms were used to optimize the weighting and bias coefficients. The final results showed that all the models had a very good performance in forecasting and were able to predict the result of the model in a single mode. Finally, a box diagram and time series and data dispersion were used.

Conclusions

According to the RMSE criteria, it can be said that the ANN-WOA model has the best performance in predicting the rainfall-runoff process. Also, all the mentioned models showed a very good performance in the forecasting process. Based on this, the ANN-WOA model has been able to

improve the accuracy of a single model by 32.4%, the ANN-BWO model by 27.6% and the WANN network by 22.4%.

Acknowledgments

The authors thank the officials of Islamic Azad University and Shahid Chamran University of Ahvaz, especially the officials and staff of the Faculty of Water and Environmental Engineering of Shahid Chamran University of Ahvaz for providing the necessary facilities and conditions for this research.

Reference

- 1- Abrahart, R.J. and See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological processes*, 14(11-12), pp.2157-2172. Doi: 10.1002/1099-1085(20000815/30)14:11/12<2157::AID-HYP57>3.0.CO;2-S.
- 1- Ahmed, A. N., Othman, F. B., Afan, H. A., Ibrahim, R. K., Fai, C. M., Hossain, M. S., ... & Elshafie, A. (2019). Machine learning methods for better water quality prediction. *Journal of Hydrology*, 578, 124084. <https://doi.org/10.1016/j.jhydrol.2019.124084>.
- 2- Banadkooki, F. B., Ehteram, M., Ahmed, A. N., Fai, C. M., Afan, H. A., Ridwam, W. M., ... & El-Shafie, A. (2019). Precipitation forecasting using multilayer neural network and support vector machine optimization based on flow regime algorithm taking into account uncertainties of soft computing models. *Sustainability*, 11(23), 6681. <https://doi.org/10.3390/su11236681>.
- 3- Guven, A. (2009). Linear genetic programming for time-series modelling of daily flow rate. *Journal of earth system science*, 118(2), 137-146.
- 2- Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D. and Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), pp.885-900.
- 3- Shi, J., Guo, J. and Zheng, S., 2012. Evaluation of hybrid forecasting approaches for wind speed and power generation time series. *Renewable and Sustainable Energy Reviews*, 16(5), pp.3471-3480. Doi: 10.1016/j.rser.2012.02.044.
- 4- Tikhamarine, Y., Souag-Gamane, D., Ahmed, A.N., Sammen, S.S., Kisi, O., Huang, Y.F. and El-Shafie, A., 2020. Rainfall-runoff modelling using improved machine learning methods: Harris hawks optimizer vs. particle swarm optimization. *Journal of Hydrology*, 589, p.125133. <https://doi.org/10.1016/j.jhydrol.2020.125133>
- 4- Yaseen, Z.M., El-Shafie, A., Afan, H.A., Hameed, M., Mohtar, W.H.M.W. and Hussain, A., 2016. RBFNN versus FFNN for daily river flow forecasting at Johor River, Malaysia. *Neural Computing and Applications*, 27, pp.1533-1542.
- 5- Zhang, D., Peng, X., Pan, K. and Liu, Y., 2019. A novel wind speed forecasting based on hybrid decomposition and online sequential outlier robust extreme learning machine. *Energy conversion and management*, 180, pp.338-357. Doi: 10.1016/j.enconman.2018.10.089.



ارزیابی عملکرد روش‌های شبیه‌سازی-بهینه‌سازی ANN-WOA و ANN-BWO در پیش‌بینی رواناب روزانه (مطالعه موردی: ایستگاه جلوگیر در حوضه آبریز کرخه)

ادریس معروفی نیا^۱، احمد شرافتی^{۲*}، هیراد عبقری^۳ و یوسف حسن زاده^۴

- ۱- دانشجوی دکتری، گروه مدیریت ساخت و آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
- ۲- نویسنده مسئول، دانشیار، گروه مدیریت ساخت و آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (asharafati@srbiau.ac.ir)
- ۳- دانشیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه ارومیه، ایران.
- ۴- استاد، گروه مهندسی آب، قطب علمی هیدروانفورماتیک، دانشکده مهندسی عمران، دانشگاه تبریز، شرکت مهندسی مشاور فراز آب، دفتر برنامه‌ریزی و مدیریت طرح‌ها، تبریز، ایران.

پذیرش: ۱۴۰۲/۰۶/۲۶

بازنگری: ۱۴۰۲/۰۶/۲۵

دریافت: ۱۴۰۱/۰۷/۱۹

چکیده

مدل‌سازی بارش-رواناب روزانه به دلیل تعدد عوامل مؤثر آن، یکی از پیچیدگی‌های علم هیدرولوژی است. ترکیب‌های مختلفی از عوامل بارش-رواناب، طی دوره آماری ۱۰ ساله (۱۳۹۰-۱۴۰۰) به عنوان ورودی برای تخمین رواناب در مقیاس زمانی روزانه مورد ارزیابی قرار گرفت. از ۸۰ درصد داده‌ها به عنوان آموزش (۲۹۲۰ نمونه) و ۲۰ درصد داده‌ها به عنوان آزمون (۷۳۰ نمونه) استفاده گردید. عوامل ورودی شامل بارش (P) و دبی (Q) که برای بارش تا شش تأخیر و برای دبی تا چهار تأخیر استفاده گردید. از ضریب همبستگی پیرسون برای ارتباط بین متغیرهای ورودی و خروجی استفاده گردید. بر این اساس ترکیب مدل شماره یک شامل بارش و دبی، دارای بیشترین همبستگی (۰/۸۰۵) و ترکیب سیزدهم (بارش و بارش از یک تا شش روز تأخیر و دبی از یک تا چهار روز تأخیر) دارای کمترین همبستگی (۰/۱۰۹) بوده است. به منظور مدل‌سازی از مدل‌های شبکه عصبی مصنوعی-الگوریتم بهینه‌سازی نهنگ (ANN-WOA)، شبکه عصبی مصنوعی-الگوریتم بهینه‌سازی عنکبوت سیاه (ANN-BWO) و مدل شبکه عصبی-موجک کلاه مکزیکی (WANN) استفاده گردید. همچنین برای ارزیابی مدل از شاخص‌های ریشه میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE)، ضریب بهره‌وری نش-ساتکلیف (NSE) و ضریب ناریبی (PBIAS) استفاده گردید. یافته‌های پژوهش نشان می‌دهد که کلبه مدل‌های فوق عملکرد بسیار خوبی در پیش‌بینی فرایند بارش-رواناب از خود نشان دادند. در این بین مدل ANN-BWO دارای بهترین عملکرد در پیش‌بینی بوده است. همچنین مدل‌های ANN-WOA و WANN و ANN-BWO به ترتیب ۳۲/۴ و ۲۷/۶ و ۲۲/۱۴ درصد دقت مدل منفرد شبکه عصبی را بهبود بخشیدند.

کلید واژه‌ها: الگوریتم عنکبوت سیاه، پیش‌بینی رواناب روزانه، ضریب همبستگی، شبکه عصبی موجکی.

مقدمه

پیش‌بینی دقیق فرایند رواناب روزانه برای برنامه‌های مدیریت منابع از قبیل کنترل سیلاب، احداث سد و سایر سازه‌های هیدرولیکی، بهره‌برداری از مخزن تامین آب و سیستم‌های برق‌آبی ضروری است (Kember et al., 1993). لذا پیش‌بینی دقیق فرایند مذکور و الگوهای آن برای پروژه‌های برنامه‌ریزی و مدیریت منابع آب حیاتی است. علاوه بر این، پیش‌بینی جریان آب می‌تواند اطلاعات قابل توجهی را برای توسعه طراحی پایدار زیرساخت آب، بررسی رفتار رودخانه‌ها برای اهداف عملیاتی و اجرایی، ارزیابی کیفیت آب، برآورد قیمت آب، و اتخاذ شیوه‌های کشاورزی پایدار در اختیار هیدرولوژیست‌ها قرار دهد (Yaseen et al., 2016). تخمین دقیق جریان در یک حوضه آبریز به دلیل توزیع آشفته، تناوب در الگوهای جریان و روابط پیچیده و غیر خطی بین عناصر حوضه آبریز دشوار

است (Guyen, 2009). لذا به دلیل پیچیدگی، ویژگی پویا، تصادفی بودن و غیرخطی بودن آن که ناشی از تاثیر مکانیزم‌ها و ویژگی‌های فیزیکی متعدد درگیر در تولید آن، یعنی ویژگی‌های حوضه آبریز (توپوگرافی و شکل)، کاربری و پوشش زمین، تبخیر و تعرق و تغییرات آب و هوایی، پیش‌بینی فرایند فوق کار آسانی نخواهد بود (Chiang et al., 2004). روش‌های اصلی برای پیش‌بینی جریان شامل فرمول‌های تجربی، مدل‌های آماری، مدل‌سازی مفهومی مبتنی بر فیزیک و روش‌های داده-مینا می‌باشد. روابط تجربی روش‌های ساده‌ای هستند که بر اساس مجموعه داده‌های خاص و برای شرایط حوضه آبریز مشخص توسعه یافته‌اند، بنابراین، برای استفاده در حوضه‌های آبریز دیگر دقیق نیستند و در میان هیدرولوژیست‌ها چندان محبوب نیستند (Salas, 1980). از زمان انتشار تحقیقات Box و Jenkins (1970)، مدل‌های آماری کلاسیک-سری‌های زمانی

