

(OPEN ACCESS)

Evaluation of Diverse Modeling Approaches for Rainfall–Runoff Processes in Semi-Arid Regions of Iran

Akram Heydari¹, Nader Jandaghi^{*2}, Mojtaba Ghareh Mahmoodlu³,
Majid Azimmohseni⁴

1. M.Sc. Student in Watershed Sciences and Engineering, Dept. of Rangeland and Watershed Management, Faculty of Agriculture and Natural Resources, Gonbad Kavous University, Gonbad Kavous, Iran. E-mail: akramheydari2912@gmail.com
2. Corresponding Author, Associate Prof. in Engineering Hydrology, Dept. of Rangeland and Watershed Management, Faculty of Agriculture and Natural Resources, Gonbad Kavous University, Gonbad Kavous, Iran. E-mail: nader.jandaghi@gmail.com
3. Associate Prof. in Environmental Hydrogeology, Dept. of Rangeland and Watershed Management, Faculty of Agriculture and Natural Resources, Gonbad Kavous University, Gonbad Kavous, Iran. E-mail: mmahmoodlu@yahoo.com
4. Associate Prof. in Statistics, Dept. of Statistics, Faculty of Science, Golestan University, Iran. E-mail: m.azim@gu.ac.ir

Article Info

Article type:
Research Full Paper

Article history:
Received: 07.05.2025
Revised: 09.30.2025
Accepted: 10.25.2025

Keywords:
Artificial Intelligence,
Khorasan Razavi Province,
Quantile Regression,
Rainfall-Runoff Modeling,
Transfer Function

ABSTRACT

Background and Objectives: The relationship between rainfall and runoff is a fundamental concept in hydrology, reflecting complex processes such as infiltration, evapotranspiration, and water exchange between surface and subsurface flows that ultimately lead to runoff generation. In arid and semi-arid regions, irregular and intense rainfall events, coupled with limited hydrometric data and the intricate structure of watersheds, pose significant challenges for water resources management. Rivers, as vital components of the hydrological cycle, play a crucial role in water supply, aquifer recharge, and ecosystem sustainability, and are highly sensitive to variations in precipitation. Advanced runoff modeling, particularly through data-driven approaches such as machine learning and deep learning, has enabled the identification of nonlinear patterns and the accurate prediction of hydrological events, providing valuable tools for informed decision-making in sustainable water resources management. Accordingly, the primary objective of this study is to evaluate and compare the performance of statistical and data-driven models, including Quantile Regression (QR), Multi-Layer Perceptron (MLP), Adaptive Neuro-Fuzzy Inference System (ANFIS), and Transfer Function (TF), in simulating the rainfall–runoff process in the semi-arid regions of Iran.

Materials and Methods: In the present study, monthly data from hydrometric and meteorological stations in three watersheds, Zoshk, Dehbar, and Kardeh, located in Khorasan Razavi Province, were used to model the rainfall–runoff process over 26 years (1997–2022). As an initial step, the Chow method was employed to assess the accuracy and homogeneity of the time series data. Given the temporal dependency of monthly rainfall and runoff data, the data were structured as a time series for further analysis. To simulate and forecast monthly runoff for the next 12 months based on rainfall data, four models were utilized: multilayer perceptron (MLP) neural network, adaptive neuro-fuzzy inference system

(ANFIS), transfer function (TF), and quantile regression (QR). Considering that more recent years provide more accurate insights into current conditions, a forward selection approach was adopted to determine the effective number of years for modeling. Among the available years, all but one were used for model training, and the remaining year was reserved for validation. The performance of the calibrated models was evaluated using three standard metrics: mean absolute error (MAE), root mean square error (RMSE), and the coefficient of determination (R^2). It is noteworthy that statistical analyses and computations in this study were performed using R software (quantreg and frbs packages), SAS, MINITAB, and SPSS.

Results: The analysis of the monthly trend of rainfall and runoff time series in the three studied watersheds revealed that these basins exhibit distinct structural characteristics. Cross-correlation analysis indicates the presence of a lagged relationship between rainfall and runoff time series in the three selected watersheds. Specifically, the direct effect of precipitation on runoff was observed with a maximum lag of one month in the Zoshk and Dehbar watersheds, while in the Kardeh watershed—due to its mountainous conditions and the higher contribution of snow in the precipitation regime—a maximum lag of three months was identified. The effective number of years for modeling, determined through a forward selection process, was found to be 17, 19, and 9 years for the Zoshk, Dehbar, and Kardeh watersheds, respectively, providing optimal model performance. The validation results of the models using MAD, RMSE, and R^2 indices indicate that the MLP model provides the most accurate estimation of monthly runoff in the Zoshk, Dehbar, and Kardeh watersheds (RMSE = 0.0032, 0.0028, and 0.0123 m³/s, respectively) compared to the other models. Following MLP, the ANFIS model ranked second in performance (RMSE = 0.0146, 0.0044, and 0.0186 m³/s, respectively). The validation results further revealed considerable similarity between the simulation outputs of the MLP and ANFIS models. After these two models, the quantile regression approach exhibited the next highest accuracy in the Zoshk, Dehbar, and Kardeh watersheds (RMSE = 0.0344, 0.0293, and 0.0444 m³/s, respectively). The transfer function model also provided relatively satisfactory results in identifying trends and evaluating prediction accuracy; however, it exhibited the weakest performance among the four models in the Zoshk, Dehbar, and Kardeh watersheds (RMSE = 0.0344, 0.0378, and 0.0510 m³/s, respectively). Validation results also indicated notable similarities between the simulation outputs of the TF and QR models. Based on the coefficient of determination for the models, it can be concluded that a substantial proportion of the variance in the dependent variable was adequately explained by the independent variables. Therefore, all four models demonstrated acceptable levels of predictive accuracy.

