

Rainfall-runoff simulation in Sagesh sub-basin using an artificial neural network model

Saeed Azadi ¹, Amin Toranjian ^{2*}, Saman Mostafaei ³

¹ Former Ph.D. Student, Department of Water Science Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

² Assistant Professor, Department of Water and Soil Science, Faculty of Agriculture, Malayer University, Malayer, Iran

³ Former M.Sc. Student, Department of Water and Soil Science, Faculty of Agriculture, Malayer University, Malayer, Iran

Extended Abstract

Introduction

The rainfall-runoff process, which is affected by various hydrological parameters, is one of the most complex hydrological processes and one of the most basic hydrological topics related to understanding and predicting the processes of runoff production and transfer. It is the outlet point of the watershed. Planning and optimal utilization of runoff is one of the essential issues in watersheds. Therefore, knowing the natural capacity of runoff production and simulating rainfall-runoff is very important. Artificial intelligence and the use of neural network models are one of the methods for rainfall-runoff forecasting. An artificial neural network is a method with the ability to learn, understand, master relationships, and resist errors. Today, artificial intelligence black-box methods such as self-constructing and self-learning functions have a wide ability to model and predict complex problems.

Materials and Methods

The purpose of this research is to evaluate the performance of the artificial neural network model for rainfall-runoff simulation in the Sagesh sub-basin in Kurdistan province. To carry out this research, 18-year (2001-2018) data received daily from the Meteorological Organization and Sagesh Regional Water and Hydrometry Company have been used. In this study, two types of meteorological and hydrometric data were used. The meteorological parameters used include precipitation, evaporation, average temperature, maximum and minimum temperature, and the hydrometric parameter used in this research was only discharge. In the Sagesh basin, rainfall-runoff changes have always been considered one of the prominent hydrological indicators. Since the Turpentine sub-basin is considered an open basin in terms of its nature, precipitation can be considered a suitable alternative for investigating discharge in the study area of this research. As a result, precipitation is selected as a potential input variable, and the adequacy of the remaining variables will be tested separately for the neural network model. In this research, the meteorological parameters used include precipitation, evaporation, average temperature, and maximum and minimum temperature, and the hydrometric parameter used in this research was only discharge. Finally, to simulate rainfall-runoff using an artificial neural network model, scenarios with different input variables were considered. To evaluate and validate the performance results of the simulated model in different scenarios of this study, four statistical criteria of correlation coefficient (R), root mean square error (RMSE), mean absolute error (MAE), and Nash-Sutcliffe index (NSE) were used.

Results and Discussion

Six investigated scenarios were randomly selected by combining different inputs. In the first scenario, the input variable includes precipitation, and the output variable is discharge. In the second scenario, the input variables include precipitation and evaporation, and the output variable is discharge. In the third scenario, the input variables include precipitation and average temperature, and the output variable is discharge. In the fourth scenario, the input variables include precipitation and flow variables with a one-day delay, and the output variable is flow. In the fifth scenario, the input variables include precipitation, average temperature, maximum and minimum temperature, and the output variable is discharge. In the sixth scenario, the input variables include precipitation, evaporation, average temperature, maximum and minimum temperature, and the output variable is discharge. In all six scenarios, the output variable is the flow rate. Also, in the modeling, 70% of the data for the training section and 30% of the data for the test section were examined. According to the final results, the performance of the artificial neural network model in scenario number four (input variables including rainfall and discharge with a one-day delay) among the six developed scenarios, with correlation coefficient values of 0.92, mean squared error of 6.65, mean absolute error of 2.04 and the Nash-Sutcliffe index of 0.84 in the training section with the values of 0.91, 5.34, 1.57, and respectively 0.82 selected as the best combination in the test

section, and in terms of statistical performance indicators, the results of the Nash-Sutcliffe index values in the training and test section were closer to one, which indicates a good match between the observed values and those simulated. Also, the correlation coefficient specifies the amount of agreement and distribution of observational data with the predicted results, which indicates that the error measurement indicators and data distribution in the training and test sections are a favorable result for prediction. The amount of discharge in this scenario shows that it has a much better performance than the rest of the scenarios. Also, in the fourth scenario, changes in the time series of observed discharge values against the simulated values in the training and test phases were investigated in the artificial neural network model. According to this figure, compared to the observed value, the simulated flow rate had good accuracy and an acceptable error value.

Conclusion

The obtained results showed that for the sub-basin of Turpentine, the algorithm of the artificial neural network model for simulating rainfall-runoff on a suitable daily scale has obtained suitable and acceptable results. So it can be said that artificial neural network modeling has high accuracy and low error for the study area. Also, artificial intelligence models can be used as a useful tool and a reliable approach for water resource managers.

Keywords: Artificial Intelligence, Discharge, Modeling, Water Resources Management.

Article Type: Research Article

Acknowledgement

We would like to express our sincere gratitude to the University of Malayer for the financial and logistical support that significantly contributed to this research project.

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data Availability Statement:

The datasets are available upon a reasonable request to the corresponding author.

Authors' contribution

Saeed Azadi: Writing-original draft preparation, Manuscript editing, Visualization; **Amin Toranjian:** Supervision, Conceptualization, methodology; **Saman Mostafaei:** Resources, Software, Formal analysis and investigation.

*Corresponding Author, E-mail: a.toranjian@malayeru.ac.ir

Citation: Azadi, S., Toranjian, A., & Mostafaei, S. (2025). Rainfall-runoff simulation in Saez sub-basin using artificial neural network model. *Water and Soil Management and Modeling*, 5(3), 74-87.
doi: 10.22098/mmws.2025.16468.1535

Received: 31 December 2024., Received in revised form: 01 February 2025, Accepted: 15 April 2025., Published online: 23 September 2025.

Water and Soil Management and Modeling, Year 2025, Vol. 5, No. 3, pp. 74-87.

Publisher: University of Mohaghegh Ardabili

© Author(s)





شبیه سازی بارش-رواناب در زیرحوضه سقز با استفاده از مدل شبکه عصبی مصنوعی

سعید آزادی^۱، امین ترنجیان^{۲*}، سامان مصطفایی^۳

^۱ دانش آموخته دکتری، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

^۲ استادیار، گروه علوم و مهندسی آب و خاک، دانشکده کشاورزی، دانشگاه ملایر، ملایر، ایران

^۳ دانش آموخته کارشناسی ارشد، گروه علوم و مهندسی آب و خاک، دانشکده کشاورزی، دانشگاه ملایر، ملایر، ایران