شبیه‌سازی فرآیند بارش-رواناب پرداختند. نتایج پژوهش فوق نشان داد که سیستم استنتاج عصبی فازی تطبیقی عملکرد بهتری نسبت به سایر مدل‌ها داشته است. Daneshvar Vousoughi و Samadzadeh (2021) به پیش‌بینی رواناب دشت اردبیل با رویکردهای پیش پردازش زمانی موجکی پرداختند. یافته‌های پژوهش فوق نشان می‌دهد که اعمال روش‌های پیش‌پردازش زمانی رفع نویز موجکی و استفاده از تبدیل موجک در پیش‌بینی رواناب روزانه با مدل شبکه عصبی مصنوعی به ترتیب به‌طور متوسط باعث بهبود ۴ و ۳۹ درصدی در مرحله آزمایش مدل گردیده است. Ghorbani et al., (2016) به مدل‌سازی رواناب روزانه با استفاده از مدل‌های هوشمند هیبریدی پرداختند. یافته‌های پژوهش فوق نشان داد که از بین مدل‌های ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، هیبرید موجک-ماشین بردار پشتیبان و هیبرید موجک-شبکه عصبی، مدل هیبرید موجک-شبکه عصبی با بیشترین دقت و کمترین خطا را داشته است. در این تحقیق به‌منظور شبیه‌سازی فرآیند رواناب روزانه ایستگاه جلوگیری اهواز در حوضه آبریز کرخه، از شبکه عصبی مصنوعی و مدل‌های فرا ابتکاری عنکبوت سیاه و نهنگ و مدل عصبی موجکی استفاده خواهیم نمود تا ضمن بهینه کردن ضرایب درونی وزن و بایاس در راستای کاهش خطای مدل و افزایش دقت آن اقدام گردد. در نهایت برای ارزیابی مدل از شاخص‌های مختلف استفاده خواهد و میزان افزایش دقت مدل‌ها مورد استفاده قرار گیرد.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه آبخیز رودخانه کرخه در غرب کشور ایران در مناطق میانی و جنوبی کوه‌های زاگرس قرار دارد. این حوضه از نظر تقسیمات کشوری جزء حوضه‌های درجه دو محسوب می‌گردد. حوضه آبریز رودخانه کرخه از حوضه‌های باز ایران است که در تقسیم‌بندی حوضه‌های آبریز ایران، حوضه فرعی به‌شمار می‌رود و زیر مجموعه حوضه آبریز خلیج فارس و دریای عمان است. مساحت کرخه برابر با ۵۱۵۲۷ کیلومتر می‌باشد. رودخانه ی کرخه، پس از کارون و دز سومین رودخانه ی بزرگ ایران از نقطه نظر آبدی محسوب می‌گردد. حوضه ی آبریز رودخانه‌ی کرخه بین ۴۶ درجه و ۷ دقیقه تا ۴۹ درجه و ۱۰ دقیقه شرقی، ۳۱ درجه و ۱۸ دقیقه تا ۳۴ درجه و ۵۸ دقیقه عرض شمالی واقع شده است. این حوضه با وسعتی در حدود ۵۰۰۰۰ کیلومتر مربع کیلومتر مربع، شامل استان‌های همدان، کرمانشاه، لرستان، ایلام، کردستان و خوزستان می باشد. شاخه های اصلی تشکیل دهنده ی رودخانه‌ی کرخه، رودخانه‌های گاماسیاب، قره‌سو، سیمره، چرداول و کشکان می‌باشند که زیر حوضه‌های اصلی کرخه را تشکیل می‌دهند. شکل (۱) موقعیت حوضه آبخیز کرخه را نشان می‌دهد.

جعبه سیاه، مانند میانگین متحرک خودهمبسته (ARMA)، میانگین متحرک خودهمبسته یکپارچه (ARIMA)، رگرسیون خطی (LR) و رگرسیون خطی چندگانه (MLR) به کار گرفته شده‌اند (Valipour and Montazar, 2012; Abudu et al., 2010). برخی از مدل‌های فیزیک-محور متداول که توسط محققان حوزه منابع آب مورد استفاده قرار می‌گیرد شامل سیستم مدل‌سازی هیدرولوژیکی (HEC-HMS) و ابزار ارزیابی آب و خاک (SWAT) می‌باشد. این مدل‌ها عموماً برای فرایندهای فیزیکی حوضه آبریز توسعه یافته‌اند و پدیده‌های حوضه آبریز را در مقیاس پیکسل در نظر می‌گیرند. لذا این مدل‌ها نیاز به تجزیه و تحلیل عمیق‌تری دارند و به مقادیر زیادی از داده‌های اندازه‌گیری شده دقیق به‌عنوان ورودی نیاز دارند (Yaseen et al., 2018). در دهه‌های اخیر، رویکردهای داده-مبنا (محاسبات نرم) توجه فرآیندهای در میان هیدرولوژیست‌ها یافته است. (Ahmed and Sarma, 2007; Afan et al., 2015). الگوریتم‌های هوش مصنوعی یادگیری ماشین، مدل‌های مفهومی هستند که می‌توانند روابط غیرخطی بین متغیرهای ورودی و خروجی‌ها را استخراج کنند (Maier et al., 2014). شبکه‌های عصبی مصنوعی رویکردی است که به‌طور گسترده در کاربردهای هیدرولوژیکی مورد استفاده قرار می‌گیرد، دو نوع یادگیری شامل یادگیری نظارت‌شده از قبیل شبکه عصبی مصنوعی پس‌انتشار پیشخور (FFBP)، تابع پایه شعاعی (RBF)، پرسپترون چند لایه (MLP) و شبکه عصبی رگرسیون تعمیم یافته (GRNN) و یادگیری غیرنظارتی از قبیل سیستم خودنگاشت (SOM) طبقه‌بندی شود (Abrahart and See, 2000; Danandeh Mehr et al., 2015). محبوبیت شبکه‌های عصبی مصنوعی به‌علت سرعت همگرایی و قابلیت تعمیم پایین آن‌ها کاهش یافته به‌خصوص زمانی که رکورد داده‌ها برای اهداف آموزشی کوتاه‌مدت مورد استفاده قرار گرفته است و دامنه داده‌های آزمایش خارج از محدوده مورد استفاده برای آموزش است که منجر به کمینه محلی و تعیین اولیه وزن‌ها به‌صورت تصادفی در هر شبیه‌سازی می‌باشد (Anusree and Varghese, 2016). یکی از راهکارهای اساسی برای بهینه‌کردن ضرایب وزنی و بایاس در شبکه‌های عصبی مصنوعی، استفاده از مدل‌های بهینه‌سازی فرا ابتکاری می‌باشد که با شبکه‌های عصبی ترکیب می‌گردد و تشکیل یک مدل هیبریدی را می‌دهد. مطالعه‌های گسترده‌ای در زمینه شبیه‌سازی فرآیند رواناب روزانه با استفاده از مدل‌های هوش مصنوعی انجام گرفته است. Ghorbani و Dehghani (2016) کاربرد شبکه‌های عصبی بیزین، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژن در تحلیل بارش - رواناب را مورد استفاده قرار دادند. نتایج پژوهش فوق نشان داد که شبکه عصبی بیزین عملکرد بهتری نسبت به سایر مدل‌ها شبیه‌سازی فرآیند رواناب روزانه داشته است. Salajegheh et al (2009) به بررسی کارایی روش‌های عصبی- فازی و مدل‌های آماری در