Conclusion: The results of this study indicated that the four models employed, including MLP, ANFIS, QR, and TF, despite differences in accuracy, demonstrated satisfactory performance in identifying patterns and modeling variations in output time series based on input data. Accordingly, these models can be considered efficient and effective tools for predicting monthly runoff based on precipitation in the study area. No evidence of persistent overfitting or underfitting, which could reduce the models' accuracy and efficiency, was observed in any of the approaches. Nevertheless, a comparison of the evaluation metrics indicated that, in terms of predictive accuracy, the models ranked in the following order:

MLP, ANFIS, QR, and TF. Given the high variability of precipitation in Khorasan Razavi Province, it was initially expected that the QR model, designed to handle extreme values differently from average values, would achieve superior accuracy. However, its performance was noticeably lower than that of the MLP and ANFIS models. Although the TF model demonstrated lower accuracy compared to the other models, it played a significant role in identifying time lags in the relationship between input variables (rainfall) and output variables (runoff). Moreover, the structure of the TF model provides a suitable framework for explaining hydrological processes and representing the influence of rainfall on runoff within a process-based modeling perspective.

Cite this article: Heydari, Akram, Jandaghi, Nader, Ghareh Mahmoodlu, Mojtaba, Azimmohseni, Majid. 2026. Evaluation of Diverse Modeling Approaches for Rainfall–Runoff Processes in Semi-Arid Regions of Iran. *Journal of Water and Soil Conservation*, 33 (1), 71-98.



© The Author(s).

DOI: 10.22069/jwsc.2025.23831.3817

Publisher: Gorgan University of Agricultural Sciences and Natural Resources

ارزیابی رویکردهای متنوع مدل‌سازی برای فرآیندهای بارش-رواناب در مناطق نیمه‌خشک ایران

اکرم حیدری^۱، نادر جندقی^{۲*}، مجتبی قره‌محمودلو^۳، مجید عظیم‌محسنی^۴

۱. دانشجوی کارشناسی ارشد علوم و مهندسی آبخیزداری، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران. رایانامه: akramheydari2912@gmail.com
۲. نویسنده مسئول، دانشیار هیدرولوژی مهندسی، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران. رایانامه: nader.jandaghi@gmail.com
۳. دانشیار هیدروژئولوژی زیست‌محیطی، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، گنبد کاووس، ایران. رایانامه: mmahmoodlu@yahoo.com
۴. دانشیار آمار، گروه آمار، دانشکده علوم، دانشگاه گلستان، ایران. رایانامه: m.azim@gu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی-پژوهشی	سابقه و هدف: رابطه بارش و رواناب از مفاهیم بنیادین هیدرولوژی به‌شمار می‌رود و بیانگر فرآیندهای پیچیده‌ای مانند نفوذ، تبخیر و تعرق و تبادل آب میان جریان‌های سطحی و زیرسطحی است که منجر به شکل‌گیری رواناب می‌شوند. در مناطق خشک و نیمه‌خشک بارش‌های نامنظم و شدید، همراه با کمبود داده‌های هیدرومتری و ساختار پیچیده حوضه‌ها، چالش‌های جدی برای مدیریت منابع آب ایجاد کرده است. رودخانه‌ها به‌عنوان شریان‌های حیاتی چرخه هیدرولوژیکی، نقشی اساسی در تأمین آب، تغذیه آبخوان‌ها و پایداری زیست‌بوم‌ها دارند و به‌شدت تحت تأثیر تغییرات بارش قرار می‌گیرند. بهره‌گیری از مدل‌سازی پیشرفته رواناب، به‌ویژه استفاده از رویکردهای داده‌محور هم‌چون یادگیری ماشین و یادگیری عمیق، امکان شناسایی الگوهای غیرخطی و پیش‌بینی دقیق رخداد‌های هیدرولوژیکی را فراهم کرده و ابزاری ارزشمند برای تصمیم‌گیری هوشمندانه در مدیریت پایدار منابع آب ارائه می‌دهد. بر این اساس هدف اصلی این پژوهش، ارزیابی و مقایسه عمل‌کرد مدل‌های آماری و داده‌محور، شامل رگرسیون چندکی (QR)، شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی-فازی (ANFIS) و تابع انتقال (TF)، در شبیه‌سازی فرآیند بارش-رواناب در مناطق نیمه‌خشک ایران است.
تاریخ دریافت: ۰۴/۰۴/۱۴ تاریخ ویرایش: ۰۴/۰۷/۰۸ تاریخ پذیرش: ۰۴/۰۸/۰۳	
واژه‌های کلیدی: استان خراسان رضوی، تابع انتقال، رگرسیون چندکی، مدل‌سازی بارش-رواناب، هوش مصنوعی	
	مواد و روش‌ها: در پژوهش حاضر، به‌منظور مدل‌سازی فرآیند بارش-رواناب در سه حوضه آبخیز زشک، دهبار و کارده واقع در استان خراسان رضوی، از داده‌های ماهانه ایستگاه‌های هیدرومتری و هواشناسی در دوره آماری ۲۶ ساله (۱۹۹۷-۲۰۲۲) استفاده شد. در گام نخست،

