

Research Paper

Applications of artificial intelligence and time series models in runoff estimation

(Case Study: Part of Halil river basin)

Elaheh Foroudi Sefat¹, Mohammad Mehdi Ahmadi^{2*}, Kourosh Qaderi³, Soudabeh Golestani Kermani⁴

1. Former MSc Student of Water Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

2. Associate Prof. of Water Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

3. Associate Prof. of Water Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

4. Assistant Prof. of Water Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

Received: 2021/12/12

Revised: 2022/04/09

Accepted: 2022/09/06

Use your device to scan and read the article online



DOI:

[10.30495/wej.2023.29501.2345](https://doi.org/10.30495/wej.2023.29501.2345)

Keywords:

Rainfall- Runoff, AutoRegressive Integrated Moving Average (ARIMA), Artificial Neural Network (ANN), Group Method of Data Handling (GMDH), Water resources management.

Abstract

Introduction: Accurate forecasting of runoff and flooding to avoid human and financial losses is one of the most challenging tasks in hydrological studies of a given locale. Therefore, researchers have paid more attention to the development of accurate flood forecasting models, including the use of artificial intelligence methods.

Methods: In this investigation, the efficiency of 3 models, ANN, GMDH and ARIMA, has been investigated in order to simulate the flood of a part of Halil river basin in Kerman province. ANN model is a non-linear modeling method that improves its performance over time. The GMDH composed code is an artificial intelligence model with exploratory self-organizing features, at the conclusion of which a complex system with optimal performance is formed. Composed ARIMA code builds a model to describe the structure of the data and then predict the time series. The input data to the above models included discharge, precipitation, temperature, wind and monthly humidity, and the simulated runoff values were compared with the observed values.

Findings: In order to evaluate the accuracy of the models in this research, statistical indices were used and the results showed that the ANN model (RMSE=0.042, MSD=0.001, MAE=0.027) had the possibility to estimate the runoff with higher accuracy compared to the GMDH model (RMSE=0.068, MSD=0.005, MAE=0.056) and the ARIMA time series (RMSE=0.096, MSD=0.009, MAE=0.063) in the studied basin. The mean error in runoff estimation with ANN model has been reduced by 38.23% and 56.25%, respectively, compared to the values estimated with GMDH and ARIMA models. According to the results obtained in this study, the artificial neural network model has been able to show a better performance than the other two models in predicting the outputs due to its suitable structural ability to find the nonlinear relationship between the input and output data.

Citation: Foroudi Sefat E, Ahmadi M.M, Qaderi K, Golestani Kermani S. Applications of artificial intelligence and time series models in runoff estimation (Case Study: Part of Halil river basin). Water Resources Engineering Journal. 2023; 16 (58): 55- 68.

*Corresponding author: Mohammad Mehdi Ahmadi

Address: Dept. of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

Tell: +989155516270

Email: Ahmadi_mm@uk.ac.ir

Extended Abstract

Introduction

Floods are one of the main known natural disasters in the world that have caused a lot of human and financial losses to communities. Therefore, according to what has been said, accurate estimation of water flow is of special importance in engineering, management and planning of water resources. (Flood control projects require accurate information on the maximum possible flood; therefore, the development of robust models for flood prediction is very important. Rainfall-runoff models are classified into two types: data-driven and knowledge-based. Knowledge-based models include information about all physical processes related to the behavior of the hydrological system, while data-based models are mainly based on measured data and seek the relationship between input and output parameters without considering the physical process. The advantage of using data-driven methods is the inclusion of inherent uncertainties in modeling. Therefore, in the present study, an attempt has been made to evaluate the accuracy of several data-driven models in predicting the rainfall-runoff process in a part of Halil River located in Kerman province.

Materials and Methods

In this study, in order to simulate and predict the runoff of a part of Halil River located in Kerman province, ANN artificial neural network toolbox, GMDH code written in MATLAB software and ARIMA time series were used. The input data in these models included precipitation, temperature, wind and monthly humidity of a previous period, from the water year of 1993 to 2015, Converted to normal data and the last two years are considered for forecasting.

In this research, ANN model with the characteristics of Levenberg-Marquardt algorithm, FF network, BP supervised learning, TRAINLM training function and TANSIG transmission function and input layer with 4 neurons were used. 60% of the input data were used for training, 20% of the data for testing and 20% of the data were used for model validation.

GMDH code written in MATLAB software was used to estimate runoff. The data is divided into two parts, training and testing, before the modeling process begins, the developed GMDH model was validated with Mackey-Glass time series.

ARIMA time series was also used to estimate runoff. The purpose of time series analysis is to study time series and build a model to describe the data structure and then predict the future values of time series. Given the importance of time series forecasting, it is necessary to build an effective model to improve forecasting accuracy. Before constructing the model and to avoid false regressions, the stationarity of the variables was first examined. For this purpose, the augmented Dickey Fuller (ADF) unit root test was used and the answer was one. Also, according to the standard errors obtained, the suitability of this model can be understood. Finally, ARIMA model (1,0,2) with Gaussian conditional probability distribution characteristics, constant coefficient of 0.0326962 and variance of 0.00830729 were obtained.

To evaluate the accuracy of ANN, GMDH and ARIMA models, the statistical indices of root mean square error (RMSE), mean squared deviation (MSD) and mean absolute value of error (MAE) were used.

Findings

Qualitative results of statistical indices for simulation of rainfall-runoff process show that the ANN, GMDH and ARIMA models with the following characteristics, respectively, had the highest accuracy in estimating runoff:

The constructed ANN model had a hidden layer with 5 neurons with the highest accuracy (RMSE = 0.042, MSD = 0.001, MAE = 0.027) in the rainfall-runoff process simulation.

In modeling with GMDH algorithm, after verifying the model, the number of best selected neurons in each layer to enter the next layer was $X = 0 \cdot 2 L_1$, which had the best performance. The results of the indicators obtained from this model are as follows:

RMSE = 0.068, MSD = 0.005, MAE = 0.056

The results of statistical indices obtained from modeling with ARIMA time series, ARIMA model (1,0,2) with constant coefficient of 0.0326962 and variance of 0.00830729, are as follows:

RMSE = 0.096, MSD = 0.009, MAE = 0.063

Comparison of runoff simulation diagrams at different intensities showed that the ANN model was able to provide a more accurate estimate of runoff at peak and low discharge points.

Discussion

The results presented in this study showed that the ANN model was able to estimate runoff in the basin with higher accuracy compared to other models. The ANN model has shown very good performance in training, validation and testing courses at peak and low flow rates, while the GMDH model has a significant difference in the peak flow estimation compared to the observed flow and has shown better performance at low flow. Because the training and validation stage of ARIMA model is different from the other two models, only the results of the test period are presented and for the calibration and validation period of ARIMA model according to the presented results and ADF test which is equal to one, the model can be qualified. But ARIMA model is less accurate in estimating runoff than the ANN and GMDH models. In general, the results show that the performance of the ANN model in estimating the runoff of the desired basin is acceptable and the best results of this model are obtained by considering 4 input parameters and 1 hidden layer with 5 neurons. The mean error in runoff estimation with ANN model was reduced by 38.23% and 56.25%, respectively, compared to the estimated values of GMDH and ARIMA models. According to the obtained results, it seems that the artificial neural network model, due to its appropriate structural ability to find a nonlinear relationship between input and output data, if high-precision data is used, has the ability to govern the process and conduct data well and show better performance in predicting outputs.