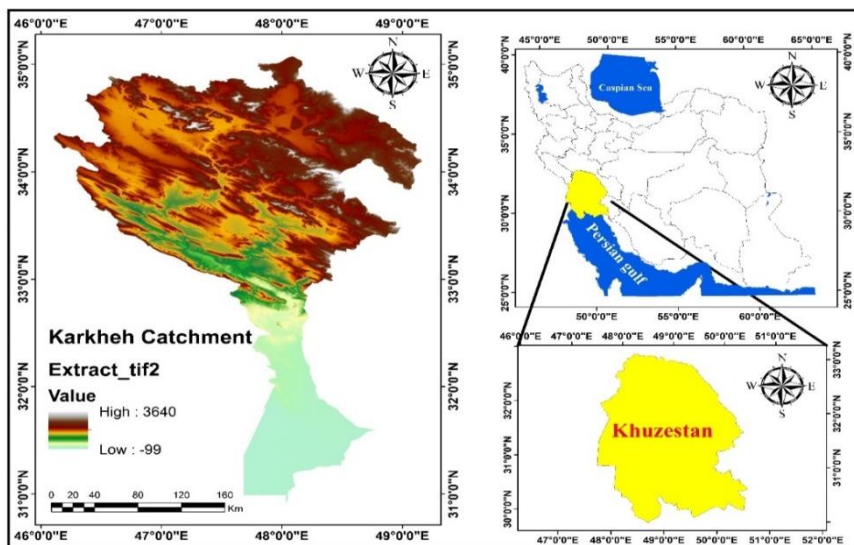


Fig. 1- The location of Karkheh watershed

شکل ۱- موقعیت حوضه آبخیز کرخه

همان گونه که در بخش بالا اشاره گردید دوره آماری ۱۰ ساله (۱۳۹۲-۱۳۴۸) به عنوان ورودی برای تخمین رواناب در مقیاس زمانی روزانه مورد ارزیابی قرار گرفت. تعداد کل داده های پژوهش ۳۶۵۰ رکورد می باشد که از ۸۰ درصد داده ها بعنوان آموزش (۲۹۲۰ رکورد) و ۱۰ درصد داده ها به عنوان آزمون (۳۶۵ رکورد) و ۱۰ درصد داده ها به عنوان اعتبارسنجی (۳۶۵ رکورد) استفاده گردید. جدول (۱) خلاصه پارامترهای آماری رایج (بیشینه، کمینه، میانگین، انحراف معیار، واریانس، ضریب تغییرات، چولگی و ضریب کشیدگی) بین متغیر ورودی (بارش بر حسب میلی متر) و دبی (بر حسب متر مکعب بر ثانیه) را نشان می دهد.

سناریوهای پژوهش و انتخاب بهترین ترکیب مدل

پدیده های مختلفی در پیش بینی رواناب روزانه تأثیرگذار هستند. از اثرات برخی از این متغیرها به علت ناچیز بودن مقدار و اثرات آنها می توان صرف نظر نمود. از مهم ترین عوامل در پیش بینی فرایند بارش-رواناب می توان به بارش و دبی اشاره نمود. در این پژوهش سناریوهای مختلفی بین متغیرهای ورودی و خروجی مورد بررسی قرار گرفت که در نهایت اثرات بارش و دبی با تأخیرهای مختلف مورد استفاده قرار گرفت. اثرات بارش با شش تأخیر و اثرات دبی با چهار تأخیر مورد ارزیابی قرار گرفت. بر این اساس برای پیدا کردن ارتباط بین متغیرهای ورودی و خروجی از ضریب همبستگی پیرسون استفاده گردید. مقدار ضریب همبستگی بین ۱ و -۱ می باشد. اگر این مقدار صفر باشد همبستگی بین داده ها وجود دارد. عدد +۱ همبستگی مستقیم و -۱ همبستگی معکوس بین متغیرهای ورودی و خروجی را

آماده سازی و پیش پردازش داده ها

به منظور پیش بینی فرایند رواناب روزانه، اطلاعات روزانه دبی و بارش ایستگاه هیدرومتری جلوگیری در بالا دست سد مخزنی کرخه، مربوط به ۱۴۰۰-۱۳۹۰ از سازمان آب و برق خوزستان جمع آوری گردید. دوره آماری ۱۰ ساله به عنوان ورودی برای تخمین رواناب در مقیاس زمانی روزانه مورد ارزیابی قرار گرفت. تعداد کل داده های پژوهش ۳۶۵۰ رکورد می باشد که از ۸۰ درصد داده ها به عنوان آموزش (۲۹۲۰ رکورد) و ۱۰ درصد داده ها به عنوان آزمون (۳۶۵ رکورد) و ۱۰ درصد نیز به عنوان اعتبارسنجی (۳۶۵ رکورد) استفاده گردید. پارامتر و متغیرهای ورودی شامل بارش بارش (P) و بارش تا شش تأخیر و دبی تا پنج تأخیر مورد استفاده قرار گرفته است. با توجه به این که داده های دارای گستره متفاوتی می باشند برای مدل سازی می بایست داده ها نرمال گردد. هدف نرمال سازی تبدیل ویژگی ها به یک مقیاس مشابه است. این باعث بهبود عملکرد و ثبات آموزش مدل می شود. رابطه (۱) نرمال کردن داده ها را نشان می دهد.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

که در این رابطه X_{norm} : داده نرمال شده، X : داده ای که می خواهیم نرمال کنیم، X_{max} و X_{min} : به ترتیب داده های کمینه و بیشینه هستند. داده های نرمال شده در بازه صفر و یک خواهند بود.

پارامترهای آماری داده های آموزش و آزمون

خروجی و درجه بندی آن‌ها را نشان می‌دهد. بر اساس مقادیر ضریب همبستگی، ترکیب مدل ورودی با توجه به رتبه و درجه هر متغیر ورودی با خروجی تشکیل می‌گردد. جدول (۳) ترکیب مدل ورودی بین متغیرهای ورودی و خروجی را نشان می‌دهد. همچنین برای نمایش گرافیکی همبستگی بین متغیرهای ورودی و خروجی از نمودار راداری (عنکبوتی) استفاده می‌گردد. این نمودار مقادیر سه متغیر یا بیشتر را نسبت به یک نقطه مرکزی با یکدیگر مقایسه می‌کند. شکل (۲) نمودار راداری بین متغیرهای ورودی و خروجی را نشان می‌دهد.

نشان می‌دهد. ضریب همبستگی از رابطه (۲) به صورت زیر به دست می‌آید:

$$r = \frac{\sum(x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \cdot \sum(y_i - \bar{y})^2}} \quad (2)$$

که در این رابطه r : ضریب همبستگی پیرسون، x_i : مقادیر متغیر x در یک نمونه یا رکورد، \bar{x} : میانگین مقادیر متغیر x ، y_i : مقادیر متغیر y در یک نمونه یا رکورد و \bar{y} : میانگین مقادیر متغیر y می‌باشند. مقدار ضریب همبستگی برابر یک می‌باشد و هر چه مقدار متغیرها به سمت عدد یک نزدیک باشد مقدار همبستگی بیشتر خواهد بود. جدول (۲) ضریب همبستگی پیرسون بین متغیرهای ورودی و

جدول ۱- پارامترهای آماری داده‌های آموزش و آزمون

Table 1- Statistical parameters of training and test datasets

Statistical parameters	Training phase (stage)		Training phase (stage)	
	P (mm)	Q(m ³ /s)	P (mm)	Q(m ³ /s)
Maximum	115	263	96	1689
Minimum	0	0	0	0
Mean	0.9712	34.992	1.396	117.795
Variance	25.5	1153.649	42.302	19317.554
standard deviation	5.049	33.965	6.504	138.987
Skewness	10.177	1.826	8.249	4.874
Kurtosis	146.848	4.926	89.332	43.445

جدول ۲- ضریب همبستگی پیرسون بین متغیرهای ورودی و خروجی و درجه بندی آن‌ها

Table 2- Pearson correlation coefficient between input and output variables and their ranking

inputs	P (t)	P (t-1)	P (t-2)	P (t-3)	P (t-4)	P (t-5)	P (t-6)	Q (t-4)	Q (t-3)	Q (t-2)	Q (t-1)
Quantity	0.325	0.280	0.215	0.180	0.133	0.109	0.0792	0.680	0.703	0.735	0.805
Rank	5	6	7	8	9	10	11	4	3	2	1

جدول ۳- ترکیب مدل‌های ورودی برای پیش‌بینی مقدار دبی خروجی

Table 3- Combination of input models to predict output streamflow rate

Scenario Number	Input variables	Output variable
1	Q(t-1)	Q(t)
2	Q(t-1), Q(t-2)	Q(t)
3	Q(t-1), Q(t-2), Q(t-3)	Q(t)
4	Q(t-1), Q(t-2), Q(t-3), Q(t-4)	Q(t)
5	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t)	Q(t)
6	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1)	Q(t)
7	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1), P(t-2)	Q(t)
8	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1), P(t-2), P(t-3)	Q(t)
0	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1), P(t-2), P(t-3), P(t-4)	Q(t)
10	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5)	Q(t)
11	Q(t-1), Q(t-2), Q(t-3), Q(t-4), P (t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), P(t-6)	Q(t)