به منظور بررسی صحت و همگنی سری‌های زمانی داده‌ها، آزمون چاو به کار گرفته شد. با توجه به وابستگی مقادیر بارش و رواناب ماهانه به زمان، داده‌ها به صورت سری‌های زمانی مرتب گردیدند. برای برازش و مدل‌سازی مقادیر رواناب ماهانه با استفاده از داده‌های بارش به منظور پیش‌بینی ۱۲ ماه آینده، از چهار مدل شامل شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی-فازی (ANFIS)، تابع انتقال (TF) و رگرسیون چندکی (QR) بهره گرفته شد. با توجه به این که سال‌های نزدیک‌تر به زمان حال اطلاعات دقیق‌تری از شرایط کنونی ارائه می‌دهند، از سال‌ها به صورت فرآیند پیش‌رو در مدل‌سازی استفاده شده و تعداد سال‌های مؤثر تعیین گردید. از میان سال‌های آماری مورد بررسی، تمامی سال‌ها برای آموزش مدل‌ها و سری زمانی یک سال به منظور اعتبارسنجی به کار رفت. اعتبارسنجی مدل‌های برازش داده شده با استفاده از سه معیار استاندارد میانگین قدرمطلق خطا (MAE)، مجذور میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) ارزیابی شد. شایان ذکر است که در این پژوهش به منظور انجام محاسبات آماری از نرم‌افزارهای R (بسته‌های quantreg و frbs)، SAS، MINITAB و SPSS استفاده شد.

یافته‌ها: بررسی روند سری‌های زمانی بارش و رواناب ماهانه در سه آبخیز مورد مطالعه نشان داد که این حوضه‌ها دارای ساختارهای متفاوتی هستند. تحلیل نمودارهای خودهمبستگی متقابل بیانگر وجود ارتباط تاخیری بین سری‌های زمانی بارش و رواناب در سه آبخیز منتخب است. بر این اساس، اثر مستقیم بارش بر رواناب در حوضه‌های آبخیز زشک و دهبار با حداکثر تأخیر یک‌ماهه و در حوضه آبخیز کارده، به دلیل شرایط کوهستانی و سهم بالاتر برف در رژیم بارندگی، با حداکثر تأخیر سه‌ماهه مشاهده شد. تعداد سال‌های مؤثر در مدل‌سازی با استفاده از فرآیند پیش‌رو برای حوضه‌های آبخیز زشک، دهبار و کارده به ترتیب ۱۷، ۱۹ و ۹ سال تعیین گردید که بهترین عمل‌کرد مدل‌ها را فراهم کرده است. بررسی نتایج اعتبارسنجی مدل‌ها با شاخص‌های MAD، RMSE و R^2 بیانگر آن است که مدل MLP در مقایسه با سایر مدل‌ها، دقیق‌ترین برآورد رواناب ماهانه را در آبخیزهای زشک، دهبار و کارده (به ترتیب $0.123 \text{ m}^3/\text{s}$ ، 0.028 ، 0.032) ارائه می‌دهد. پس از آن، مدل ANFIS ($0.186 \text{ m}^3/\text{s}$ ، 0.044 ، 0.146) در رتبه دوم قرار دارد. اعتبارسنجی مدل‌ها هم‌چنین نشان‌دهنده شباهت قابل توجه نتایج مدل‌سازی دو روش MLP و ANFIS است. پس از این دو مدل، رگرسیون چندکی بالاترین دقت را در آبخیزهای زشک، دهبار و کارده ارائه داد (به ترتیب $0.444 \text{ m}^3/\text{s}$ ، 0.293 ، 0.344). مدل تابع انتقال نیز مشابه مدل QR نتایج نسبتاً مناسبی در تشخیص روند و ارزیابی دقت ارائه کرده است؛ اما در مقایسه با سه مدل دیگر، ضعیف‌ترین عمل‌کرد را در آبخیزهای زشک، دهبار و کارده داشته است (به ترتیب $0.510 \text{ m}^3/\text{s}$ ، 0.378 ، 0.344). نتایج اعتبارسنجی هم‌چنین بیانگر شباهت زیاد نتایج مدل‌سازی رواناب ماهانه در دو روش TF و QR بود. بر اساس ضریب تعیین برای مدل‌ها، می‌توان نتیجه گرفت که سهم قابل توجهی از واریانس متغیر وابسته به طور قابل قبولی توسط متغیرهای مستقل توضیح داده شده است؛ بنابراین، همه مدل‌ها از دقت مناسبی برخوردارند.