Conclusion

In the present study, the data of precipitation, temperature, wind and monthly humidity of a previous period in the statistical period of 1993 to 2015 of Konarouyeh station were used to model the rainfall-runoff process using ANN, GMDH, ARIMA models and statistical indicators to evaluate the accuracy of the models. Based on the results, all three models ANN, GMDH and ARIMA have the appropriate accuracy for modeling runoff in the basin. But the accuracy of ANN model (RMSE = 0.042, MSD = 0.001, MAE = 0.027) is higher than GMDH and ARIMA models for modeling and predicting runoff in this basin. It should be noted that the introduction of new models in the field of runoff estimation shows that currently a model that can show with certainty the best performance in runoff estimation, not yet been developed. Therefore, in the range of acceptable statistical values of a model, it is not a necessary and sufficient condition to select that model, so to choose the best model in an area, relying on a model cannot make the right decision, so according to what was said, the proposal Several models can be compared to simulate an area.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Elaheh Foroudi Sefat, Mohammad Mehdi Ahmadi, Kourosh Qaderi.

Methodology and data analysis: Elaheh Foroudi Sefat, Mohammad Mehdi Ahmadi, Kourosh Qaderi.

Supervision and final writing: Mohammad Mehdi Ahmadi, Kourosh Qaderi, Soudabeh Golestani Kermani.

Conflicts of interest

The authors declared no conflict of interest.

مقاله پژوهشی

کاربرد مدل‌های هوش مصنوعی و سری زمانی در تخمین رواناب (مطالعه موردی: قسمتی از حوضه آبریز رودخانه هلیل)

الهه فرودی صفات^۱، محمد مهدی احمدی^{۲*}، کورش قادری^۳، سودابه گلستانی کرمانی^۴

۱. فارغ التحصیل مقطع کارشناسی ارشد رشته سازه‌های آبی، بخش علوم و مهندسی آب، دانشگاه شهید باهنر کرمان، کرمان، ایران

۲. دانشیار بخش علوم و مهندسی آب دانشگاه شهید باهنر کرمان، کرمان، ایران

۳. دانشیار بخش علوم و مهندسی آب دانشگاه شهید باهنر کرمان، کرمان، ایران

۴. استادیار بخش علوم و مهندسی آب دانشگاه شهید باهنر کرمان، کرمان، ایران

چکیده

مقدمه: پیش‌بینی دقیق رواناب و سیلاب برای جلوگیری از خسارتهای جانی و مالی یکی از چالش برانگیزترین کارها در مطالعات هیدرولوژیکی یک منطقه میباشند. از این رو، توسعه مدل‌های دقیق پیش‌بینی از قبیل روشهای هوش مصنوعی مورد توجه بیشتر محققین قرار گرفته است.

روش: در این تحقیق به بررسی کارایی ۳ مدل ANN، GMDH و ARIMA جهت شبیه‌سازی سیلاب قسمتی از حوضه رودخانه هلیل رود در استان کرمان پرداخته شد. مدل ANN یک روش مدل‌سازی غیرخطی است که به مرور عملکرد خود را بهبود می‌بخشد. GMDH یک مدل هوش مصنوعی با ویژگی‌های قابلیت خودسازماندهی اکتشافی است که در انتهای آن سیستمی پیچیده با عملکرد مطلوب شکل می‌گیرد. کد نوشته شده ARIMA به ساخت مدلی برای توصیف ساختار داده‌ها و سپس پیش‌بینی سری زمانی می‌پردازد. داده‌های ورودی به مدل‌های فوق شامل دبی، بارش، دما، باد و رطوبت ماهانه بودند و مقادیر رواناب شبیه‌سازی شده با مقادیر مشاهداتی مقایسه گردید.

یافته‌ها: جهت ارزیابی دقت مدل‌ها از شاخص‌های آماری RMSE، MSD و MAE استفاده شد و نتایج بدست آمده نشان داد مدل (RMSE=0/042 (m³/s) و MSD=0/001 (m³/s)²، MAE=0/027 (m³/s) ANN توانست رواناب را با دقت بالاتری در مقایسه با مدل (RMSE=0/068، MSD=0/005 و MAE=0/056) GMDH و سری زمانی (RMSE=0/096، MSD=0/009 و MAE=0/063) ARIMA در حوضه مورد مطالعه برآورد کند. میانگین خطا در تخمین رواناب با مدل ANN در مقایسه با مقادیر تخمین زده شده با مدل ARIMA و GMDH به ترتیب ۳۸/۲۳ و ۵۶/۲۵ درصد کاهش یافت.

نتیجه‌گیری: باتوجه به نتایج بدست آمده در این مطالعه، مدل شبکه عصبی مصنوعی به سبب توانایی ساختاری مناسب جهت پیدا کردن رابطه غیرخطی بین داده‌های ورودی و خروجی، توانسته است کارایی بهتری نسبت به دو مدل دیگر از خود نشان دهند.

تاریخ دریافت: ۱۴۰۰/۰۹/۲۱

تاریخ داوری: ۱۴۰۱/۰۱/۲۰

تاریخ پذیرش: ۱۴۰۱/۰۶/۱۵

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

[10.30495/wej.2023.29501.2345](https://doi.org/10.30495/wej.2023.29501.2345)

واژه‌های کلیدی:

بارش - رواناب، خودهمبسته با میانگین متحرک یکپارچه (ARIMA)، شبکه عصبی مصنوعی (ANN)، کنترل گروهی داده‌ها (GMDH)، مدیریت منابع آب.

* نویسنده مسئول: محمد مهدی احمدی

نشانی: گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران.

تلفن: ۰۹۱۵۵۵۱۶۳۷۰

پست الکترونیکی: Ahmadi_mm@uk.ac.ir

مقدمه

و هرچند ممکن است توانایی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشند، اما اغلب رواناب خروجی حوضه را به صورت دقیق تخمین می‌زنند (۹). دقت و توانایی این مدل‌ها در برخی از تحقیقات مورد توجه قرار گرفته است از جمله پورنعمت رودسری و همکاران (۱۳۹۳) به مدل‌سازی فرآیند بارش - رواناب با استفاده از روش ANN و GMDH در حوضه آبخیز پلرود پرداختند. براساس نتایج ایشان، مدل GMDH با ضریب رگرسیون ۰/۹۴۵ نسبت به مدل ANN با ضریب رگرسیون ۰/۸۹۵ عملکرد بهتری در مدل‌سازی بارش - رواناب این منطقه داشت (۹). عیسی زاده و همکاران (۱۳۹۶) برای شبیه‌سازی رواناب ماهانه حوضه خرخره چای از مدل‌های خطی خودهمبسته، خودهمبسته با میانگین متحرک و خودهمبسته میانگین متحرک یکپارچه، شبکه عصبی پرسپترون چند لایه، برنامه‌ریزی بیان ژن با چهار و سیزده تابع ریاضی و مدل ماشین بردار پشتیبان با سه تابع کرنل طی یک دوره ۲۴ ساله استفاده کردند. نتایج ایشان نشان داد که مدل پرسپترون چند لایه (۵,۳) با RMSE برابر با ۰/۸۴ برای دوره واسنجی و RMSE برابر با ۰/۸۶ برای اعتبارسنجی، مناسب‌ترین مدل برای شبیه‌سازی رواناب ماهانه حوضه مذکور است (۱۰).