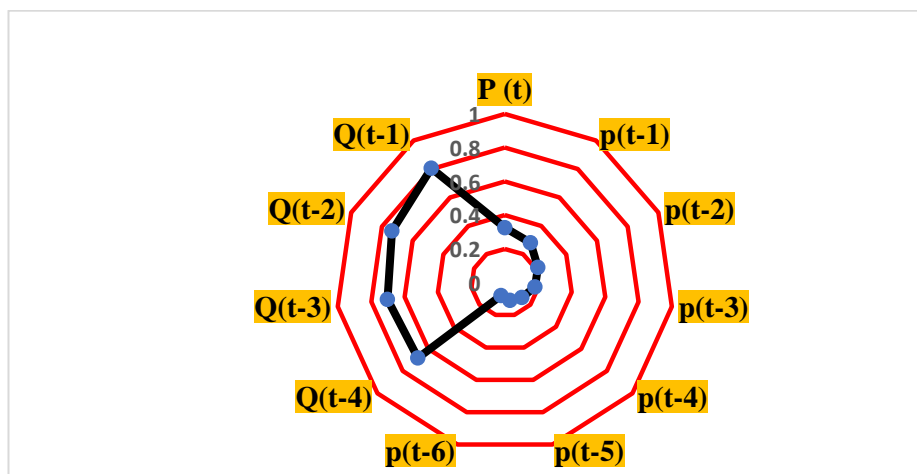


Fig. 2- Radar diagram between input and output variables based on Pearson correlation coefficient

شکل ۲- نمودار راداری بین متغیرهای ورودی و خروجی بر اساس ضریب همبستگی پیرسون

لایه خروجی برونند (Freire et al., 2019). ساختار ریاضی مدل پرسپترون چندلایه از رابطه (۳) به دست می آید:

$$y_i = f\left(\sum_{j=1}^N W_{ji} x_j + b_i\right) \quad (3)$$

که در این رابطه x_i برابر i امین مقدار گره لایه قبلی و y_i برابر با i امین مقدار گره لایه فعلی، b_i : بایاس گره i ام در لایه فعلی، W_{ji} : وزن اتصال x_j و y_i و N : تعداد گره ها در لایه قبلی و f : تابع فعال ساز در لایه فعلی می باشد (Mohanty et al., 2019).

$(x_1, x_2, \dots, x_{N_{var}})$ بدست می آید. بنابراین طبق رابطه (۵) خواهیم داشت:

$$\text{Fitness} = (\text{widow}) = f(x_1, x_2, \dots, x_{N_{var}}) \quad (5)$$

برای شروع الگوریتم بهینه سازی، یک ماتریس بیه نامزدهای اندازه $N_{pop} \times N_{var}$ با جمعیت اولیه عنکبوت ها تولید می شود. سپس جفت والدین به طور تصادفی انتخاب می شوند تا مرحله زایش را با جفت گیری انجام دهند که در آن عنکبوت نر در طی آن یا بعد از آن توسط ماده خورده می شود. از آنجا که این جفت ها از یکدیگر مستقل نیستند، به منظور تولید مثل نسل جدید، به طور موازی و همچنین در طبیعت، هر یک از جفت ها جدا از بقیه جفت می شوند. در دنیای واقعی، در هر جفت گیری تقریباً ۱۰۰۰ تخم تولید می شود، اما سرانجام، برخی از نوزادان عنکبوتی زنده می مانند که قوی تر هستند. اکنون، در این الگوریتم برای تولید مثل، باید آرایه ای به نام آلفا ایجاد شود تا زمانی که آرایه بیه با اعداد تصادفی شامل باشد، سپس فرزندان با استفاده از α

مدل های تحقیق

شبکه عصبی مصنوعی

شبکه های عصبی مصنوعی (ANN) به عنوان تعمیم سیستم های عصبی بیولوژیکی برای مدل های ریاضی توسعه یافته اند (Haykin, 1999). در حقیقت شبکه عصبی مصنوعی، یک روش شبیه سازی می باشد که از مطالعه سیستم شبکه عصبی موجودات زنده الهام گرفته است (Nayak et al., 2006). معمولاً یک شبکه عصبی مصنوعی مبتنی بر سه لایه است که در آن لایه ورودی داده ها به شبکه معرفی می شوند، سپس یک یا چند لایه پنهان وجود دارد که در آن داده ها پردازش می شوند تا در نهایت با نتیجه نهایی به

ساختار الگوریتم BWO

در اصطلاحات الگوریتم ژنتیک و ازدحام ذرات، این ساختار به ترتیب "کروموزوم" و "موقعیت ذره" نامیده می شود، اما در الگوریتم بهینه سازی بیه سیاه (BWO) به آن "بیه" گفته می شود. در این الگوریتم، راه حل بالقوه هر مسئله به عنوان عنکبوت بیه سیاه در نظر گرفته شده است. هر عنکبوت بیه مقادیر متغیرهای مسئله را نشان می دهد. برای حل توابع معیار (بنچمارک)، ساختار باید به عنوان یک آرایه در نظر گرفته شود. که در آن N_{var} ابعاد یک مسئله بهینه سازی است. یک بیه یک آرایه از $1 \times N_{var}$ است که نشان دهنده جواب مسئله است. این آرایه به صورت زیر طبق رابطه (۴) تعریف می شود:

$$\text{Widow} = [x_1, x_2, x_{N_{var}}] \quad (4)$$

هر یک از مقادیر متغیر متغیر $(x_1, x_2, x_{N_{var}})$ یک عدد نقطه شناور است. تابع تناسب بیه با ارزیابی عملکرد تناسب f در یک بیه

این فرآیند برای $N_{var} / 2$ بار تکرار می‌شود، در حالی که اعداد تصادفی انتخاب شده نباید تکرار شوند. سرانجام، فرزندان و مادران به آرایه‌ای اضافه می‌شوند و براساس تابع تناسب آنها مرتب می‌شوند، اکنون با توجه به رتبه‌بندی همجنس‌خواری، برخی از بهترین افراد به جمعیت تازه تولید شده اضافه می‌شوند. این مراحل برای همه جفت‌ها اعمال می‌شود. شکل (۳) فلوجارت الگوریتم پیشنهادی عنکبوت بیوه سیاه را نشان می‌دهد.

معادله (۶) تولید می‌شوند که در آن x_1 و x_2 والدین هستند، y_1 و y_2 فرزندان هستند.

$$\begin{cases} y_1 = \alpha \times x_1 + (1 - \alpha) \times x_2 \\ y_2 = \alpha \times x_2 + (1 - \alpha) \times x_1 \end{cases} \quad (6)$$




Fig. 3- Flowchart of the proposed black widow Optimization algorithm (Houssein et al., 2021)
 شکل ۳- فلوجارت الگوریتم پیشنهادی عنکبوت بیوه سیاه (Houssein et al., 2021)




Fig. 4-a- Feeding behavior of humpback whales' bubble net (Rana et al., 2020) b) Feeding behavior of humpback whales' bubble net (Mirjalili & Lewis, 2016)

شکل ۴-الف رفتار تغذیه‌ای شبکه حباب‌دار نهنگ‌های کوهان‌دار (Rana et al., 2020) ب- رفتار تغذیه‌ای شبکه حباب‌دار نهنگ‌های کوهان‌دار (Mirjalili & Lewis, 2016)

الگوریتم بهینه سازی نهنگ (WOA)

الگوریتم بهینه سازی نهنگ توسط Lewis و Mirjalili (2016) ارائه گردید. این الگوریتم مبتنی بر هوش ازدحامی است که برای مشکلات بهینه سازی پیوسته پیشنهاد مورد استفاده قرار می گیرد. این روش از شکار نهنگ های کوهان دار در بهینه سازی مسائلی که روش های تغذیه شبکه حیابی بود استفاده می نمایند (Watkins and Schevill, 1974). تغذیه با شبکه حیابی یک رفتار تغذیه ای منحصر به فرد و پیچیده است که توسط نهنگ های کوهان دار انجام می شود. وقتی نهنگ های کوهان دار، ماهی های کوچک و کریل (میگو) را در نزدیکی سطح اقیانوس پیدا می کنند، یک شبکه حباب ماریپچ بیرون می زند و طعمه ها را در یک مسیر دایره ای محاصره می نمایند (Friedlaender et al., 2011). با توجه به این سری از رفتارها، برای ساخت یک مدل ریاضی الگوریتم نهنگ، سه ساختار اساسی جستجوی طعمه، محاصره طعمه و حمله با شبکه حباب را در نظر خواهد گرفت. الگوریتم به پارامترهای کنترل کمتری نیاز دارد. عملاً فقط یک پارامتر (فاصله زمانی) نیاز به تنظیم دقیق دارد. در الگوریتم نهنگ، جمعیت نهنگ های کوهان دار از طریق فضای جستجوی چند بعدی برای غذا جستجو می کنند (Fan et al., 2022). شکل (۴-الف) رفتار تغذیه ای شبکه حباب دار نهنگ های کوهان دار و شکل (۴-ب) را نشان می دهد.