چکیده

برنامه ریزی و بهره برداری بهینه از رواناب یکی از مسائل ضروری در حوزه های آبخیز است. بنابراین آگاهی از ظرفیت طبیعی تولید رواناب و شبیه سازی بارش-رواناب دارای اهمیت زیادی است. هوش مصنوعی و استفاده از مدل های شبکه عصبی یکی از روش های پیش بینی بارش-رواناب است. هدف از این پژوهش ارزیابی عملکرد مدل شبکه عصبی مصنوعی برای شبیه سازی بارش-رواناب در زیرحوضه سقز است. به منظور انجام این پژوهش، داده های روزانه هواشناسی و آب سنجی منطقه شامل بارش، دما و تبخیر و دبی در دوره آماری ۱۸ ساله (۱۳۹۷-۱۳۸۰) تهیه و مورد بررسی قرار گرفت. ارزیابی عملکرد مدل، با استفاده از شش سناریوی ترکیبی و چهار معیار آماری ضریب همبستگی (R)، میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و شاخص نش-ساتکلیف (NSE) انجام شد. متغیرهای ورودی در سناریوی اول بارش، در سناریو دوم بارش و تبخیر، در سناریوی سوم بارش و دمای میانگین، در سناریوی چهارم، بارش و متغیر دبی با یک روز تأخیر، در سناریوی پنجم، بارش، دمای میانگین، بیشینه دما و کمینه و در سناریوی ششم، بارش، تبخیر و دمای میانگین و بیشینه و کمینه دما می باشند. در تمامی سناریوها نیز دبی به عنوان متغیر خروجی در نظر گرفته شد. پس از بررسی تمامی سناریوها، نهایتاً مدل پیشنهادی شبکه عصبی مصنوعی در سناریوی چهارم که متغیرهای ورودی شامل بارش و دبی همراه با یک روز تأخیر بود، با مقادیر ضریب همبستگی ۰/۹۲، میانگین مربعات خطا ۶/۶۵، میانگین خطای مطلق ۲/۰۴ و شاخص نش-ساتکلیف ۰/۸۴ در بخش آموزش به ترتیب با مقادیر ۰/۹۱، ۵/۳۴، ۱/۵۷ و ۰/۸۲ در بخش آزمون عملکرد بهتری نسبت به سایر مدل های توسعه یافته شده، از خود نشان داد. نتایج نشان داد استفاده از مدل شبکه عصبی مصنوعی به عنوان یکی از مدل های هوش مصنوعی برای شبیه سازی بارش-رواناب در مقیاس روزانه مناسب و دارای صحت بالا و خطای کم برای منطقه مطالعاتی بوده و می تواند به عنوان ابزاری مفید و رویکردی قابل اعتماد در اختیار مدیران منابع آب قرار گیرد.

واژه های کلیدی: دبی، مدل سازی، مدیریت منابع آب، هوش مصنوعی.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: a.toranjian@malayeru.ac.ir

استناد: آزادی، سعید، ترنجیان، امین، و مصطفایی، سامان (۱۴۰۴). شبیه سازی بارش-رواناب در زیرحوضه سقز با استفاده از مدل شبکه عصبی

مصنوعی. *مدل سازی و مدیریت آب و خاک*، ۵(۳)، ۷۴-۸۷.

doi: 10.22098/mmws.2025.16468.1535

تاریخ دریافت: ۱۴۰۳/۱۰/۱۱، تاریخ بازنگری: ۱۴۰۳/۱۱/۱۳، تاریخ پذیرش: ۱۴۰۴/۰۱/۲۶، تاریخ انتشار: ۱۴۰۴/۰۷/۰۱

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۴، دوره ۵، شماره ۳، صفحه ۷۴ تا ۸۷

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

فرآیند بارش-رواناب که از پارامترهای مختلف هیدرولوژیکی تأثیر می پذیرد یکی از پیچیده ترین فرآیندهای هیدرولوژیکی به شمار می آید و از اساسی ترین مباحث هیدرولوژی مربوط به درک و پیش بینی فرآیندهای تولید رواناب و انتقال آن به نقطه خروجی حوزه آبخیز است (Solgi et al., 2015).

اهمیت و ضرورت مهار آب های سطحی جهت سیاست گذاری و برنامه ریزی های تأمین آب با وجود افزایش روزافزون تقاضای آب و هدر رفتن حجم زیادی از رواناب ها در کشور، و به علت عدم کنترل بیش از پیش آن ضرورت می یابد. بدیهی است برآورد صحیح جریان رواناب حوضه ها نخستین گام در استحصال این منابع و استفاده از پتانسیل موجود در حوزه های آبخیز است (Zoratipour et al., 2009).

در قرن اخیر پیش بینی دقیق رواناب یک چالش مهم برای متخصصین بوده است. برای اینکه بتوان تخمین های صحیحی از رواناب را به دست آورد، مدل های متعددی با روش های متنوع به کار گرفته شده است که در طول زمان این مدل ها نسخه های پیشرفته ای از خود به نمایش گذاشته اند. از این رو Raoof et al. (2024) از بارش حداکثر روزانه و توزیع آماری پیرسون تیپ ۳ با استفاده از نرم افزار EasyFit به عنوان ورودی در شبیه سازی هیدروگراف سیلاب برای دوره های بازگشت دو تا ۱۰۰ ساله استفاده نمودند و دبی حداکثر سیلاب شبیه سازی شده با دبی سیلاب مشاهداتی مورد مقایسه قرار گرفت. نتایج شبیه سازی هیدروگراف سیلاب آن ها نشان داد که با افزایش دوره بازگشت، حداکثر دبی با شیب بیش تری افزایش می یابد. اثر تغییر شماره منحنی روی دبی های حداکثر سیلاب در دوره بازگشت کم به مراتب بیش تر از دوره بازگشت زیاد است. Mirzaei et al. (2015) به شبیه سازی هیدروگراف سیلاب با استفاده از سیستم مدل سازی حوضه با بهره گیری از الگوی بارش بهینه پرداختند. بررسی دبی شبیه سازی شده با الگوهای متفاوت آن ها نشان داد الگوی بارش WMO با مدل بارش-رواناب SCS در برآورد حداکثر دبی لحظه ای، به عنوان مدل پیشنهادی برای حوضه آتشفشان استان اردبیل انتخاب شد. به دلیل وجود روابط پیچیده غیرخطی در تبدیل زمان بارش به رواناب، تحلیل بارش-رواناب بسیار مشکل است (Estaghmatashan and Normand, 2015).

در دهه های اخیر در بخش های مختلفی از جمله مدل سازی بارش-رواناب، روش های هوش مصنوعی کاربرد پیدا کرده اند. شبکه های عصبی مصنوعی^۱ (ANN) در موارد زیادی به ویژه

زمانی که روابط فیزیکی کاملاً شناخته شده نیست به کار گرفته می شود. این روش نیازی به دانستن فرآیند پدیده ندارد و زیرمجموعه روش های جعبه سیاه است و این روش در اصل یک مدل غیرخطی است و می تواند متغیرهای زمانی را نیز دخالت دهد (Nourani and Komasi, 2013).