بهینان مطلق و همکاران (۱۳۹۸) با استفاده از مدل رگرسیون کمترین مربعات فازی و مدل ARIMA و در نظر گرفتن دوره آماری ۲۵ ساله، به شبیه‌سازی دبی ماهانه حوضه آبخیز کوه سوخته پرداختند و مدل ARIMA را با NS برابر ۰/۸۸ به عنوان مدل کارا معرفی کردند (۱۱). تساکری و همکاران (۲۰۱۸) به بررسی مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیون خطی چندگانه برای پیش‌بینی سیلاب در رودخانه موهاک^۴ در نیویورک پرداختند. آنها بیان کردند که مدل شبکه عصبی مصنوعی یک مدل پیش‌بینی کارآمدتر در مقایسه با مدل‌های رگرسیون خطی ارائه می‌کند. با این حال، مدل رگرسیون خطی امکان تفسیر فیزیکی داده‌های تجزیه شده را فراهم می‌کند. آنها اظهار داشتند مدل ترکیبی تجزیه سری‌های زمانی و شبکه عصبی مصنوعی دقت بسیار بالایی دارد و مدل پیش‌بینی بهبود یافته‌ای برای خطر سیل تا ۹۶٪ را ارائه می‌دهد (۱۲). تبوسوم و دار (۲۰۲۰) با هدف توسعه مدل‌های جدید پیش‌بینی سیل با استفاده از ۵ الگوریتم مختلف شبکه عصبی مصنوعی، مطالعه‌ای بر روی رودخانه آبرفتی در منطقه کشمیر^۵ هند انجام دادند و مدل شبکه عصبی لونیگ - مارکوارت با میانگین مجذور خطای ۰/۰۰۲ را به عنوان بهترین مدل معرفی کردند (۱۳). دودانگه و همکاران (۲۰۲۰) به پیش‌بینی حساسیت سیل در حوضه آبخیز منطقه هراز-نکا در شمال ایران براساس SVR^۶ و GMDH پرداختند. نتایج آنها نشان داد که مدل SVR (RMSE=۰/۲۹ - ۰/۳۶) عملکرد بهتری نسبت به مدل GMDH (RMSE=۰/۳۶ - ۰/۳۹) داشت و همچنین می‌توان عملکرد این دو روش را در ترکیب با الگوریتم ژنتیک (GA) و جستجوی هارمونی (HS) به طور قابل توجهی بهبود بخشید (۱۴). دهانی و همکاران (۲۰۲۰) به پیش‌بینی سیلاب با استفاده

بالا رفتن درجه حرارت زمین و تغییرات گسترده در چرخه آب و هوا باعث وقوع حوادث شدید بارشی و همچنین فراوانی این حوادث شده است. به علاوه وسعت مناطق نفوذ ناپذیر به دلیل تغییر کاربری اراضی و دفعات وقایع شدید بارندگی در اغلب مناطق افزایش یافته است که در نهایت سبب بروز سیلاب‌های فراوان می‌شود (۱). انتظار می‌رود در آینده به دلیل تغییر آب و هوا، جنگل زدایی، افزایش سطح دریا و رشد جمعیت در مناطق مستعد سیل، این خسارات تشدید شود و نهایتاً تا سال ۲۰۵۰ تعداد افراد آسیب پذیر در برابر بلایای سیل به دو میلیارد نفر افزایش یابد (۲). وقوع سیلاب عامل مهمی در بروز خسارات اجتماعی و اقتصادی و همچنین از دست رفتن جان انسان‌ها است که یک خطر بالقوه برای مناطق پرجمعیت واقع در کناره و پایین رودخانه‌ها محسوب می‌شود (۳). از این رو لازم است که اقدامات حفاظتی سازه‌ای و غیرسازه‌ای برای کاهش اثرات سیلاب‌ها انجام شود. اگرچه اقدامات سازه‌ای (به عنوان مثال سد‌ها و خاکریزها) خطر سیل را کاهش می‌دهد، اما نمی‌تواند آن را به طور کامل از بین ببرد و بنابراین کارشناسان مدیریت سیلاب، خواستار توجه بیشتر به اقدامات غیرسازه‌ای هستند که بتواند خطرات سیلاب را کاهش دهد و سازوکارهای برگشت پذیر و کم-هزینه‌تری را برای کاهش خطر سیل فراهم کند (۲). از جمله نظارت دقیق و هشدار سریع سطح آب رودخانه که اقدامی مهم برای اطمینان از ایمنی زندگی ساکنان حوضه رودخانه است و پیش‌بینی دقیق سطح آب پیش نیاز اساسی برای این منظور است (۴). در واقع مدل‌سازی و پیش‌بینی دقیق سیلاب کلید مدیریت و آماده سازی برای حوادث شدید سیل است و مطلوب این است که این پیش‌بینی‌ها و هشدارها، دقیق و در اسرع وقت انجام شود (۵). لازمه این امر آن است که مدل ابتدا بر اساس داده‌های رویدادهای گذشته در هر منطقه به خوبی آموزش ببیند تا قادر باشد حوادث آینده را پیش‌بینی کند (۶). اما از آنجا که در پیش‌بینی‌های بلند مدت، دقت پیش‌بینی‌ها کاهش و عدم اطمینان افزایش می‌یابد، لازم است با اجرای بیش از یک مدل و مقایسه نتایج، به مدل برتر و پیش‌بینی قابل اعتمادتری دست پیدا کرد (۷). در این راستا روش‌های مختلفی مانند مدل‌های عددی، روش‌های آماری و تکنیک‌های یادگیری ماشین در دسترس است و مطالعات انجام شده نشان می‌دهد که تکنیک‌های یادگیری ماشین مانند شبکه عصبی مصنوعی (ANN^۱)، کنترل گروهی داده‌ها (GMDH^۲) و سری‌های زمانی از جمله مدل خودهمبسته با میانگین متحرک یکپارچه (ARIMA^۳) برای پیش‌بینی پدیده‌های هیدرولوژیکی مناسب هستند. زیرا فرآیندهای فیزیکی تأثیرگذار بر این پدیده‌ها، روابطی بسیار پیچیده و غیرخطی دارند و این روش‌ها توانایی بالایی در شناسایی روابط غیرخطی بین متغیرهای ورودی و خروجی بدون نیاز به درک ماهیت فرآیندهای فیزیکی را دارا می‌باشند (۸). مزیت استفاده از این روش‌ها، وارد کردن عدم قطعیت‌های ذاتی موجود در متغیرها و داده‌ها در مدل‌سازی است

^۴ -Mohawk

^۵ -Kashmir

^۶ -Support Vector Regression

^۱ -Artificial Neural Network (ANN)

^۲ -Group Method of Data Handling (GMDH)

^۳ -AutoRegressive Integrated Moving Average (ARIMA)

که مدل‌ها می‌توانند عملکرد مطلوبی داشته باشند. به همین منظور در تحقیق حاضر به ارزیابی دقت مدل‌های ANN و GMDH در مقایسه با سری زمانی ARIMA در تخمین رواناب بخشی از حوضه هلیل رود واقع در استان کرمان پرداخته شده است.