موقعیت های نهنگ های کوهان دار منفرد به عنوان متغیرهای مختلف تصمیم بیان می گردد، در حالی که فاصله بین نهنگ کوهان دار منفرد و غذا با ارزش هزینه هدف مطابقت دارد. مکان وابسته به زمان یک نهنگ منفرد با سه فرآیند عملیاتی کوچک شدن طعمه های محاصره کننده، روش حمله حباب خالص (مرحله بهره برداری) و جستجوی طعمه (مرحله اکتشاف) اندازه گیری می شود. ابتدا مدل ریاضی محاصره طعمه، مانور تغذیه ای شبکه حباب و جستجوی طعمه ارائه می گردد. نهنگ های کوهان دار می توانند موقعیت طعمه را تشخیص داده و آنها را محاصره کنند. نهنگ های کوهان دار بسیار زیرک هستند و موقعیت طعمه را به خوبی تشخیص داده و سپس آنها را محاصره می کنند. از آنجا که موقعیت بهینه طراحی در فضای جستجو پیش بینی شناخته نشده است، الگوریتم WOA فرض می کند که بهترین راه حل فعلی کاندیدا، همان طعمه هدف است یا نزدیک به بهینه است. پس از تعریف کردن بهترین عامل جستجو و سایر عوامل جستجو، سعی می گردد موقعیت و مکان خود را نسبت به بهترین عامل جستجو به روز می کنند. این رفتار با معادله های (۷) و (۸) نشان داده شده است:

$$\vec{D} = |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)| \quad (7)$$

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D} \quad (8)$$

که در آن t تکرار اخیر، \vec{A} و \vec{C} ضرایب برداری، X^* بردار موقعیت بهترین راه حل به دست آمده تاکنون، \vec{X} بردار موقعیت، | مقدار مطلق، و * ضرب داخلی عنصر به عنصر است. لازم به ذکر است که در صورت وجود راه حل بهتر، X^* باید در هر تکرار به روز شود. بردارهای \vec{A} و \vec{C} از روابط (۹) و (۱۰) به شرح زیر محاسبه می شوند:

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a} \quad (9)$$

$$\vec{C} = 2 \cdot \vec{r} \quad (10)$$

که \vec{a} در طول تکرار (و در مراحل اکتشاف و بهره برداری) به صورت خطی از دو به صفر کاهش می یابد و \vec{r} یک بردار تصادفی در بازه [۰، ۱] است. موقعیت (Y, X) یک عامل جستجو را می توان با توجه به موقعیت بهترین رکورد فعلی (Y^* , X^*) به روزرسانی نمود. با تنظیم مقدار بردارهای \vec{A} و \vec{C} می توان مکان های مختلف اطراف بهترین عامل را با توجه به موقعیت فعلی بدست آورد. با تعریف بردار تصادفی (\vec{r}) می توان به هر موقعیتی در فضای جستجو واقع در بین نقاط کلیدی نشان داده شده رسید. معادله (۸) به هر عامل جستجو اجازه می دهد موقعیت خود را در همسایگی بهترین راه حل فعلی به روز نموده و محاصره طعمه را شبیه سازی می کند. به منظور مدل سازی ریاضی رفتار شبکه حباب نهنگ های کوهان دار، دو روش به شرح زیر طراحی شده است:

الف) کوچک کردن مکانیسم محاصره است که با کاهش مقدار \vec{a} در معادله (۹) به دست می آید نکته مهم که باید به آن توجه داشته باشید این است که دامنه نوسانات \vec{A} نیز با \vec{a} کاهش می یابد. به عبارت دیگر \vec{A} یک مقدار تصادفی در بازه [-a, a] است که در آن \vec{a} در طول تکرار از مقدار دو به صفر کاهش می یابد. با تنظیم مقادیر تصادفی برای \vec{A} در [۱، -۱]، موقعیت جدید یک عامل جستجو را می توان در هر مکانی بین موقعیت اصلی عامل و موقعیت بهترین عامل فعلی تعریف کرد.

ب) موقعیت به روزرسانی ماریپچی: این رویکرد ابتدا فاصله بین نهنگ واقع در (Y, X) و طعمه واقع در سمت (Y^* , X^*) را محاسبه می کند. سپس یک معادله ماریپچی بین موقعیت نهنگ و طعمه ایجاد می شود تا حرکت ماریپچی شکل نهنگ های کوهان دار را به صورت زیر تقلید کند که از معادله (۱۱) به دست می آید.

$$\vec{X}(t+1) = \vec{D} \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) \quad (11)$$

جایی که $\vec{D} = |\vec{X}^*(t) - \vec{X}(t)|$ می باشد. همچنین فاصله نهنگ اول تا طعمه را نشان می دهد (بهترین راه حل به دست آمده تا

قادر است بین یک حرکت مارپیچی یا دایره‌ای جابه‌جا شود. سرانجام، الگوریتم فوق با تامین شدن شرط خروجی، خاتمه می‌یابد.

معیارهای ارزیابی مدل

در این پژوهش برای ارزیابی عملکرد سناریوهای مختلف تعریف شده برای روش‌های مورد مطالعه از معیارهای ارزیابی ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب بهره‌وری نش-ساتکلیف (NSE) و ضریب درصد ناریبی (PBIAS) از طریق روابط (۱۵) تا (۱۹) استفاده می‌کنیم.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^N (Q_t^{pr} - Q_t^{ob})^2}{\sum_{i=1}^N (Q_t^{ob})^2} \right) \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_t^{pr} - Q_t^{ob})^2} \quad (16)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Q_t^{pr} - Q_t^{ob})^2}{\sum_{i=1}^N (Q_t^{pr} - \bar{Q}_t^{pr})^2} \quad (17)$$

$$PBIAS = \frac{\sum_{i=1}^N (Q_t^{pr} - Q_t^{ob})}{\sum_{i=1}^N Q_t^{pr}} \quad (18)$$

از لحاظ کیفی اگر ضریب R^2 بین صفر تا ۰/۵ باشد مدل نتیجه رضایت بخشی ندارد. اگر بین ۰/۵ تا ۰/۶ باشد نتایج رضایت بخش، اگر بین ۰/۶ تا ۰/۷ باشد خوب و اگر بین ۰/۷ تا ۱ باشد نتیجه بسیار خوب می‌باشد. شاخص RMSE دارای واحد دبی (مترمکعب بر ثانیه) می‌باشد. هر چه این مقدار کمتر باشد نتیجه بهتر خواهد بود (Ayele et al., 2007; Moriasi et al., 2017). اگر ضریب بهره‌وری نش-ساتکلیف کمتر مساوی ۰/۴ باشد نتیجه رضایت بخش نخواهد بود. اگر ضریب مذکور بین ۰/۴ تا ۰/۵ باشد نتیجه قابل قبول، اگر بین ۰/۵ تا ۰/۶۵ باشد نتیجه رضایت بخش، اگر بین ۰/۶۵ تا ۰/۷۵ باشد خوب و اگر بین ۰/۷۵ تا ۱ باشد بسیار خوب خواهد بود. ضریب درصد ناریبی نیز اگر کمتر یا مساوی ± 10 باشد نتیجه بسیار خوب خواهد بود. اگر بین ± 10 تا ± 15 باشد نتیجه خوب، اگر بین ± 15 تا ± 25 باشد رضایت بخش و اگر بزرگتر یا مساوی ± 25 باشد نتیجه رضایت بخش نخواهد بود. (Legates and Mccab, 1999).

نتایج و بحث

انتخاب مؤثرترین ترکیب از متغیرهای ورودی، مهم‌ترین گام در حوزه یادگیری ماشین می‌باشد. قرار دادن متغیرهای غیر مرتبط و یا متغیرهایی که ضریب همبستگی منفی دارند باعث کاهش دقت مدل‌سازی و افزایش خطای مدل می‌گردد. لذا انتخاب یک ترکیب بهینه‌ی مؤثر، پیچیدگی مدل را کاهش می‌دهد. نتایج تجزیه و تحلیل

کنون، b برای تعریف شکل مارپیچ لگاریتمی ثابت است، l یک عدد تصادفی بین $[-1, 1]$ و \cdot ضرب عنصر به عنصر است. لازم به ذکر است که نهنگ‌های کوهان‌دار به‌طور همزمان در اطراف طعمه شنا می‌کنند و در یک مسیر مارپیچی شکل قرار می‌گیرند. برای مدل‌سازی این رفتار هم‌زمان، ما تصور می‌کنیم که احتمال ۵۰ درصد برای انتخاب بین مکانیزم تنگ کردن محاصره یا مدل مارپیچی برای به‌روزرسانی موقعیت نهنگ‌ها هنگام بهینه‌سازی وجود دارد. مدل ریاضی آن از رابطه (۱۲) به شرح زیر به دست می‌آید:

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A} \cdot \vec{D} & \text{if } p < 0.5 \\ \vec{D} \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) & \text{if } p \geq 0.5 \end{cases} \quad (12)$$