شبکه عصبی مصنوعی روشی با قابلیت یادگیری، قابلیت فهم، تسلط بر روابط و مقاومت در برابر خطا است. امروزه روش های جعبه سیاه هوش مصنوعی به عنوان توابع خودساز و خودیادگیر، قابلیت وسیعی در مدل سازی و پیش بینی مسائل پیچیده دارند. در سال های اخیر مطالعاتی از موارد کاربرد روش شبکه عصبی مصنوعی در علوم و مهندسی آب صورت گرفته است.

به عنوان مثال، Dehghani et al. (2015) به شبیه سازی جریان روزانه در حوزه آبخیز کسلیان با استفاده از شبکه عصبی مصنوعی و شبکه عصبی-فازی تطبیقی پرداختند. پژوهش گران از آمار بارش، تبخیر و دما ایستگاه هواشناسی سنگده به عنوان ورودی این مدل ها و از آمار دبی ایستگاه ولیک بن که خروجی این مدل ها است طی سال های ۱۳۸۲ تا ۱۳۸۸ استفاده کردند. طبق نتایج این پژوهش می توان دریافت که شبکه عصبی-فازی تطبیقی با تابع عضویت زنگوله ای شکل و شعاع تأثیر ۰/۱۴ نسبت به مدل شبکه عصبی مصنوعی با همان ساختار با الگوریتم آموزشی لونیگ-مارکوارت، تابع انتقال سیگموئید و ۱۴ نرون در لایه مخفی در دوره آزمون، توانایی بهتری برای مدل سازی بارش-رواناب در حوزه آبخیز کسلیان را دارا بوده است.

در پژوهشی، Mirzania et al. (2021) فرآیند بارش-رواناب را در حوضه صوفی چای با استفاده از شبکه عصبی مصنوعی و هیبرید موج-شبکه عصبی مورد مطالعه قرار دادند. در طول دوره آماری (۱۳۹۸-۱۳۸۰) داده های بارش-رواناب برای آموزش و صحت سنجی مدل ها استفاده شد و برای هر مدل، شش سناریو به کار برده شد. در حالت کلی نتایج هر دو مدل گویای صحت کارکرد آن ها است. از لحاظ اولویت، نتایج نشان داد که روش شبکه عصبی مصنوعی در بهبود و پیش بینی بارش-رواناب مناسب تر است.

همچنین، Phuphong et al. (2013) به پیش بینی رواناب بر پایه شبکه عصبی مصنوعی در نبود داده های بارش پرداختند. نتایج آن ها نشان داد که ضریب همبستگی مقادیر مشاهداتی و محاسباتی سطح آب برای ایستگاه تاکینفائو بیش تر از ۰/۹۲ و جذر میانگین مربعات خطا ۱/۹۲ درصد میانگین سالانه سطح آب و برای ایستگاه بان موانگ کونگ نیز ضریب همبستگی بیش تر از ۰/۸۶ و جذر میانگین مربعات خطا ۶/۶۷ درصد میانگین سالیانه سطح آب بوده است. پژوهش گران اظهار داشتند

¹ Artificial Neural Networks

نتایج به‌دست آمده از این پژوهش در پیش‌بینی از صحت قابل‌قبولی برخوردار بوده است.

در پژوهشی، (Kashani et al. (2016 با استفاده از مدل خطی ولترا و مدل هوشمند شبکه عصبی به ارزیابی مدل‌سازی فرآیند غیرخطی بارش-رواناب پرداختند. داده‌های بارش و رواناب مربوط به ۱۵ رویداد از حوزه آبخیز ناورود واقع در شمال ایران جمع‌آوری شد و به‌ترتیب ۷۰ درصد و ۳۰ درصد رویدادها برای آموزش و تست مدل استفاده کردند. آن‌ها عملکرد مدل ولترا را با استفاده از پنج معیار عملکرد مختلف با مدل شبکه عصبی پرسپترون چند لایه مقایسه کردند. طبق نتایج آن‌ها مشخص شد که مدل هوشمند شبکه عصبی توانایی بالاتری نسبت به مدل ولترا در پیش‌بینی‌های رواناب حوزه آبخیز ناورود را دارا است. به‌طور کلی، برخلاف سایر مدل‌های خطی، مدل خطی ولترا در شبیه‌سازی فرآیند غیرخطی بارش-رواناب کارایی بالایی ندارد و نیاز به تعمیم مدل به مرتبه‌های بالاتر و کاهش تعداد پارامترهای قابل تخمین آن خواهد داشت.

هم‌چنین در پژوهشی، (Patel and Joshi et al. (2017 استفاده از شبکه عصبی مصنوعی به مدل‌سازی ضرایب بارش-رواناب در حوزه آبخیز داروی در هند پرداختند. با بررسی نتایج مشاهده شد مدل شبکه عصبی خطای بسیار پایینی داشته و برای شبیه‌سازی ضرایب بارش-رواناب در این حوضه پیشنهاد می‌شود. آن‌ها در پژوهش خود از داده‌های ۲۹ ساله بارش و رواناب استفاده نمودند که منجر به دستیابی به نتایج صحیح‌تری در این مطالعه شده است.

(Chanklan et al. (2018 با استفاده از ترکیب دو روش شبکه عصبی مصنوعی-رگرسیون ماشین بردار پشتیبان به مدل‌سازی بارش-رواناب پرداختند. نتایج آن‌ها نشان داد روش ترکیبی شبکه عصبی مصنوعی-رگرسیون ماشین بردار پشتیبان عملکرد بهتری در مقایسه بین رواناب واقعی و پیش‌بینی شده نسبت به روش‌های ماشین بردار پشتیبان و رگرسیون خطی داشت. در نهایت نتایج آن‌ها حاکی بر آن بود که مدل ترکیبی مورد نظر در پیش‌بینی مقادیر اوج رواناب در فصل بارش‌های شدید از صحت عملکرد بالایی برخوردار است.

با در نظر گرفتن ویژگی‌ها و توانایی‌های منحصر به فرد شبکه‌های عصبی مصنوعی در مطالعات انجام شده، این روش‌ها می‌توانند به‌عنوان روشی توانا و سودمند در مسائل مختلف مهندسی مانند مطالعات سیستم منابع آب به‌کار گرفته شوند. بنابراین با توجه به اهمیت پیش‌بینی مناسب جریان رودخانه و شبیه‌سازی فرآیند بارش-رواناب در مدیریت مخازن سدها، مقدار ورودی آب رودخانه به دریا یا دریاچه و موارد دیگری همچون کنترل سیلاب، در این پژوهش با بهره‌گیری از روش شبکه عصبی مصنوعی اقدام به پیش‌بینی جریان رودخانه و شبیه‌سازی فرآیند بارش-رواناب در سطح زیرحوضه سقز در استان کردستان از زیرحوضه‌های دریاچه ارومیه و در قالب سناریوهای مختلف پرداخته شد. در نتیجه، بارش به‌عنوان متغیر ورودی بالقوه انتخاب می‌شود و کفایت متغیرهای باقیمانده به‌طور جداگانه برای مدل شبکه عصبی آزمایش خواهد شد.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه


زیرحوضه سقز در استان کردستان واقع شده که جزئی از حوزه آبخیز دریاچه ارومیه است و شامل شهرستان سقز و مناطق اطراف آن است. منطقه مورد مطالعه مابین ۴۵ درجه و ۵۰ دقیقه تا ۴۷ درجه و ۲۳ دقیقه شرق طول جغرافیایی و ۳۵ درجه و ۴۳ دقیقه تا ۳۶ درجه و ۴۵ دقیقه شمال عرض جغرافیایی و در ارتفاع میانگین ۱۵۰۰ متری از سطح دریا قرار دارد (شکل ۱).