داده‌ها و روش‌ها

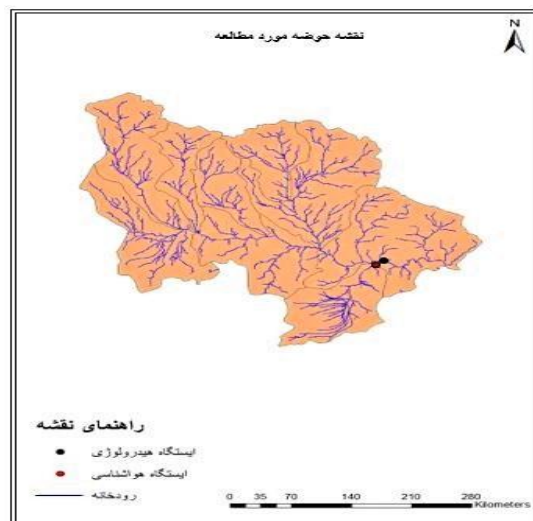
در این تحقیق به منظور شبیه‌سازی و پیش‌بینی رواناب از جعبه ابزار شبکه عصبی مصنوعی، کد GMDH نوشته شده در محیط نرم‌افزار MATLAB و سری زمانی ARIMA در حوضه آبریز هلیل رود استفاده گردید که در ادامه به بیان روش کار پرداخته شده است.

معرفی حوضه مورد مطالعه

رودخانه هلیل رود بزرگترین رود جنوب شرق ایران است که در استان کرمان واقع شده و زیر حوضه‌ی هامون - جازموربان می‌باشد. با توجه به مساحت حوضه آبریز تحت پوشش رودخانه هلیل، می‌توان گفت این رودخانه اصلی‌ترین منبع آبی منطقه می‌باشد. حوضه مورد مطالعه در تحقیق حاضر مساحت ۷/۳۷۱۱ کیلومتر مربع از زیر حوضه‌های حوضه آبریز رودخانه هلیل را دربر می‌گیرد. رودخانه اصلی این حوضه از سرشاخه رودخانه سلطانی شروع و به ایستگاه هیدرومتری کناروئیه با مختصات ۲۸° ۵۱' ۳۱" شمالی، ۱۴' ۲۳" ۵۷° شرقی و ارتفاع ۱۴۵۶ متر خاتمه می‌یابد که بخشی از اطلاعات آن در (جدول ۱) ارائه شده است. منطقه کناروئیه دارای ایستگاه هواشناسی نیز می‌باشد که موقعیت ایستگاه‌ها در (شکل ۱) نشان داده شده است. اطلاعات مورد استفاده در این تحقیق شامل دبی، بارش، دما، باد و رطوبت به صورت ماهانه از سال آبی ۱۹۹۳ (Oct. 1993) تا سال آبی ۲۰۱۵ (Sep. 2015) بودند که از شرکت آب منطقه‌ای کرمان دریافت شد.

از مدل ANN در جزیره موریس^۷ پرداختند. ایشان از داده‌های حداقل و حداکثر دما، بارندگی و رطوبت هوا گرد آوری شده از یازده ایستگاه هواشناسی به عنوان اطلاعات ورودی به مدل استفاده کردند. نتایج ایشان نشان داد که مدل ANN توانست سیلاب را با دقت مناسبی ($R^2 = 0.98$) تخمین بزند (۱۵). بانو و همکاران (۲۰۲۱) به پیش‌بینی سیلاب حوضه یامونا ناگارا^۸ در هند و مندل و بیسواس (۲۰۲۱) به پیش‌بینی رواناب حوضه رودخانه مایوراکشی^۹ در هند با استفاده از مدل ANN پرداختند و دقت قابل قبول این مدل در تخمین رواناب را گزارش کردند (۱۶ و ۱۷).

خداخواه و همکاران (۲۰۲۲) نیز به بررسی تغییرات جریان رودخانه با استفاده از روش‌های SARIMA، LSSVM، ANFIS و GMDH در دو حوضه آبریز رودخانه‌ای واقع در استان گیلان پرداختند. و مدل SARIMA را به عنوان بهترین مدل معرفی کردند. همچنین آنها بیان داشتند که مدل‌های تصادفی خطی برای پیش‌بینی ماهانه جریان رودخانه در این منطقه نسبت به دیگر مدل‌ها مناسب‌تر است (۱۸). در جوامع پیشرفته امروزی نیاز به الگوهای مناسب و مدل‌های دقیق تبدیل بارش به رواناب در بخش‌هایی از جمله کشاورزی، آب خانگی، بهره‌برداری از مخزن سدها، پیش‌بینی و سامانه‌های هشدار و مهار سیلاب برای کاهش آسیب‌های مالی و جانی مشهود است و در این راستا سری‌های زمانی و مدل‌های هوش مصنوعی ابزاری بسیار کارآمد برای مطالعه پدیده‌های هیدرولوژیکی هستند و با داشتن شناخت کافی از آن‌ها می‌توان تغییرات این پدیده‌ها در آینده را با دقت مناسب مدل‌سازی و پیش‌بینی کرد (۱۹). اما ضروری است که با توجه به خصوصیات هر حوضه، توانایی و دقت مدل‌های مختلف مورد مطالعه بیشتر قرار گیرد تا بتوان به انتخاب مناسب‌ترین مدل در شرایط خاص هر منطقه دست یافت. با توجه به ماهیت مدل‌های داده محور ANN و GMDH که به ترتیب براساس عملکرد شبکه عصبی مغز و مبنای ریاضی توسعه یافته‌اند و میزان داده‌های حوضه آبریز مورد مطالعه، فرض شده است



شکل ۱: موقعیت حوضه آبریز مورد مطالعه

⁹ -Mayurakshi

⁷ -Mauritius

⁸ -Yamuna Nagar

جدول ۱: اطلاعات رودخانه مورد مطالعه

متوسط دبی (m^3/s)	متوسط سالانه بارندگی (mm)	حداقل دما سالانه ($^{\circ}C$)	متوسط دما سالانه ($^{\circ}C$)	حداکثر دما سالانه ($^{\circ}C$)
۳/۴۲	۱۸۲/۴۲	۱۲	۲۰/۹	۲۹/۸

مدل‌های استفاده شده برای شبیه سازی رواناب

مدل ANN

در این روش برای تخمین رواناب از جعبه ابزار شبکه عصبی مصنوعی در نرم افزار MATLAB استفاده شد. شبکه عصبی مصنوعی یکی از روش‌های مدل‌سازی است که عملکرد خود را در انجام فعالیت‌ها به مرور بهبود می‌دهد و از جمله روش‌های غیر خطی توزیع داده‌ها است که به خوبی ارجحیت و برتری خود را در قیاس با روش‌های خطی نشان داده است. یک شبکه عصبی مصنوعی شبکه‌ای از عناصر ساده به نام

نرون است که ورودی را دریافت و تغییراتی در ورودی‌ها ایجاد می‌کند و سپس خروجی‌های شبکه را تولید می‌کند (۲۰). در این مدل‌سازی ۶۰٪ داده‌های ورودی برای آموزش، ۲۰٪ داده‌ها برای تست و ۲۰٪ داده‌ها برای اعتبارسنجی مورد استفاده قرار گرفت. دو سال آخر نیز برای پیش‌بینی مدل در نظر گرفته شد. پس از فراخوانی داده‌ها در نرم‌افزار MATLAB، مدل‌سازی انجام و شبکه‌ای با خصوصیت‌های زیر (جدول ۲) تشکیل شد.