که در آن p عدد تصادفی در بازه $[0, 1]$ است. علاوه بر روش تور حبابی، نهنگ‌های کوهان‌دار به‌طور تصادفی طعمه را جستجو می‌کنند. از همان روش مبتنی بر تغییر بردار \vec{A} می‌توان برای جستجوی طعمه (اکتشاف) استفاده کرد. در حقیقت، نهنگ‌های کوهان‌دار با توجه به موقعیت یکدیگر به‌طور تصادفی جستجو می‌کنند. بنابراین، ما از \vec{A} با مقادیر تصادفی بزرگتر از ۱ یا کمتر از ۱- استفاده می‌کنیم تا عامل جستجو را مجبور کنیم از یک نهنگ مرجع دور شود. بر خلاف مرحله بهره‌برداری، ما موقعیت یک عامل جستجو را در مرحله اکتشاف با توجه به یک عامل جستجوگر انتخاب شده به جای بهترین عامل جستجوی موجود تاکنون به‌روز می‌کنیم. این مکانیزم و $|\vec{A}| > 1$ بر کاوش تأکید کرده و الگوریتم WOA را برای انجام جستجوی جهانی کاهش می‌دهد. مدل ریاضی جستجو از طریق روابط (۱۳) و (۱۴) به شرح زیر است:

$$\vec{D} = \vec{C} \cdot \vec{X}_{rand} - \vec{X} \quad (13)$$

$$\vec{X}(t+1) = \vec{X}_{rand} - \vec{A} \cdot \vec{D} \quad (14)$$

جایی که \vec{X}_{rand} یک بردار موقعیت تصادفی (یک نهنگ تصادفی) است که از بین جمعیت فعلی انتخاب شده است. الگوریتم WOA با مجموعه‌ای از راه‌حل‌های تصادفی شروع می‌شود. در هر تکرار، عوامل جستجو مواضع خود را با توجه به یک عامل جستجوی تصادفی انتخاب شده یا بهترین راه‌حل تاکنون به‌روز می‌کنند. به‌منظور ارائه اکتشاف و بهره‌برداری، پارامتر a از دو به صفر کاهش می‌یابد. یک عامل جستجوی تصادفی انتخاب می‌شود $\vec{A} > 1$ ، در حالی که بهترین راه حل هنگام انتخاب $\vec{A} < 1$ برای به‌روزرسانی موقعیت عوامل جستجو می‌باشد. بسته به مقدار p ، الگوریتم نهنگ

به‌کار رفته در فاز آموزش بر اساس شاخص RMSE، مدل ANN-WOA با مقدار ۱۳/۸۳ مترمکعب بر ثانیه کمترین خطا و بهترین عملکرد را دارا می‌باشد. همچنین بعد از الگوریتم WANN و ANN-BWO به ترتیب با ۱۴/۱۱ و ۱۴/۲۷ مترمکعب بر ثانیه در رتبه‌های بعدی قرار گرفتند. همچنین نتایج در بخش آزمون نیز مشابه می‌باشد. در این بخش الگوریتم ANN-WOA با ۴۴/۶۱ مترمکعب بر ثانیه بهترین عملکرد را داشته است. همچنین نتایج بررسی‌ها بر اساس شاخص R^2 نیز نشان می‌دهد که مدل در بخش آموزش با ۰/۸۳۹ و در بخش آزمون ۰/۸۹۷ شبکه ANN-WOA دارای بهترین عملکرد بوده است. همچنین از لحاظ کیفی نیز می‌توان گفت که با توجه به این که کلیه مدل‌های مذکور بین بازه ۰/۷ تا ۱ قرار داشتند در درجه‌بندی بسیار خوب طبقه‌بندی می‌گردند. نتایج ضریب بهره‌وری نش-ساتکلیف نیز نشان می‌دهد که در فاز آموزش الگوریتم ANN-BWO با مقدار ۰/۶۵۵ در درجه‌بندی خوب و در فاز آزمون نیز با مقدار ۰/۸۷۹ در درجه‌بندی بسیار خوب قرار دارد. همچنین مدل ANN-WOA نیز در فاز آموزش با مقدار ۰/۶۷۵ و در فاز آزمون با ۰/۸۸۶ در رتبه‌بندی خوب و بسیار خوب قرار دارند. همچنین مدل WANN نیز در فاز آموزش دارای مقدار ۰/۶۶۲ و در فاز آزمون با ۰/۸۹۰ دارای رتبه‌بندی خوب و بسیار خوب هستند. همچنین نتایج بررسی‌ها نشان می‌دهد که بر اساس شاخص بهره‌وری نش-ساتکلیف در فاز آموزش الگوریتم ANN-WOA دارای بهترین عملکرد و در فاز آزمون الگوریتم WANN دارای عملکرد بهتری بوده است. نتایج ضریب نا اریبی نیز نشان می‌دهد که با توجه به این که نتایج کلیه مدل‌ها زیر ده درصد می‌باشد عملکرد بسیار خوب از لحاظ کیفی گزارش می‌گردد. جدول (۴) نتایج ارزیابی مدل بر اساس معیارهای مختلف ارزیابی را در دو فاز آموزش و آزمون نشان می‌دهد. اشکال (۵) تا (۷) نیز نتایج سری‌های زمانی بین داده‌های مشاهداتی (واقعی) و داده‌های پیش‌بینی شده را نشان می‌دهد. در این اشکال محور عمودی مقدار دبی بر حسب متر مکعب بر ثانیه و محور افقی زمان بر حسب روز را نشان می‌دهد. همچنین اشکال (۸) تا (۱۰) نمودار پراکندگی بین داده‌های مشاهداتی و واقعی را نشان می‌دهد که در آن محور افقی، دبی داده‌های مشاهداتی و محور عمودی، دبی داده‌های پیش‌بینی شده را نشان می‌دهد. در این پژوهش جهت اختصار صرفاً نتایج سری‌های زمانی در فاز آزمون نشان داده شده است.

ضریب همبستگی پیرسون نشان می‌دهد که گنجاندن متغیرهای نامربوط در ترکیب ورودی، عملکرد مدل را کاهش می‌دهد و مدل پیچیده‌تری ایجاد می‌کند. تجزیه و تحلیل همبستگی نشان می‌دهد که دبی روز قبل (Q_{t-1}) مهمترین عامل در پیش‌بینی‌کننده جریان ($r = 0.80$) در ایستگاه جلوگیری می‌باشد. پس از آن دبی دو روز قبل ($r = 0.73, Q_{t-2}$)، دبی سه روز قبل ($r = 0.70, Q_{t-3}$)، دبی چهار روز قبل ($r = 0.68, Q_{t-4}$)، بارندگی ($r = 0.32, P_t$) و بارش با یک، دو، سه لغایت شش روز تأخیر دارای رتبه‌بندی‌های مختلف در مدل‌سازی می‌باشند. لذا ترکیب مدل شماره یک دارای بالاترین ضریب همبستگی و ترکیب مدل یازدهم دارای کمترین همبستگی می‌باشد. نتایج نشان می‌دهد که فرایند بارش به‌تنهایی دبی جریان را به‌طور دقیق پیش‌بینی نمی‌کند. علت این امر ساختار پیچیده و غیرخطی فرآیند رواناب روزانه می‌باشد. اگرچه بارش تنها فرآیندی است که رواناب در حوضه آبریز تولید می‌کند، فرآیند رواناب روزانه تحت تأثیر پارامترهای زیادی قرار می‌گیرد. بنابراین، افزودن متغیرها به طور منطقی عملکرد مدل‌ها را افزایش می‌دهد. همچنین متغیرهایی با ضرایب همبستگی بسیار پایین (مانند P_{t-6}) و یا متغیرهایی با ضریب همبستگی منفی می‌توانند بر عملکرد مدل تأثیر منفی بگذارند. از سوی دیگر، هر حوضه و هر مدل ساختار متفاوت و مخصوص به‌خودی دارد و بر اساس مفروضات مختلف توسعه یافته است. قرار دادن ورودی‌های مرتبط کمتر در یک مدل، ظرفیت پیش‌بینی آن را کاهش می‌دهد. نتایج تحقیقات قبلی برخی از پژوهشگران نشان می‌دهد که افزایش بیش از حد متغیرهای ورودی نه‌تنها کمکی به افزایش دقت مدل‌سازی و کاهش خطا نمی‌کند بلکه ساختار و فیزیکی مدل‌ها را پیچیده می‌کند و دقت پیش‌بینی را کاهش می‌دهد. چنین تضعیفی ممکن است ناشی از اثرات منفی بر واریانس باشد (Shi et al., 2012; Zhang et al., 2019). پس از شناسایی بهترین سناریوی ترکیب ورودی و مقدار بهینه برای هر اپراتور، عملکرد هر یک از مدل‌های توسعه‌یافته با استفاده از مجموعه داده آموزشی، با استفاده از مجموعه داده اعتبارسنجی در مرحله آزمون مورد ارزیابی قرار گرفت. نتایج این ارزیابی برای برآورد و مقایسه عملکرد مدل مورد استفاده قرار گرفت. لذا پس از ساخت مدل‌ها و تعیین بهترین ترکیب ورودی در مرحله آموزش، الگوریتم‌ها با استفاده از مجموعه داده‌های آزمایشی برای ارزیابی قدرت کلی هر مدل اعتبارسنجی شدند. نتایج نشان می‌دهد که از بین الگوریتم‌های