زیر حوضه سقز از نظر اقلیمی کوهستانی و سرد و جزء اقلیم مدیترانه‌ای محسوب می‌شود. هم‌چنین، به‌دلیل داشتن ارتفاع و عرض جغرافیایی بالا، دارای تابستان‌های معتدل و زمستان‌های بسیار سرد است. از نظر وزش باد جزء مناطقی است که باد همیشه در آن جریان داشته و بیش‌ترین وزش‌های باد در فصل‌های پاییز و بهار اتفاق می‌افتد و جهت آن بیش‌تر جنوب‌غرب و غرب است. زیرحوضه آبخیز سقز از نظر جغرافیایی در غرب ایران واقع شده است و شیب متوسط آن ۱۴/۵۸ درصد است. خصوصیات جغرافیایی و تقسیمات اقلیمی این منطقه به‌صورت خلاصه در جدول ۱ ارائه شده است.

جدول ۱- خصوصیات هیدرولوژیکی زیر حوضه و اقلیم منطقه مورد مطالعه سقز

Table 1. Hydrological characteristics of the Sub basin, and climate of the studied area of Saqqez

Variable	Value
Area (km ²)	453
Circumference (km)	120
Gravilius coefficient	1.59
Elongation coefficient	0.80
Average basin slope (%)	14.58
Main waterway slope (km)	79.20
Amberge coefficient	117.63
Regional climate type based on Amberge	Cold semi-arid climate
Regional prevailing wind direction	Southwest
Annual prevailing wind speed (m/s)	5.20



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه
Figure 1. Geographical location of the study area

انتخاب نوع شبکه اولین و مهم ترین قدم در شروع طراحی معماری شبکه می باشد. یک مدل شبکه عصبی مصنوعی با سه لایه معمولی، دارای یک ورودی، یک خروجی و یک لایه پنهان است (Li et al., 2021).

$$v_j = \sum_{i=1}^n \omega_{ji} x_i + b_j \quad (1)$$

$$y_i = \varphi(v_j) \quad (2)$$

v_j مقدار فعال سازی نرون، w_{ji} مقدار وزن سیناپسی، x مقدار ورودی، b_j مقدار bias در لایه پنهان، v_i نرون لایه خروجی و φ تابع فعال سازی است. آموزش شبکه عصبی مصنوعی در سه مرحله انجام می شود: (۱) کنترل الگوی آموزشی ورودی، (۲) محاسبه و انتشار مجدد خطای مربوطه و (۳) تنظیم وزن (Li et al., 2021).

پس از جمع آوری داده ها و بررسی صحت آن ها، اجرای ساختارهای مختلف شبکه عصبی مصنوعی به منظور مدل سازی بارش-رواناب در زیر حوضه سقز در نرم افزار NeuroSolutions (Ver.5) صورت گرفت. نرم افزار فوق از قابلیت نرمال سازی داده ها برخوردار است (Aksoy and Haralick, 2001). سپس، ۷۰ درصد داده ها برای آموزش شبکه و ۳۰ درصد باقی مانده برای آزمون شبکه به منظور اعتبارسنجی مدل در نظر گرفته شد. ترکیب مختلف شبکه عصبی مصنوعی با تعداد لایه ها و نرون های متفاوت با یکدیگر مقایسه شدند و بر مبنای معیارهای ارزیابی خطا، شبکه عصبی مصنوعی با بهترین معماری انتخاب شد.

۲-۲- داده های مورد نیاز

در این مطالعه از داده های روزانه ۱۸ ساله (۱۳۹۷-۱۳۸۰) هواشناسی و هیدرومتری ایستگاه قباغلو که از سازمان هواشناسی و شرکت آب منطقه ای استان کردستان اخذ شده، استفاده شد. پارامترهای هواشناسی و هیدرومتری استفاده شده در این پژوهش شامل بارش، تبخیر، میانگین دما، بیشینه و کمینه دما و دبی متوسط در مقیاس روزانه است (جدول ۲).

جدول ۲- خلاصه آماری داده های مشاهداتی

Table 2. Statistical summary of the observational data

Parameters used	Statistical parameters (daily)			
	Average	Maximum	Minimum	Standard Deviation
Rainfall (mm)	1.40	81.00	0.00	4.70
Discharge (m ³ /s)	8.50	243.00	0.00	15.40
Evaporation (mm)	6.20	22.40	0.00	3.50
Average temperature (°C)	13.30	34.70	1.30	4.20
Maximum temperature (°C)	18.90	40.30	-8.10	11.70
Minimum temperature (°C)	5.60	33.90	-20.40	8.60

۲-۳- روش شبکه عصبی مصنوعی

روش شبکه عصبی مصنوعی، یک روش محاسباتی از سیستم های عصبی است. این مدل ها که با الهام گرفتن از طرز کار مغز بشر ساخته شده اند، قابلیت یادگیری، فراخوانی و تعمیم یافتن از الگوهای یادگیری یا داده ها را دارا می باشند (Nozari and Azadi, 2017). شبکه عصبی مصنوعی یک مدل ریاضی خطی است که می تواند فرآیندهای غیرخطی دلخواه را شبیه سازی کرده و همچنین، ورودی ها و خروجی های هر سیستم را به هم مرتبط سازد (Parsaie et al., 2019).

$$R = \frac{\sum_{i=1}^N (X_{oi} - \bar{X}_{oi})(X_{pi} - \bar{X}_{pi})}{\sqrt{\sum_{i=1}^N (X_{oi} - \bar{X}_{oi})^2 \cdot \sum_{i=1}^N (X_{pi} - \bar{X}_{pi})^2}} \quad (5)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (X_{oi} - X_{pi})^2}{\sum_{i=1}^N (X_{oi} - \bar{X}_{oi})^2} \right] \quad (6)$$

در این روابط، N تعداد روزهای دوره مورد مطالعه X_{pi} مقادیر اندازه‌گیری شده دبی خروجی، X_{oi} مقادیر پیش‌بینی شده دبی خروجی با استفاده از مدل، $\bar{X}_{pi}$ میانگین داده‌های اندازه‌گیری شده دبی خروجی و $\bar{X}_{oi}$ میانگین داده‌های پیش‌بینی شده دبی خروجی در هر روز می‌باشد.