جدول ۲: خصوصیت‌های مدل ANN

تعداد نرون	لایه پنهان	تابع انتقال	تابع آموزش	قانون یادگیری	نوع شبکه	الگوریتم
۵	۱	TANSIG	TRAINLM	BP	FF	Levenberg-Marquardt

داده‌های ورودی در این مدل شامل بارش، دما، باد و رطوبت ماهانه یک دوره قبل از سال آبی ۱۹۹۳ تا ۲۰۱۵ بود که با استفاده از رابطه (۱) به نرمال تبدیل شدند.

$$X_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

در رابطه (۱)، X_n داده نرمال شده، X داده هر سری و X_{min} و X_{max} به ترتیب کمترین و بیشترین مقدار در هر سری می‌باشند (۹). در این شبکه، لایه ورودی شامل ۴ نرون بود و پس از اجرای مدل با توجه به داده‌ها، جواب بدست آمده دارای یک لایه پنهان با ۵ نرون بود.

مدل GMDH

در این روش برای تخمین رواناب از کد GMDH نوشته شده در محیط MATLAB استفاده گردید. کد توسعه داده شده GMDH یکی دیگر از روش‌های مدل‌سازی است که در این رویکرد از الگوریتمی تکرار شونده و افزایشی استفاده می‌شود که شامل تولید و افزوده شدن ساختارهای پایه بسیار ساده است و به مرور با ترکیب این ساختارهای ساده، سیستمی پیچیده شکل می‌گیرد که دارای عملکردی مطلوب است. مبانی ریاضی الگوریتم GMDH براساس تجزیه سری توابع ولترا پایه‌ریزی شده که برای بیان ارتباط بین متغیرهای ورودی و خروجی است. این سری توابع مشابه با چند جمله‌ای گسسته شده کولموگروف-گابور^{۱۰} به شرح زیر است (۲۱).

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (2)$$

که در رابطه فوق a_0 ضریب ثابت، $A = (a_1, a_2, \dots, a_m)$ بردار وزن‌ها و $X = (x_1, x_2, \dots, x_m)$ بردار متغیرهای ورودی است (۹). پس از ساختن شبکه، عملکرد به صورتی است که خروجی هر لایه به عنوان ورودی لایه بعد در نظر گرفته می‌شود. تابع انتقال نرون‌ها از لایه‌ای به لایه دیگر می‌تواند به صورت چندجمله‌ای خطی و یا غیرخطی به صورت روابط (۳) و (۴) باشد که w_0 تا w_5 ضرایب این چندجمله‌ای‌ها هستند (۲۲).

$$y = g(x_1, x_2) = w_0 + w_1 x_1 + w_2 x_2 \quad (3)$$

$$y = g(x_1, x_2) = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2 \quad (4)$$

در این کدنویسی باید بهترین نرون‌های تولید شده در هر لایه که خطای کمتری دارند را انتخاب و به لایه بعد منتقل کرد. داده‌های ورودی در این مدل نیز شامل بارش، دما، باد و رطوبت ماهانه یک دوره قبل از سال آبی ۱۹۹۳ تا ۲۰۱۵ بود که با استفاده از رابطه (۱) به نرمال تبدیل شدند. داده‌ها به دو بخش آموزش و تست تقسیم و دو سال آخر برای پیش‌بینی در نظر گرفته شد. در این مدل‌سازی، تعداد بهترین نرون‌های منتخب هر لایه برای ورود به لایه بعد به صورت $X = 0.2 L_1$ بود که بهترین عملکرد را داشت. قبل از آغاز فرآیند مدل‌سازی، به اعتبارسنجی مدل توسعه داده شده GMDH با سری زمانی Mackey_Glass پرداخته شد.

صحت سنجی مدل توسعه داده شده GMDH

¹⁰-Gabor – Kolmogorov

در تحقیق حاضر از سری زمانی ARIMA نیز برای تخمین رواناب استفاده گردید. هدف از تجزیه و تحلیل سری‌های زمانی، مطالعه سری-های زمانی و ساخت مدلی برای توصیف ساختار داده‌ها و سپس پیش-بینی مقادیر آینده سری‌های زمانی است و با توجه به اهمیت پیش‌بینی سری زمانی، ساخت یک مدل موثر با هدف بهبود دقت پیش‌بینی ضروری است (۲۴). سری زمانی ARIMA در تحقیق حاضر در محیط نرم‌افزار MATLAB نوشته شد. داده‌های ورودی در این مدل نیز شامل بارش، دما، باد و رطوبت ماهانه یک دوره قبل از سال آبی ۱۹۹۳ تا ۲۰۱۵ بود که با استفاده از رابطه (۱) به نرمال تبدیل شدند و دو سال آخر برای پیش‌بینی در نظر گرفته شد. پس از طی مراحل بالا، مدل ARIMA(1,0,2) با مشخصات زیر (جدول ۳) برای شبیه سازی فرآیند بارش- رواناب ساخته شد.