جدول ۴- نتایج ارزیابی مدل بر اساس معیارهای مختلف ارزیابی را در دو فاز آموزش و آزمون
Table 4- Results of model evaluation based on different evaluation criteria in two phases of training and testing

Models/Evaluation Criteria	RMSE	MAE	NSE	PBIAS	R ²
BWO-Train	14. 270	4. 668	0. 655	-2. 346	0. 828
BWO-Test	48. 116	21. 192	0. 879	2. 9595	0. 88
WOA-Train	13. 833	4. 775	0. 675	-3. 407	0. 839
WOA-Test	44. 613	19. 968	0. 886	-3. 018	0. 897
WANN-Train	14. 110	5. 176	0. 662	-3. 9251	0. 833
WANN-Test	45. 898	20. 654	0. 890	4. 006	0. 891




Fig. 8- Observed and predicted runoff hydrograph by ANN-BWO algorithm in the test phase
 شکل ۵- هیدروگراف رواناب مشاهداتی و پیش بینی شده توسط الگوریتم ANN-BWO در مرحله آزمون




Fig. 9- Observed and predicted runoff hydrograph by ANN-WOA algorithm in the test phase
 شکل ۶- هیدروگراف رواناب مشاهداتی و پیش بینی شده توسط الگوریتم ANN-WOA در مرحله آزمون




Fig. 10- Observed and predicted runoff hydrograph by WANN algorithm in the test phase
 شکل ۷- هیدروگراف رواناب مشاهداتی و پیش بینی شده توسط الگوریتم WANN در مرحله آزمون




Fig. 11- scatter plot diagram between observation data and real data for ANN-BWO model in the test phase

شکل ۸- نمودار پراکندگی بین داده‌های مشاهده‌ای و داده‌های واقعی برای مدل ANN-BWO در فاز آزمون




Fig. 12- scatter plot diagram between observation data and real data for ANN-WOA model in the test phase

شکل ۹- نمودار پراکندگی بین داده‌های مشاهده‌ای و داده‌های واقعی برای مدل ANN-WOA در فاز آزمون




Fig. 13- Scatter plot diagram between observation data and real data for ANN-WOA model in the test phase

شکل ۱۰- نمودار پراکندگی بین داده‌های مشاهده‌ای و داده‌های واقعی برای مدل ANN-WOA در فاز آزمون




Fig. 11- Box plot for the measured and predicted streamflow values

شکل ۱۱- نمودار جعبه‌ای برای مقادیر دبی جریان اندازه‌گیری شده و پیش‌بینی شده

غیرخطی بهره گرفت. عنکبوت بیوه سیاه نیز از الگوریتم‌های نوین فرا ابتکاری می‌باشد. در این الگوریتم هرچه تعداد فرزندان بیشتر باشد، شانس بیشتری برای کشف مقدار بیشتری از فضای جستجو وجود دارد که بدست آوردن عملکرد بالا برای مرحله اکتشاف را تضمین می‌کند. بنابراین الگوریتم فوق قادر به فرار از بهینه محلی و حرکت بسوی بهینه جهانی می‌شود. همچنین، عملکرد همجنس‌خواری توانایی از بین بردن سریع راه‌حل‌های نامناسب را فراهم می‌کند. در نتیجه، نسل بعدی توسط والدین بهتر تولید خواهد شد که همگرایی سریع راه‌حل‌های نزدیک به راه حل‌های بهینه را تضمین می‌کند.

نتیجه‌گیری

پیش‌بینی فرایند رواناب روزانه برای ارزیابی تأثیر سیل و اجرای برنامه‌های مدیریت سیل مفید و ضروری است. با این حال به دلیل ماهیت غیرخطی و آشفته فرآیندهای تولید دبی جریان، همچنان یک کار چالش‌برانگیز برای مهندسان می‌باشد. این پژوهش برای شبیه‌سازی فرایند بارش-رواناب ایستگاه جلوگیری اهواز واقع در حوضه آبریز کرخه، به روش یادگیری ماشین انجام گرفته است. در این تحقیق از دو الگوریتم بهینه‌سازی نهنگ و عنکبوت سیاه استفاده گردید. همچنین از موزیک کلاسه مکزیک نیز برای افزایش دقت مدل و برآورد ضرایب وزنی و بایاس استفاده گردد. کلیه الگوریتم‌های مورد استفاده برای توسعه مدل‌های مبتنی بر داده‌های ۱۰ ساله بارندگی و جریان روزانه استفاده شد. یافته‌های اصلی مطالعه را می‌توان به شرح زیر خلاصه کرد:

✓ متغیرهای زیادی در پیش‌بینی فرایند بارش-رواناب تأثیرگذار هستند که در میان عوامل مذکور بارش و دبی اثرات ملموس‌تری در این فرایند دارند. همچنین تأخیرهای مختلف برای بارش و دبی لحاظ گردید که در این میان، بارش با یک روز تأخیر (Q_{t-1}) موثرترین متغیر برای پیش‌بینی فرایند بارش رواناب می‌باشد.

در این پژوهش از نمودار جعبه‌ای برای توصیف تغییرات داده‌ها استفاده گردید. تحلیل نتایج نمودار جعبه‌ای نشان می‌دهد که الگوریتم ANN-BWO در پیش‌بینی داده‌های کمینه در مقایسه با داده‌های مشاهداتی عملکرد بهتری داشته است. به عبارتی دیگر این الگوریتم در پیش‌بینی داده‌های کمینه، چارک سوم، میانه و داده‌های بیشینه عملکرد بهتری داشته است. در عوض الگوریتم WOA-ANN در پیش‌بینی چارک اول عملکرد بهتری داشته است. شکل (۱۱) نمودار جعبه‌ای برای مقادیر دبی جریان اندازه‌گیری شده و پیش‌بینی شده نشان می‌دهد. این مطالعه الگوریتم بهینه‌سازی مبتنی بر ازدحام را با الهام از رفتار شکار نهنگ‌های کوهان‌دار ارائه داده است. روش پیشنهادی شامل سه اپراتور برای شبیه‌سازی جستجوی طعمه، محاصره طعمه و رفتار جستجوی حباب تور نهنگ‌های کوهان‌دار است. نتایج نشان می‌دهد که از لحاظ تجزیه و تحلیل اکتشاف، بهره‌برداری، جلوگیری از بهینه‌سازی محلی و رفتار همگرایی الگوریتم پیشنهادی دارای عملکرد خوبی بوده است. مدل فوق مبتنی بر جمعیت بوده و توانایی جلوگیری از بهینه‌سازی محلی و دستیابی به یک راه‌حل بهینه جهانی را دارد. این مزایا باعث می‌شود الگوریتم فوق برای حل مشکلات مختلف بهینه‌سازی مقید مناسب باشد. سرعت همگرایی، کاهش زمان محاسبات و گیر نکردن در دام نقاط بهینه محلی از جمله مزایای دیگر این مدل می‌باشد. استفاده از اپراتورهای تصادفی به مدل اجازه می‌دهد تا از بهینه محلی فرار کرده و به بهینه جهانی تقریبی همگرا شود. عنصر اصلی برای دستیابی به چنین هدفی به رابطه مناسب بین اکتشاف و بهره‌برداری بستگی دارد. اکتشاف با شناسایی متنوع‌ترین مناطق جستجو در مناطق جستجوگر، امیدوارکننده‌ترین مناطق است. هرچه عملکرد یک الگوریتم فرا ابتکاری خاص در توازن این دو عملکرد بهتر باشد، عملکرد آن بهتر خواهد بود. بر این اساس توصیه می‌گردد از الگوریتم فوق برای حل مسائل بهینه‌سازی چندهدفه استفاده گردد. همچنین اصلاحات اساسی برای مدل فوق انجام گرفته تا بتوان در مسائل بهینه‌سازی در دنیای واقعی، به خصوص مشکلات بهینه‌سازی گسسته و برنامه‌ریزی

ANN-WOA و WANN و ANN-BWO به ترتیب ۳۲/۴ و ۲۷/۶ و ۲۲/۱۴ درصد دقت مدل شبکه عصبی منفرد را بهبود بخشیدند.

تشکر و قدردانی

این مقاله بر گرفته از رساله دکتری گروه مدیریت ساخت و آب دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران می‌باشد. نویسندگان این مقاله مراتب تشکر و قدردانی خود را از شرکت آب منطقه‌ای خوزستان و مجله علوم و مهندسی آبیاری دانشگاه چمران اهواز اعلام می‌دارند.

✓ هر چه زمان تأخیر هر متغیر ورودی بیشتر باشد، ضریب همبستگی و اثربخشی آن برای اهداف پیش‌بینی کمتر است. به عبارتی ساده‌تر افزایش زمان تأخیر موجب کاهش ضریب همبستگی و در نهایت کاهش دقت مدل در پیش‌بینی خواهد شد.