۳- نتایج و بحث

۳-۱- یافته‌های مدل‌سازی با شبکه عصبی مصنوعی

براساس تحلیل سناریوها

نتایج مدل به‌منظور شبیه‌سازی بارش-رواناب با استفاده از مدل شبکه عصبی مصنوعی، در شش سناریو اجرا شده به‌صورت زیر است:

الف- نتایج سناریو اول

در این سناریو متغیر ورودی بارش و متغیر خروجی دبی متوسط روزانه در نظر گرفته شده است. برای ارزیابی صحت عملکرد مدل شبکه عصبی مصنوعی در جدول ۳ شاخص‌های آماری RMSE، NSE، MAE و R در بخش آموزش و آزمون محاسبه است. مقادیر NSE در بازه [منفی بی نهایت و ۱] بوده و هر چقدر مقدار این پارامتر به یک نزدیک‌تر باشد، نشان‌دهنده تطابق خوب بین مقادیر مشاهداتی و شبیه‌سازی شده است. همچنین، ضریب همبستگی مشخص‌کننده مقدار تطابق داده‌های مشاهداتی با نتایج پیش‌بینی شده است. لذا با توجه به جدول ۳ و براساس نتایج شاخص‌های آماری می‌توان گفت شاخص‌های خطاسنجی در بخش آموزش و آزمون نتیجه مطلوبی برای پیش‌بینی مقدار دبی در این سناریو نشان نمی‌دهد.

جدول ۳- نتایج شاخص‌های آماری برای سناریو ۱

Table 3. Results of the statistical indicators for scenario 1

Evaluation criteria	Stage	Calculated values
R	Training	0.29
	Testing	0.35
RMSE	Training	15.73
	Testing	11.82
NSE	Training	0.09
	Testing	0.10
MAE	Training	9.97
	Testing	8.54

در شکل ۲ نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و

پس از تعیین تعداد لایه و تعداد نرون‌های بهینه هر لایه، از توابع انتقالی و الگوریتم‌های یادگیری مختلفی برای معماری شبکه استفاده شد. پس از طراحی شبکه، تعداد تکرارهای متفاوت جهت انتخاب بهترین تعداد تکرار مورد آزمون قرار گرفت. پس از اینکه اجزای مناسب شبکه انتخاب شد، از داده‌های آزمون برای ارزیابی صحت پیش‌بینی و اعتبارسنجی مدل پیشنهادی استفاده شد. لازم به ذکر است پارامترهای ورودی و خروجی با توجه به سناریوهای تعریف شده انتخاب شدند.

۴-۲- معرفی سناریوهای اجرا شده

با هدف شبیه‌سازی بارش-رواناب و با استفاده از روش شبکه عصبی مصنوعی، از شش سناریو با متغیرهای ورودی مختلف جهت ارزیابی عملکرد مدل استفاده شد. اولین گام تعیین پارامترهای ورودی مناسب است. متغیر ورودی در سناریوی اول، بارش و در سناریوی دوم، بارش و تبخیر بوده است. در سناریوی سوم، متغیرهای ورودی بارش و دمای میانگین، و در سناریوی چهارم، شامل بارش و متغیر دبی با یک روز تأخیر بوده است. در سناریوی پنجم، متغیرهای ورودی شامل بارش، دمای میانگین، بیشینه دما و کمینه و نهایتاً در سناریوی ششم، متغیرهای ورودی بارش، تبخیر، دمای میانگین، دمای بیشینه و کمینه بوده است. متغیر خروجی در شش سناریوی ذکر شده، پارامتر دبی متوسط روزانه بوده و ورودی در یک روز مشخص منجر به دبی خروجی متناظر آن شده و شبیه‌سازی مطابق با آن صورت گرفته است.

۵-۲- اعتبارسنجی مدل

جهت ارزیابی و اعتبارسنجی نتایج مدل شبیه‌سازی شده، شاخص‌های آماری ریشه میانگین مربعات خطا^۱ (RMSE)، خطای مطلق میانگین^۲ (MAE)، ضریب همبستگی^۳ (R) و ضریب نش-ساتکلیف^۴ (NSE) در نظر گرفته شده است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_{pi} - X_{oi})^2} \quad (3)$$

$$MAE = \left| \sum_{i=1}^N \frac{X_{pi} - X_{oi}}{N} \right| \quad (4)$$

¹ Root Mean Square Error


² Mean Absolute Error

³ Correlation Coefficient

⁴ Nash-Sutcliffe Efficiency

زیادی برخوردار بوده و نتایج تغییرات سری زمانی دبی شبیه‌سازی شده، تطابق نسبتاً ضعیفی با مقادیر مشاهداتی دارد.

آزمون در سناریو ۱ نشان داده شده است. این شکل نشان‌دهنده این واقعیت است که مقادیر مشاهداتی و شبیه‌سازی شده دبی در سناریو اول از صحت کم و مقدار خطای



شکل ۲- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۱
Figure 2. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 1

جدول ۴- نتایج شاخص‌های آماری برای سناریو ۲


Table 4. Results of the statistical indicators for scenario 2

Evaluation criteria	Stage	Calculated values
R	Training	0.40
	Testing	0.45
RMSE	Training	15.05
	Testing	11.32
NSE	Training	0.16
	Testing	0.17
MAE	Training	9.06
	Testing	7.73

در شکل ۳ نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون در سناریو دوم نشان داده شده است. با توجه به این شکل داده‌های مدل‌سازی شده فاصله زیادی با مقادیر مشاهداتی دارند که طبق تعریف نمودار سری زمانی مشخص می‌گردد نتایج قابل‌قبولی محاسبه نشده است.

ب- نتایج سناریو دوم

در سناریو دوم متغیرهای ورودی شامل بارش و تبخیر و متغیر خروجی دبی متوسط روزانه است. طبق جدول ۴ نتایج به‌دست آمده نشان می‌دهد که در بخش آموزش مقادیر شاخص‌های آماری R، RMSE، NSE و MAE به ترتیب ۰/۴۰، ۱۵/۰۵، ۰/۱۶ و ۹/۰۶ است و در بخش آزمون هم به ترتیب برابر با ۰/۴۵، ۱۱/۳۳، ۰/۱۷ و ۷/۷۳ برای سناریو دو به‌دست آمده است که بیانگر نتیجه قابل‌قبولی نیست.




شکل ۳- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۲
Figure 3. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 2

جدول ۵- نتایج شاخص‌های آماری برای سناریو ۳

Table 5. Results of the statistical indicators for scenario 3		
Evaluation criteria	Stage	Calculated values
R	Training	0.35
	Testing	0.43
RMSE	Training	15.40
	Testing	11.42
NSE	Training	0.12
	Testing	0.16
MAE	Training	9.45
	Testing	7.68

در شکل ۴ نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون در سناریو سوم نشان داده شده است. لذا سناریو سوم که متغیرهای ورودی آن بارش و دمای میانگین بود نیز برای مدل‌سازی در این منطقه مناسب نیست.