جدول ۳: خصوصیت‌های مدل ARIMA

توزیع احتمال شرطی	ضریب ثابت	واریانس	p	d	q
Gaussian	۰/۰۳۲۶۹۶۲	۰/۰۰۸۳۰۷۲۹	۱	۰	۲

جدول ۴ نتایج شاخص‌های ارزیابی شبیه‌سازی فرآیند بارش- رواناب مدل‌های فوق را ارائه داده است. طبق نتایج جدول ۴ مدل ANN دقت بالاتری (RMSE=۰/۰۴۲(m³/s)، MSD=۰/۰۰۱(m³/s)² و MAE=۰/۰۲۷(m³/s)) نسبت به مدل (RMSE=۰/۰۶۸(m³/s)، MSD=۰/۰۰۵(m³/s)² و MAE=۰/۰۵۶(m³/s)) GMDH و (RMSE=۰/۰۹۶(m³/s)، MSD=۰/۰۰۹(m³/s)² و MAE=۰/۰۶۳(m³/s)) سری زمانی ARIMA در تخمین رواناب حوضه مورد مطالعه داشته است. شکل ۲ نمودار خروجی مدل ANN و دبی مشاهداتی ایستگاه کنارویی را نشان می‌دهد. براساس شکل ۲ مشخص است، مدل ANN در دوره‌های آموزش، اعتبارسنجی و تست هم در دبی پیک و هم در دبی کم عملکرد بسیار مناسبی از خود نشان داده است. شکل ۳ نمودار خروجی مدل GMDH و دبی مشاهداتی ایستگاه کنارویی را نشان می‌دهد. باتوجه به شکل ۳ مشخص است، مدل GMDH در دوره‌های آموزش، اعتبارسنجی و تست در تخمین دبی پیک اختلاف قابل توجهی نسبت به دبی مشاهداتی دارد و در دبی کم عملکرد بهتری از خود نشان داده است. به دلیل اینکه مرحله آموزش و اعتبارسنجی مدل ARIMA با دو مدل دیگر متفاوت است، در جدول ۴ فقط نتایج دوره تست ارائه شده است و برای دوره واسنجی و اعتبارسنجی مدل ARIMA باتوجه به نتایج ارائه شده در جدول ۵ و آزمون ADF تست که برابر با یک شد، می‌توان به شایستگی مدل ARIMA(1,0,2) ساخته شده پی برد.

اعتبارسنجی مدل GMDH توسط معادله دیفرانسیلی Mackey-Glass مورد بررسی قرار گرفت. این معادله به صورت زیر می‌باشد:

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad (5)$$

در این رابطه مقادیر a و b به ترتیب ۰/۲ و ۰/۱ است و شرایط اولیه به صورت $x(0)=1/2$ ، $\tau=17$ و مقادیر منفی برابر با صفر در نظر گرفته شدند (۲۳). در این مدل‌سازی از مقادیر گذشته سری زمانی تا زمان t برای پیش‌بینی مقادیر سری زمانی در گام زمانی t+p استفاده شد. در این تحقیق p=6 انتخاب شد؛ در حالی که ورودی‌ها $\{x(t-18), x(t-12), x(t-6), x(t)\}$ هستند، سری زمانی Mackey-Glass برای زمان $x(t+6)$ محاسبه گردید. از ۵۰۰ جفت داده اولیه برای آموزش و ۵۰۰ جفت داده باقی مانده برای تست استفاده شد.

مدل ARIMA

قبل از ساخت مدل و برای پرهیز از رگرسیون‌های کاذب، ابتدا مانایی متغیرها مورد بررسی قرار گرفت که برای این منظور از آزمون ریشه واحد دیکی فولر تعمیم یافته (ADF) استفاده گردید. با استفاده از این آزمون، مانایی و یا واگرایی سری زمانی بررسی می‌شود (۲۵).

ارزیابی دقت مدل‌ها

برای ارزیابی دقت مدل‌های ANN، GMDH و ARIMA از شاخص-های آماری جذر میانگین مربعات خطا (RMSE)، میانگین مجذور انحراف (MSD) و میانگین قدرمطلق خطا (MAE) مطابق روابط (۶) الی (۸) استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{n}} \quad (6)$$

$$MSD = \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{n} \quad (7)$$

$$MAE = \frac{\sum_{i=1}^n |Q_{obs} - Q_{sim}|}{n} \quad (8)$$


در روابط فوق Q_{obs} مقدار دبی مشاهداتی، Q_{sim} مقدار دبی شبیه‌سازی شده، n تعداد کل داده‌ها و μ میانگین می‌باشد (۱۹). نزدیکی مقادیر حاصل از شاخص‌های مذکور به صفر، نشان دهنده دقت بیشتر مدل در تخمین رواناب منطقه است.

نتایج و بحث


در این تحقیق به بررسی عملکرد پیش‌بینی مدل‌های ANN، GMDH و ARIMA برای تخمین رواناب قسمتی از حوضه آبریز هلیل رود پرداخته شد.

جدول ۴: شاخص‌های ارزیابی شبیه‌سازی فرآیند بارش - رواناب با مدل ANN و GMDH و ARIMA

مدل	معیار	آموزش	اعتبارسنجی	تست
ANN	RMSE (m^3/s)	۰/۰۸۹	۰/۰۳۹	۰/۰۴۲
	MSD (m^3/s^2)	۰/۰۰۸	۰/۰۰۱	۰/۰۰۱
	MAE (m^3/s)	۰/۰۵۱	۰/۰۲۹	۰/۰۲۷
GMDH	RMSE (m^3/s)	۰/۱۳۲	۰/۰۳۸	۰/۰۶۸
	MSD (m^3/s^2)	۰/۰۱۷	۰/۰۰۱	۰/۰۰۵
	MAE (m^3/s)	۰/۰۸۲	۰/۰۲۹	۰/۰۵۶
ARIMA	RMSE (m^3/s)	—	—	۰/۰۹۶
	MSD (m^3/s^2)	—	—	۰/۰۰۹
	MAE (m^3/s)	—	—	۰/۰۶۳



شکل ۲: مقایسه نتایج خروجی مدل ANN و دبی مشاهداتی ایستگاه کناروئیه



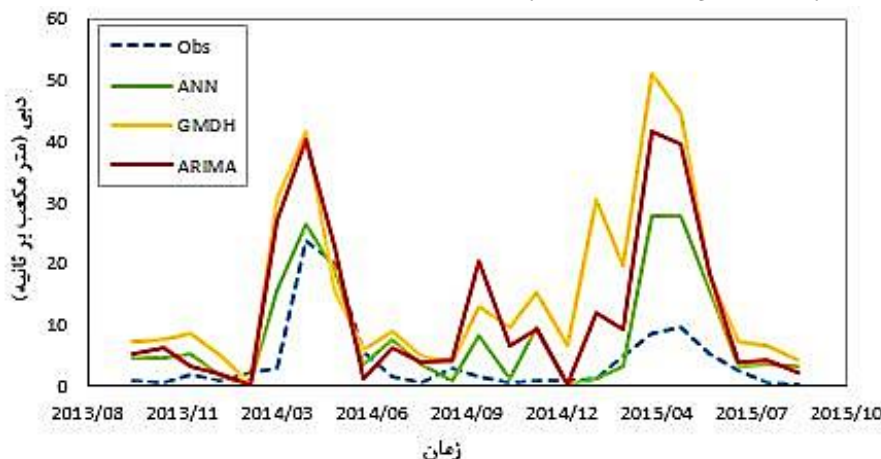
شکل ۳: مقایسه نتایج خروجی مدل GMDH و دبی مشاهداتی ایستگاه کناروئیه

جدول ۵: پارامترهای مدل ARIMA

پارامتر	مقدار پارامتر	خطای استاندارد	آماره T
AR (1)	۰/۴۲۴۴۱۸	۰/۲۴۸۱۱۲	۱/۷۱۰
MA (1)	۰/۲۸۱۱۷۸	۰/۲۶۷۲۵	۱/۰۵۲۱۲
MA (2)	۰/۰۹۶۳۳۷	۰/۱۹۰۰۲۲	۰/۵۲۴۳۲۷

است هم در نقاط پیک و هم در نقاط با دبی کم، تخمین دقیق تری از رواناب نسبت به دو مدل دیگر داشته باشد.