✓ با توجه به شاخص ارزیابی RMSE می‌توان گفت که عملکرد مدل ANN-WOA دارای بهترین عملکرد در پیش‌بینی فرایند رواناب روزانه بوده است. همچنین کلیه مدل‌های مذکور عملکرد بسیار خوبی در فرایند پیش‌بینی از خود نشان دادند. همچنین بر اساس معیار RMSE نتایج پیش‌بینی مدل‌ها نشان می‌دهد که به ترتیب مدل‌های

References

- 1- Abrahart, R.J. and See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological processes*, 14(11-12), pp.2157-2172. Doi: 10.1002/1099-1085(20000815/30)14:11/12<2157::AID-HYP57>3.0.CO;2;S.
- 2- Abudu, S., Cui, C.L., King, J.P. and Abudukadeer, K., 2010. Comparison of performance of statistical models in forecasting monthly streamflow of Kizil River, China. *Water Science and Engineering*, 3(3), pp.269-281. Doi: 10.3882/j.issn.1674-2370.2010.03.003.
- 3- Afan, H.A., El-Shafie, A., Yaseen, Z.M., Hameed, M.M., Wan Mohtar, W.H.M. and Hussain, A., 2015. ANN based sediment prediction model utilizing different input scenarios. *Water resources management*, 29, pp.1231-1245.
- 4- Ahmed, J.A. and Sarma, A.K., 2007. Artificial neural network model for synthetic streamflow generation. *Water resources management*, 21, pp.1015-1029.
- 5- Anusree, K. and Varghese, K.O., 2016. Streamflow prediction of Karuvannur River Basin using ANFIS, ANN and MNL models. *Procedia Technology*, 24, pp.101-108. Doi: 10.1016/j.protcy.2016.05.015.
- 6- Ayele, G.T., Teshale, E.Z., Yu, B., Rutherford, I.D. and Jeong, J., 2017. Streamflow and sediment yield prediction for watershed prioritization in the Upper Blue Nile River Basin, Ethiopia. *Water*, 9(10), p.782. Doi: 10.3390/w9100782.
- 7- Box, G.P., & Jenkins, 1970. Time series analysis: forecasting and control, San Francisco: John Wiley & Sons.
- 8- Chiang, Y.M., Chang, L.C. and Chang, F.J., 2004. Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling. *Journal of hydrology*, 290(3-4), pp.297-311. Doi: 10.1016/j.jhydrol.2003.12.033.
- 9- Danandeh Mehr, A., Kahya, E., Şahin, A. and Nazemosadat, M.J., 2015. Successive-station monthly streamflow prediction using different artificial neural network algorithms. *International Journal of Environmental Science and Technology*, 12, pp.2191-2200.
- 10- Daneshvar Vousoughi, F. and Samadzadeh, R., 2021. Predicting runoff with pre-processing approaches in Ardabil plain. *Hydrogeomorphology*, 8(26), pp.116-99. Doi: 10.22034/hyd.2021.44060.1570. (In Persian).
- 11- Fan, Q., Chen, Z., Zhang, W. and Fang, X., 2022. ESSAWOA: enhanced whale optimization algorithm integrated with salp swarm algorithm for global optimization. *Engineering with Computers*, 38(Suppl 1), pp.797-814.

- 12-Freire, P.K.D.M.M., Santos, C.A.G. and da Silva, G.B.L., 2019. Analysis of the use of discrete wavelet transforms coupled with ANN for short-term streamflow forecasting. *Applied Soft Computing*, 80, pp.494-505. Doi: 10.1016/j.asoc.2019.04.024.
- 13-Wiley, D., Ware, C., Bocconcelli, A., Cholewiak, D., Friedlaender, A., Thompson, M. and Weinrich, M., 2011. Underwater components of humpback whale bubble-net feeding behaviour. *Behaviour*, pp.575-602.
- 14-Ghorbani, M.A. and Dehghani, R., 2016. Application of Bayesian Neural Networks, Support Vector Machines and Gene Expression Programming Analysis of Rainfall-Runoff Monthly (Case Study: Kakarza River). *Irrigation Science and Engineering*, 39(2), pp.125-138.
- 15-Ghorbani, M.A., Azani, A. and Mahmoudi Vanolya, S. 2016 . Rainfall-Runoff Modeling Using Hybrid Intelligent Models, *Iran Water Resources Research*, 11(2), 146 (In Persian).
- 16-Guven, A., 2009. Linear genetic programming for time-series modelling of daily flow rate. *Journal of earth system science*, 118, pp.137-146.
- 17-Haykin S. 1999. Neural Networks. MacMillan Publishing Company.
- 18-Houssein, E.H., Helmy, B.E.D., Oliva, D., Elngar, A.A. and Shaban, H., 2021. A novel black widow optimization algorithm for multilevel thresholding image segmentation. *Expert Systems with Applications*, 167, p.114159. Doi: 10.1016/j.eswa.2020.114159.
- 19-Kember, G., Flower, A.C. and Holubeshen, J., 1993. Forecasting river flow using nonlinear dynamics. *Stochastic Hydrology and Hydraulics*, 7, pp.205-212.
- 20-Legates, D.R. and McCabe Jr, G.J., 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), pp.233-241. Doi: 10.1029/1998WR900018.
- 21-- Maier, H.R., Kapelan, Z., Kasprzyk, J., Kollat, J., Matott, L.S., Cunha, M.C., Dandy, G.C., Gibbs, M.S., Keedwell, E., Marchi, A. and Ostfeld, A., 2014. Evolutionary algorithms and other metaheuristics in water resources: Current status, research challenges and future directions. *Environmental Modelling & Software*, 62, pp.271-299. Doi: 10.1016/j.envsoft.2014.09.013.
- 22-Mirjalili, S. and Lewis, A., 2016. The whale optimization algorithm. *Advances in engineering software*, 95, pp.51-67. Doi: 10.1016/j.advengsoft.2016.01.008.
- 23-Mohanty, U.C., Nageswararao, M.M., Sinha, P., Nair, A., Singh, A., Rai, R.K., Kar, S.C., Ramesh, K.J., Singh, K.K., Ghosh, K. and Rathore, L.S., 2019. Evaluation of performance of seasonal precipitation prediction at regional scale over India. *Theoretical and Applied Climatology*, 135, pp.1123-1142.
- 24-Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D. and Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), pp.885-900.
- 25-Nayak, P.C., Rao, Y.S. and Sudheer, K.P., 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water resources management*, 20, pp.77-90. *Water resources management*, 20, 77-90.
- 26-Rana, N., Latiff, M.S.A., Abdulhamid, S.I.M. and Chiroma, H., 2020. Whale optimization algorithm: a systematic review of contemporary applications, modifications and developments. *Neural Computing and Applications*, 32, pp.16245-16277.

- 27-Salajegheh, A., Fathabadi, A and Mahdavi, M. 2009. Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff process, *Journal of Range and Watershed Management*, 62(1), 65 (In Persian).
- 28-Salas, J.D., 1980. *Applied modeling of hydrologic time series*. Water Resources Publication.
- 29-Sari, I., Zengin, S., Davutoglu, V., Yildirim, C. and Gunay, N., 2008. Myocarditis after black widow spider envenomation. *The American journal of emergency medicine*, 26(5), pp.630-e1. Doi: 10.1016/j.ajem.2007.09.012.
- 30-Shi, J., Guo, J. and Zheng, S., 2012. Evaluation of hybrid forecasting approaches for wind speed and power generation time series. *Renewable and Sustainable Energy Reviews*, 16(5), pp.3471-3480. Doi: 10.1016/j.rser.2012.02.044.
- 31-Valipour, M. and Montazar, A.A., 2012. Sensitive analysis of optimized infiltration parameters in SWDC model. *Advances in Environmental Biology*, pp.2574-2582.
- 32-Watkins, W.A. and Schevill, W.E., 1979. Aerial observation of feeding behavior in four baleen whales: *Eubalaena glacialis*, *Balaenoptera borealis*, *Megaptera novaeangliae*, and *Balaenoptera physalus*. *Journal of Mammalogy*, 60(1), pp.155-163. Doi: 10.2307/1379766.
- 33-Yaseen, Z.M., Awadh, S.M., Sharafati, A. and Shahid, S., 2018. Complementary data-intelligence model for river flow simulation. *Journal of Hydrology*, 567, pp.180-190. Doi: 10.1016/j.jhydrol.2018.10.020.
- 34-Yaseen, Z.M., El-Shafie, A., Afan, H.A., Hameed, M., Mohtar, W.H.M.W. and Hussain, A., 2016. RBFNN versus FFNN for daily river flow forecasting at Johor River, Malaysia. *Neural Computing and Applications*, 27, pp.1533-1542.
- 35-Zhang, D., Peng, X., Pan, K. and Liu, Y., 2019. A novel wind speed forecasting based on hybrid decomposition and online sequential outlier robust extreme learning machine. *Energy conversion and management*, 180, pp.338-357. Doi: 10.1016/j.enconman.2018.10.089.