شکل ۴- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۳
Figure 4. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 3


پ- نتایج سناریو سوم

در سناریو سوم متغیرهای ورودی بارش و دمای میانگین و متغیر خروجی دبی متوسط روزانه است. مقدار دبی مدل‌سازی شده با مقدار واقعی دبی مورد مقایسه قرار گرفت. با توجه به نتایج مقادیر R ، $RMSE$ ، NSE و MAE در بخش آموزش به‌ترتیب برابر با ۰/۳۵، ۱۵/۴۰، ۰/۱۲ و ۹/۴۵ و در بخش آزمون نیز به‌ترتیب برابر با ۰/۴۳، ۱۱/۴۲، ۰/۱۶ و ۷/۶۸ به‌دست آمد (جدول ۵). لذا طبق تعاریف معیارهای ارزیابی، این مقادیر نمی‌توانند برای شبیه‌سازی یک مدل نتایج قابل‌قبولی باشند.

جدول ۶- نتایج شاخص‌های آماری برای سناریو ۴

Table 6. Results of the statistical indicators for scenario 4		
Evaluation criteria	Stage	Calculated values
R	Training	0.92
	Testing	0.91
RMSE	Training	6.65
	Testing	5.34
NSE	Training	0.84
	Testing	0.82
MAE	Training	2.04
	Testing	1.57

در شکل ۵ نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون در مدل شبکه عصبی مصنوعی برای سناریو چهارم نشان داده شده است. با توجه به این شکل مقدار دبی شبیه‌سازی شده در مقایسه با مقدار مشاهداتی از تطابق مناسب و مقدار خطای قابل قبولی برخوردار است. (Shahani et al. (2023 پژوهشی را در منطقه کشف‌رود واقع در استان خراسان جنوبی با مدل‌های شبکه عصبی مصنوعی و یادگیری عمیق جهت برآورد بارش-رواناب انجام دادند. بدین منظور عملکرد دو مدل در مدل‌سازی بارش-رواناب با ورودی‌های بارش و دبی روزانه با تأخیرهای مختلف مقایسه شد. یافته‌های پژوهش نشان داد در سناریو تعریف شده با ورودی بارندگی با تأخیر صفر تا دو و دبی رودخانه با تأخیر یک، نتایج قابل قبولی با مدل شبکه عصبی مصنوعی به دست آمده است. لذا آن‌ها اظهار داشتند که نتایج به دست آمده، نسبت به نتایج سایر سناریوهای تعریف شده صحیح‌تر است.



شکل ۵- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۴

Figure 5. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 4

ت- نتایج سناریو چهارم


در سناریو چهارم متغیرهای ورودی بارش و متغیر دبی با یک روز تأخیر و متغیر خروجی دبی متوسط روزانه است. از نتایجی که در جدول ۶ به دست آمده است مقادیر معیارهای ارزیابی R، RMSE، NSE و MAE برای بخش آموزش به ترتیب برابر با ۰/۹۲، ۶/۶۵، ۰/۸۴ و ۲/۰۴ و برای بخش آزمون به ترتیب برابر با ۰/۹۱، ۵/۳۴، ۰/۸۲ و ۱/۵۷ را نشان می‌دهد. طبق نتایج معیارهای ارزیابی، می‌توان گفت که این سناریو از صحت قابل قبولی برخوردار است.

طبق نتایج این جدول مقادیرهای NSE در بخش آموزش و آزمون به یک نزدیک‌تر بوده که نشان‌دهنده تطابق خوب بین مقادیر مشاهداتی و شبیه‌سازی شده است. همچنین، ضریب همبستگی مشخص‌کننده مقدار تطابق بین داده‌های مشاهداتی با نتایج پیش‌بینی شده است، که می‌توان گفت شاخص‌های خطاسنجی در بخش آموزش و آزمون نتیجه مطلوبی برای پیش‌بینی مقدار دبی در این سناریو را نشان می‌دهد.

جدول ۷- نتایج شاخص‌های آماری برای سناریو ۵

Table 7. Results of the statistical indicators for scenario 5		
Evaluation criteria	Stage	Calculated values
R	Training	0.47
	Testing	0.49
RMSE	Training	14.48
	Testing	11.12
NSE	Training	0.22
	Testing	0.20
MAE	Training	8.26
	Testing	6.57

در شکل ۶ نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون نشان داده شده است. با توجه به این شکل، داده‌های مدل‌سازی شده فاصله زیادی با مقادیر مشاهداتی دارند و نشان می‌دهد در این سناریو نتایج قابل‌قبولی به‌دست نیامده است و ترکیب متغیر بارش با دمای میانگین، بیشینه و کمینه برای پیش‌بینی مقدار دبی در این منطقه مناسب نیست.



شکل ۶- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۵
Figure 6. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 5

جدول ۸- نتایج شاخص‌های آماری برای سناریو ۶

Table 8. Results of the statistical indicators for scenario 6		
Evaluation criteria	Stage	Calculated values
R	Training	0.52
	Testing	0.53
RMSE	Training	14.09
	Testing	10.80
NSE	Training	0.27
	Testing	0.25
MAE	Training	7.93
	Testing	6.33


در شکل ۷ نیز نتایج تغییرات سری زمانی مقادیر دبی متوسط روزانه مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون در سناریو ششم نشان داده شده است که

ج- نتایج سناریو ششم

در سناریو ششم نتایج میزان تأثیر متغیرهای بارش، تبخیر، دمای میانگین و بیشینه و کمینه دما برای پیش‌بینی مقدار متغیر خروجی دبی متوسط روزانه مورد بحث قرار گرفت. طبق جدول ۸ نتایج به‌دست آمده نشان می‌دهد که در بخش آموزش مقادیر شاخص‌های آماری R، RMSE، NSE و MAE در قسمت آموزش به‌ترتیب ۰/۵۲، ۱۴/۰۹، ۰/۲۷ و ۷/۹۳ و در بخش آزمون هم به‌ترتیب برابر با ۰/۵۳، ۱۰/۸۰، ۰/۲۵ و ۶/۳۳ به‌دست آمده است که بیانگر نتیجه قابل‌قبولی نیست.

مورد مطالعه است.

نشان‌دهنده عدم توانایی این سناریو جهت مدل‌سازی در منطقه



شکل ۷- تغییرات سری زمانی مقادیر دبی مشاهداتی در برابر مقادیر شبیه‌سازی شده در مرحله آموزش و آزمون سناریو ۶
Figure 7. Changes in the time series of the observed discharge values against the simulated values in the stages of training and testing scenario 6

۴- نتیجه‌گیری

در دهه‌های اخیر همواره بررسی صحیح و مدل‌سازی بارش-رواناب در مدیریت منابع آب در داخل و خارج کشور حائز اهمیت بوده است. در این پژوهش با استفاده از مدل شبکه عصبی مصنوعی، دبی در زیر حوضه سقز واقع در حوزه آبخیز دریاچه ارومیه مورد بررسی قرار گرفت. دوره آماری داده‌ها ۱۸ سال در مقیاس روزانه بود که اطلاعات مربوط به دبی از ایستگاه قباغلو اخذ شد. داده‌های هواشناسی شامل پارامترهای بارش، تبخیر، دمای میانگین، بیشینه و کمینه دما است. در این میان، جهت ارزیابی صحیح مدل شبکه عصبی مصنوعی، شش سناریو مختلف توسعه داد شد و سپس میزان عملکرد مدل شبکه عصبی مصنوعی در برآورد مدل‌سازی بارش-رواناب مورد بررسی قرار گرفت.