شکل ۴ مقایسه نتایج خروجی مدل‌های ANN، GMDH و ARIMA را نسبت به دبی مشاهداتی ایستگاه مورد مطالعه برای دو سال آخر دوره آماری نشان می‌دهد. همانگونه که مشخص است مدل ANN توانسته



شکل ۴: مقایسه نتایج شبیه‌سازی مدل‌های ANN، GMDH و ARIMA و دبی مشاهداتی ایستگاه کناروئیه

مدت نسبت به مدل ANN ندارد (۱۰ و ۲۹) که با نتایج حاضر سازگاری دارد. توجه به این مطلب ضروری است که با توجه به محدودیت و تفاوت ماهیت و نوع داده‌های در دسترس در هر حوضه آبریز، عملاً امکان پیشنهاد قطعی یک مدل و اطمینان از کاربری دقیق آن در همه حوضه‌ها وجود ندارد (۳۰) و اصولاً ارائه مدل‌های جدید در زمینه تخمین رواناب نشان می‌دهد مدلی که بتواند با قطعیت بهترین کارایی را در تخمین رواناب داشته باشد به وجود نیامده است. لذا ضروری است که این موضوع همواره در مورد حوضه‌های مختلف مورد بررسی قرار گرفته و مدل مناسب بر اساس شرایط موجود معرفی گردد.

نتیجه‌گیری

در تحقیق حاضر به ارزیابی دقت مدل‌های هوشمند شبکه عصبی مصنوعی ANN، کنترل گروهی داده‌ها GMDH و سری زمانی ARIMA در تخمین رواناب بخشی از حوضه آبریز هلیل رود پرداخته شد. از داده‌های بارش، دما، باد و رطوبت ماهانه یک دوره قبل در بازه آماری ۱۹۹۳ تا ۲۰۱۵ ایستگاه کناروئیه برای مدل‌سازی استفاده شد و از شاخص‌های آماری برای ارزیابی دقت مدل‌ها استفاده گردید. براساس نتایج بدست آمده دقت مدل $RMSE=0.042 (m^3/s)$ ، $MSD=0.001 (m^3/s)^2$ و $MAE=0.027 (m^3/s)$ ANN نسبت به دو مدل $RMSE=0.068 (m^3/s)$ ، $MSD=0.005 (m^3/s)^2$ و $MAE=0.056 (m^3/s)$ GMDH و $RMSE=0.096 (m^3/s)$ ، $MSD=0.005 (m^3/s)^2$ و $MAE=0.056 (m^3/s)$ ARIMA

در مجموع بررسی نتایج بدست آمده نشان می‌دهد که عملکرد مدل ANN در تخمین رواناب حوضه مورد نظر در مقایسه با دو مدل دیگر قابل قبول‌تر بوده و بهترین نتایج از این مدل با لحاظ کردن ۴ پارامتر ورودی و ۱ لایه پنهان با ۵ نرون حاصل شده است. میانگین خطا در تخمین رواناب با مدل ANN در مقایسه با مقادیر تخمین زده شده با مدل GMDH و ARIMA به ترتیب ۳۸/۲۳ و ۵۶/۲۵ درصد کاهش یافته است. در واقع به نظر می‌رسد که مدل شبکه عصبی مصنوعی به سبب توانایی ساختاری مناسب جهت پیدا کردن رابطه غیرخطی بین داده‌های ورودی و خروجی، در صورت استفاده از داده‌های با دقت بالا می‌تواند فرآیند حاکم بر داده‌ها را به خوبی فراگرفته و در پیش‌بینی خروجی‌ها، کارایی بهتری از خود نشان دهد که نتایج بسیاری از تحقیقات انجام شده در زمینه پیش‌بینی رواناب از جمله تساکری و همکاران (۲۰۱۸)، تبوسوم و دار (۲۰۲۰)، دهانی و همکاران (۲۰۲۰)، مازومدر و همکاران (۲۰۲۱)، ساهو و همکاران (۲۰۲۲)، وونگ و همکاران (۲۰۲۲) نیز موید همین مطلب است (۱۲، ۱۳، ۱۵، ۲۶، ۲۷ و ۲۸). همچنین نتایج ارائه شده توسط برخی محققان نیز نشان داد که مدل GMDH و سری‌های زمانی در مقایسه با مدل ANN از دقت کمتری در شبیه‌سازی برخوردارند که این ضعف می‌تواند به این علت باشد که در شبیه‌سازی سری زمانی جریان ماهانه، جریان در هر ماه تابعی از جریان‌های ماه قبل می‌باشد و عوامل بسیاری موجب کاهش یا افزایش جریان رودخانه می‌شوند که در محاسبات وارد نمی‌شود و مدل GMDH دقت رضایت بخشی در پیش‌بینی‌های کوتاه مدت و بلند

حامی مالی

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

طراحی و ایده‌پردازی: الهه فرودی صفات، محمد مهدی احمدی، کورش قادری؛

روش‌شناسی و تحلیل داده‌ها: الهه فرودی صفات، محمد مهدی احمدی، کورش قادری؛

نظارت و نگارش نهایی: محمد مهدی احمدی، کورش قادری، سودابه گلستانی کرمانی.

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

ARIMA سری زمانی (MAE=0/063 (m³/s) و MSD=0/009 برای مدل‌سازی و پیش‌بینی رواناب در این حوضه بالاتر است. توجه به این نکته ضروری است که ارزیابی دقت مدل‌های هوشمند در هر حوضه و اطمینان از عملکرد آنها، همواره یک موضوع چالشی بوده و امکان ارائه نظر قطعی در مورد دقت مدل‌ها به دلیل ویژگی‌های خاص هر منطقه و ارائه مدل‌های جدید وجود ندارد و لازم است به صورت جداگانه بررسی شود.

پیشنهادها

پیشنهاد می‌شود فرآیند شبیه‌سازی رواناب در مقیاس روزانه و همچنین مقایسه نتایج بدست آمده با دیگر مدل‌های هوشمند و یا هیدرولوژیکی و مدل‌های ترکیبی مورد بررسی قرار گیرد. همچنین ضروری است که عملکرد مدل‌های مذکور جهت اطمینان از قابلیت تعمیم کاربری آنها در حوضه‌های آبریز مختلف مورد بررسی قرار گیرد.

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت‌کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.