در نهایت طبق نتایج به‌دست آمده از بین شش سناریو توسعه داده شده، عملکرد مدل شبکه عصبی مصنوعی در سناریو چهارم با ورودی‌های بارش و دبی همراه با یک روز تأخیر، به‌عنوان بهترین ترکیب انتخاب شد. در این سناریو، شاخص‌های آماری نشان‌دهنده تطابق بسیار خوبی بین مقادیر مشاهداتی و شبیه‌سازی شده دبی متوسط روزانه نسبت به سایر سناریوها است. نتایج به‌دست آمده نشان داد که برای زیر حوضه سقز، الگوریتم مدل شبکه عصبی مصنوعی، نتایج مناسب و قابل‌قبولی حاصل شده است. پس می‌توان گفت مدل‌سازی مدل شبکه عصبی مصنوعی دارای عملکرد صحیح‌تر و خطای کم برای منطقه مطالعاتی است.

با توجه به شش سناریوی مدل‌سازی شده و نتایج به‌دست آمده، توانایی مدل شبکه عصبی مصنوعی در سناریوی شماره چهار با ورودی‌های بارش و دبی با یک واحد زمانی تأخیر با توجه به معیارهای ارزیابی R ، $RMSE$ ، NSE و MAE در بخش آموزش به‌ترتیب 0.92 ، $6/65$ ، 0.84 و $2/04$ حاصل شد و در بخش آزمون نیز به‌ترتیب 0.91 ، $5/34$ ، 0.82 و $1/57$ به‌دست آمد. لذا سناریو چهار بهترین سناریو با دو لایه پنهان و تعداد نرون ۱۰ با الگوریتم یادگیری لونیگ مارکوئت و تابع انتقال تانژانت در لایه اول و پورلاین در لایه دوم، به‌عنوان بهترین معماری شبکه برای قسمت آموزش و آزمون در این پژوهش انتخاب و برترین ترکیب برای مدل‌سازی بارش-رواناب در زیر حوضه سقز انتخاب شد. همچنین، سناریوی اول که متغیر ورودی آن بارش بود، با توجه به مقادیر معیارهای ارزیابی فوق به‌ترتیب برابر با 0.29 ، $15/73$ ، 0.09 و $9/97$ در بخش آموزش و 0.35 ، $11/82$ ، 0.10 و $8/54$ در بخش آزمون، بیش‌ترین خطا را نسبت به سایر سناریوها برای زیر حوضه سقز از خود نشان داد. ارجاع به پژوهش، (Mirzania et al. (2021) فرایند بارش-رواناب در حوضه صوفی چای با استفاده از شبکه عصبی مصنوعی و هیبرید موجک-شبکه عصبی مورد مطالعه قرار دادند. در طول دوره آماری (۱۳۸۰-۱۳۹۸) داده‌های بارش-رواناب برای آموزش و صحت‌سنجی مدل‌ها استفاده شد و برای هر مدل شش سناریو به‌کار برده شد. در حالت کلی نتایج هر دو مدل گویای صحت قابل‌قبولی بود. از لحاظ اولویت، نتایج نشان داد، روش شبکه عصبی مصنوعی در بهبود و پیش‌بینی بارش-رواناب در سناریوهای تعریف شده عملکرد مناسب‌تری دارد.

سپاسگزاری

از همکاری و مساعدت سازمان هواشناسی و شرکت آب منطقه‌ای استان کردستان در انجام مراحل مختلف پژوهش از جمله در اختیار قرار دادن داده‌ها و از دانشگاه ملایر جهت حمایت معنوی از این پژوهش قدردانی می‌شود.

تضاد منافع نویسندگان

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

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

مشارکت نویسندگان

سعید آزادی: نگارش نسخه اولیه مقاله، ویرایش و بازبینی مقاله، بازبینی متن مقاله؛ **امین ترنجیان:** مفهوم‌سازی، راهنمایی و مشاوره، کنترل نتایج؛ **سامان مصطفایی:** انجام تحلیل‌های نرم‌افزاری/آماري، تحلیل‌های آماری.

منابع

استقامت اشان، پریسا، و نورمند، بهرزا (۱۳۹۵). مدل بارش-رواناب حوضه آبریز صوفی چای با استفاده از شبکه عصبی مصنوعی. *همایش سراسری فناوری و تکنولوژی در مهندسی عمران، برق و مکانیک*. <https://elmnet.ir/doc/20634488-9191>
دهقانی، نوید، وفاخواه، مهدی، و بهره‌مند، عبدالرضا (۱۳۹۵). مدل‌سازی بارش-رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی-عصبی تطبیقی در حوزه آبخیز کسلیان. *پروژه‌نامه مدیریت حوزه آبخیز*، ۷ (۱۳)، ۱۳۳ - ۱۲۸.
doi: 10.18869/acadpub.jwmr.7.13.137

رئوف، مجید، کاظمی، ژیللا، مصطفی‌زاده، رئوف، حسینی، یاسر و میرزایی، سجاد (۱۴۰۳). اثر تغییر شماره منحنی روی هیدروگراف سیلاب در یک حوزه آبخیز عکس‌العمل سریع (مطالعه موردی: حوزه آبخیز خیابوچای اردبیل). *مدل‌سازی و مدیریت آب و خاک*، ۴(۱)، ۲۶۱-۲۴۸.

doi: 10.22098/mmws.2023.12295.1221

ذرتی‌پور، امین، سلاجقه، علی، المعالی، نگار، و عسکری، حسین محمد (۱۳۸۸). بررسی مدل بارش-رواناب با استفاده از روش‌های شبکه عصبی مصنوعی و رگرسیون دو متغیره آماری (مطالعه موردی در حوزه آبخیز میناب). *پژوهش‌های آبخیزداری*، ۲۲ (۲)، ۸۳-۶۹.
<https://www.magiran.com/p1059321>

سلگی، اباذر، زارعی، حیدر، پورحقی، امیر، و خدابخشی، حمیدرضا (۱۳۹۵). پیش‌بینی بارش ماهانه با مدل ترکیبی شبکه عصبی مصنوعی-موجک و مقایسه با مدل شبکه عصبی مصنوعی. *آبیار و آب ایران*، ۶ (۲۳)، ۳۳-۱۸.

https://www.waterjournal.ir/article_73948.html

شاهانی، محمدحسین، رضавردی‌نژاد، وحید، و حسینی، سیدعباس (۱۴۰۲). مقایسه مدل‌های شبکه عصبی مصنوعی و یادگیری عمیق در مدل‌سازی بارش-رواناب رودخانه کشف‌رود و پیش‌بینی اثر تغییر اقلیم بر پارامترهای هواشناسی و دبی رودخانه. *سد و نیروگاه برق آبی ایران*، ۱۰ (۳۳)، ۹۷-۸۳.
doi: 10.1001.1.23225882.1402.0.0.6.7

میرزانی، احسان، ملک‌احمدی، حسین، شاه‌محمدی، یادگار، و ابراهیم‌زاده، علی (۱۴۰۰). تأثیر موجک بر افزایش دقت مدل‌های تضمینی در مدل‌سازی بارش-رواناب (مطالعه موردی: حوضه صوفی‌چای). *مدل‌سازی و مدیریت آب و خاک*، ۱ (۳)، ۷۹-۶۷.
doi: 10.22098/MMWS.2021.9335.1035

میرزایی، سجاد، رئوف، مجید، رسول‌زاده، علی، و پوراسکندر، ساناز (۱۳۹۴). شبیه‌سازی هیدروگراف سیلاب رودخانه حوضه آتشیگاه استان اردبیل با بهره‌گیری از الگوی بارش بهینه. *پژوهش‌های حفاظت از خاک و آب*، ۲۲ (۵)، ۸۰-۶۳.
doi: 10.1001.1.23222069.1394.22.5.4.4

References

Aksoy, S., & Haralick, M. (2001). Feature normalization and likelihood-based similarity measures for image retrieval. *Journal Pattern Recognition Letters*, 22(5), 563-582. doi: 10.1016/S0167-8655(00)00112-4
Chanklan, R., Kaoungku, N., Suksut, K., Kerdprasop, K., & Kerdprasop, N. (2018). Runoff prediction with a combined artificial neural network and support vector regression. *International Journal of Machine Learning and Computing*, 8(1), 39-43. doi: 10.18178/ijmlc.2018.8.1.660.
Dehghani, N., Vafakhah, M., & Bahremand, A.A. (2015). Rainfall-Runoff Modeling using Artificial Neural Network and Neuro-Fuzzy Inference System in Kasilian Watershed. *Journal of Watershed Management Research*. 7

doi: 128-137.
10.18869/acadpub.jwmr.7.13.137 [In Persian]
Estaghmateshan, P., & Normand, B. (2015). Rainfall-runoff model of Sufi Chai watershed using artificial neural network. *National Conference of Technology in Civil, Electrical and Mechanical Engineering*. <https://elmnet.ir/doc/20634488-9191> [In Persian]
Kashani, M. H., Ghorbani, M.A., Dinpashoh, Y., & Shahmorad, S. (2016). Integration of volterra model with artificial neural networks for rainfallrunoff simulation in forested catchment of northern Iran. *Journal of Hydrology*, 540, 340-354. doi: 10.1016/j.jhydrol.2016.06.028
Li, S., Yang, J., & Ansell, A. (2021). Discharge prediction for rectangular sharp-crested weirs by machine learning techniques. *Flow*

- Measurement and Instrumentation*, 79, 101931. doi: 10.1016/j.flowmeasinst.2021.101931 [In Persian]
- Mirzaei, S., Raoof, M., Rasoulzadeh, A., & Poreskandar, S. (2015). Simulation Flood Hydrograph of Atashgah Basin River of Ardabil Province using optimized Rainfall Pattern. *Journal of Soil and Water Conservation Research*, 22(5), 63-80. doi: 20.1001.1.23222069.1394.22.5.4.4 [In Persian]
- Mirzania, A., Malek Ahmadi, H., Shahmohammadi, Y., & Ebrahim Zadeh, A. (2021). Impact of wavelet on accuracy of estimated models in rainfall-runoff modeling (Case study: Sufi Chay). *Soil and Water Modeling and Management*, 1 (3), 67-79. doi: 10.22098/MMWS.2021.9335.1035 [In Persian]
- Nourani, V., & Komasi, M.A. (2013). Geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology*, 490, 41-55. doi: 10.1016/j.jhydrol.2013.03.024
- Nozari, H., & Azadi, S. (2017). Experimental evaluation of artificial neural network for predicting drainage water and groundwater salinity at various drain depths and spacing. *Journal of Neural Comput & Applic*, 31, 1227-1236. doi: 10.1007/s00521-017-3155-9
- Parsaie, A., Haghiabi, A. H., Emamgholizadeh, S., & Azamathulla, H.M. (2019). Prediction of discharge coefficient of combined weir-gate using ANN, ANFIS and SVM. *International Journal of Hydrology Science and Technology*, 9(4), 412. doi:10.1504/ijhst.2019.102422
- Patel, A. B., & Joshi, G.S. (2017). Modeling of rainfall-runoff correlations using artificial neural network-a case study of Dharoi Watershed of a Sabarmati River Basin, India *Journal Civil Engineering*, 3(2), 78-87. doi: 10.28991/cej-2017-00000074
- Phuphong, S., Surussavadee, C., & Member, S. (2013). An artificial neural network based runoff forecasting model in the absence of precipitation data: a case study of Khlong U-Tapao river basin, Songkhla Province, Thailand. *4th International Conference on Intelligent Systems, Modelling and Simulation*. Pp: 73-77, doi: 10.1109/ISMS.2013.51
- Raoof, M., Kazemi, J., Mostafazadeh, R., Hoseini, Y., & Mirzaei, S. (2024). Effect of curve number changes on flood hydrograph in a rapid response watershed (Case study: Ardabil Khiavchai Watershed). *Water and Soil Management and Modelling*, 4(1), 248-261. doi: 10.22098/mmws.2023.12295.1221 [In Persian]
- Shahani, M.H., Rezavardinejad, V., & Hosseini, S.A. (2023). Comparison of artificial neural network and deep learning models in rainfall-runoff modeling of Kashafrud river and predicting climate change impact on meteorological parameters and river flow. *Scientific Journal of Iranian Hydroelectric Dam and Power Plant*, 10(33), 2023, dor: 20.1001.1.23225882.1402.0.0.6.7 [In Persian]
- Solgi, A., Zarei, H., Pourhaghi, A., & Khodabakhshi, H.R. (2015). Forecasting Monthly Precipitation Using a Hybrid Model of Wavelet Artificial Neural Network and Comparison with Artificial Neural Network. *Journal of Irrigation and Water Engineering*, 6(23), 18-33, https://www.waterjournal.ir/article_73948.html [In Persian]
- Zorati pour, A., Salageghe, A., Almaali, N., & Askari, H. (2009). The assessment of precipitation-runoff model by using of artificial neural network and regression methods (Case study: Minab Basin). *Watershed Management Research*, 22 (2), 69-83. <https://www.magiran.com/p1059321> [In Persian]