References

1. Lee, E.H., Kim, J.H. 2018. Development of a Flood-Damage-Based Flood Forecasting Technique. *Journal of Hydrology*, 563, pp 181-194.
2. Jain, S.H.K., Mani, P., Jain, S.K., Prakash, P., Singh, V.P., Tullos, D., Kumar, S., Agarwal, S.P., Dimri, A.P. 2018. A Brief review of flood forecasting techniques and their applications. *International Journal of River Basin Management*, 16(3), pp 329-344.
3. Le, X.H., Ho, H.V., Lee, G., Jung, S. 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*, 11(7), 1387.
4. Li, Y., Shi, H., Liu, H. 2020. A hybrid model for river water level forecasting: Cases of Xiangjiang River and Yuanjiang River. *China. Journal of Hydrology*, 587, pp 1-13.
5. Wu, W., Emerton, R., Duan, Q., Wood, A., W., Wetterhall, F., Robertson, D., E. 2020. Ensemble flood forecasting: Current status and future opportunities. *WILEY*, 3(29), pp 1-32.
6. Jun, C.L., Mohamed, Z.S., peik, A.L., Razali, S.F., Sharil, S. 2016. Flood forecasting model using empirical method for a small catchment area. *Journal of Engineering Science and Technology*, 11(5), pp 666-672.
7. Rodriguez Rivero, C., Patiño, H.D., Pucheta, J., Sauchelli, V. 2016. A new Approach for Time Series Forecasting: Bayesian Enhanced by Fractional Brownian Motion with application to rainfall series. *International Journal of advanced Computer Science and Applications*, 7(2), pp 1-8.
8. Kumar, S., Roshni, T., Himayoun, D. 2019. A Comparison of Emotional Neural Network (ENN) and Artificial Neural Network (ANN) Approach for Rainfall-Runoff Modelling. *Civil Engineering Journal*, 5(10), pp 2120-2130.
9. Pournemat Roudsari, A., Qaderi, K., Karimi-Googhari, S.H. 2014. Rainfall Runoff Modeling using Group Method of Data Handling (GMDH) and Artificial Neural Network (ANN) In Polrood Basin. *Journal of Watershed Management Research*, 5(10), pp 68-84. [In Persian].
10. Isazadeh, M. Ahmadzadeh, H., Ghorbani, M.A., Fazelifard, M.H. 2018. An Assessment of Time Series and

- Autoregressive Artificial Neural Network Models, Support Vector Machine and Gene Expression Programming Models Performance in Monthly River Flow Simulation (Case Study: Kherkherechi River Basin). *Irrigation Sciences and Engineering*, 40(4), pp 91-107. [In Persian].
11. Behyan Motlagh, S., Honarbakhsh, A., Abdolahi, KH., Pajouhesh, M. 2020. Evaluation of the Efficiency of Time Series and Fuzzy Models in Monthly Discharge Modeling (Case Study: Kohsukhteh Watershed). *Hydrogeomorphology*, 6(21), pp 65-86. [In Persian].
 12. Tsakiri, K., Marsellos, A., Kapetanakis, S. 2018. Artificial Neural Network and Multiple Linear Regression for Flood Prediction in Mohawk River, New York. *Water*, 10(9), 1158.
 13. Tabbussum, R., Dar, A.Q. 2020. Comparative analysis of neural network training algorithms for the flood forecast modelling of an alluvial Himalayan river. *J Flood Risk Management*, 13: e12656.
 14. Dodangeh, E., Panahi, M., Rezaie, F., Lee, S., Tien Bui, D., Lee, C.W., Pradhan, B. 2020. Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology*, 590, 125423.
 15. Dhunny, A.Z., Seebocus, R.H., Allam, Z., Chuttur, M.Y., Eltahan, M., Mehta, H. 2020. Flood Prediction using Artificial Neural Networks: Empirical Evidence from Mauritius as a Case Study. *Knowledge Engineering and Data Science*, 3(1), pp 1-10.
 16. Bano, P., Singh, R., Aggarwal, G. 2021. Forecasting of Flood in Upper Yamuna Basin by Using Artificial Neural Network and Geoinformatics Techniques & Learning. *Ilkogretim Online*, 20(5), pp 3008-3021.
 17. Mandal, S., Biswas, S. 2021. Runoff Prediction Using Artificial Neural Network and SCS-CN Method: A Case Study of Mayurakshi River Catchment, India. In *Water Security and Sustainability: Proceedings of Down to Earth 2019*, Springer Singapore, pp 27-42.
 18. Khodakhah, H., Aghelpour, P., Hamed, Z. 2022. Comparing linear and non-linear data-driven approaches in monthly river flow prediction, based on the models SARIMA, LSSVM, ANFIS, and GMDH. *Environ Sci Pollut Res* 29, 21935–21954.
 19. Motamednia, M., Karimi Zarchi, K., Nohegar, A., Saberi Anari, M., Malekian, A. 2019. An Assessment the Performance of Genetic Programming and Auto Regressive Moving Average on the Daily Discharge Prediction (Case study: The Amameh Watershed). *Watershed Management Research*, 32(2), pp 2-18. [In Persian].
 20. Azizi, H., Montazeri, M. 2015. Anticipated Monthly Temperatures for Selected Stations in Isfahan Province Using Artificial Neural Network Multi-Layer Perceptron. *GeoRes*, 30(3), 241-258. [In Persian].
 21. Abrishami Moghaddam, H., Abdoli, GH., Ahrari, M., Dolatabadi, S. 2012. Applying GMDH Algorithm for rule extraction from the oil price behavior. *Energy Economics Review*, 9(32), pp 147-168. [In Persian].
 22. Eivani, Z., Ahmadi, M.M., Qaderi, K. 2016. Estimation of Suspended Sediment Load Concentration in River System using Group Method of Data Handling (GMDH). *Journal of Watershed Management Research*, 7(13), pp 218-229. [In Persian].
 23. Zhongda, T., Shujiang, L., Yanhong, W., Yi, S. (2017). A prediction method based on wavelet transform and multiple models

- fusion for chaotic time series. *Chaos, Solitons and Fractals*, 98, PP 158-172.
24. Siami, Namini, S., Tavakoli, N., Siami, Namin, A. 2018. A Comparison of ARIMA and LSTM in Forecasting Time Series. 17th IEEE International Conference on Machine Learning and Applications, pp 1394-1401.
 25. Mehdiabadi, M., Mohammadi pour, R. 2019. Determining the nonlinear effect of the money market interest rate on the Tehran stock exchange by the means of generalized autoregressive conditional heteroskedasticity (GARCH) model and smooth transition regression (STR) model. *Financial Engineering and Securities Management (Portfolio Management)*. 10(40), pp 126-151. [In Persian].
 26. Mazumder, M. T. R., Gupta, B. C. 2021. Flood Forecasting Using Artificial Neural Network (ANNs): A Case study of Jamuna River. In: AGU Fall Meeting 2021, held in New Orleans, LA, 13-17 December 2021.
 27. Sahoo, B., Nanda, T., Chatterjee, C. 2022. Flood Forecasting Using Simple and Ensemble Artificial Neural Networks. In: Pandey, A., Chowdary, V.M., Behera, M.D., Singh, V.P. (eds) *Geospatial Technologies for Land and Water Resources Management*. Water Science and Technology Library, vol 103. Springer, Cham.
 28. Wong, W. M., Subramaniam, S. K., Feroz, F. S., Ai Fen Rose, L. 2022. Short-term Water Level Forecast Using ANN Hybrid Gaussian-Nonlinear Autoregressive Neural Network. *International Journal of Integrated Engineering*, 14(4), 425-437.
 29. Ziari, H., Sobhani, J., Ayoubinejad, J., Hartmann, T. 2015. Prediction of IRI in short and long terms for flexible pavements: ANN and GMDH methods, *International Journal of Pavement Engineering*.
 30. Rosamma, C.N. 2022. Applicability of Soft Computational Models for Integrated Water Resource Management. In: *Modeling and Simulation of Environmental Systems*. 1st Edition.