نتیجه‌گیری: نتایج این پژوهش نشان داد که چهار مدل مورد استفاده، شامل ANFIS، MLP، TF و QR، با وجود تفاوت در میزان دقت، عمل کرد قابل قبولی در شناسایی الگوها و مدل‌سازی تغییرات سری‌های زمانی خروجی بر اساس داده‌های ورودی نشان داده‌اند. بر این اساس، می‌توان از این مدل‌ها به‌عنوان ابزارهایی کارآمد و مؤثر برای پیش‌بینی رواناب ماهانه بر مبنای میزان بارش در منطقه مورد مطالعه بهره گرفت. در هیچ‌یک از مدل‌های بررسی شده شواهدی از بیش‌برازش یا کم‌برازش مستمر که منجر به کاهش دقت و کارایی مدل‌ها شود، مشاهده نشد. با این حال، مقایسه شاخص‌های ارزیابی نشان داد که از نظر دقت، مدل‌ها به‌ترتیب شامل MLP، ANFIS، QR و TF بوده‌اند. با توجه به نوسانات بالای بارش در استان خراسان رضوی، انتظار می‌رفت مدل QR که برای نقاط حدی سازوکار متفاوتی نسبت به مقادیر متوسط در نظر می‌گیرد، دقت بالاتری داشته باشد؛ با این حال دقت آن نسبت به دو مدل MLP و ANFIS به‌طور چشم‌گیری پایین‌تر بود. اگرچه مدل TF از نظر دقت نسبت به سایر مدل‌ها ضعیف‌تر عمل کرده است، اما این مدل در شناسایی تأخیر زمانی در اثرگذاری بین متغیرهای ورودی (بارش) و خروجی (رواناب) نقش قابل‌توجهی ایفا می‌کند. علاوه‌براین، ساختار مدل TF چارچوب مناسبی برای تبیین فرآیندهای هیدرولوژیکی و نحوه اثرگذاری بارش بر رواناب به‌صورت یک مدل فرآیندمحور فراهم کرده است.

استناد: حیدری، اکرم، جندقی، نادر، قره‌محمودلو، مجتبی، عظیم‌محسنی، مجید (۱۴۰۵). ارزیابی رویکردهای متنوع مدل‌سازی برای فرآیندهای بارش-رواناب در مناطق نیمه‌خشک ایران. *پژوهش‌های حفاظت آب و خاک*، ۳۳ (۱)، ۹۸-۷۱.

DOI: 10.22069/jwsc.2025.23831.3817



© نویسندگان.

ناشر: دانشگاه علوم کشاورزی و منابع طبیعی گرگان

مقدمه

رابطه بارش-رواناب یک مفهوم اساسی در هیدرولوژی است. این مفهوم توضیح می‌دهد که چگونه بارش از طریق فرآیندهای هیدرولوژیکی مانند نفوذ، تبخیر و تعرق و تبادل آب بین جریان‌های سطحی و زیرسطحی، به رواناب سطحی تبدیل می‌شود (۱). در مناطق خشک و نیمه‌خشک، بارش‌ها اغلب با تغییرات شدید مکانی و زمانی همراه هستند و وقوع بارندگی‌های شدید و ناگهانی در این مناطق بسیار محتمل است (۲ و ۳). در این مناطق که شامل قسمت عمده‌ای از مساحت ایران می‌شود، بارندگی‌های نامنظم و شدید، همراه با کمبود داده‌های هیدرومتری و پیچیدگی ساختار هیدرولوژیکی حوضه‌ها، چالش‌های متعددی را در مدیریت منابع آب ایجاد می‌کند. رودخانه‌ها بخش حیاتی چرخه هیدرولوژیکی را تشکیل داده و نقش مهمی در تأمین منابع آب، تغذیه آبخوان‌ها، و حفظ تنوع زیستی اکوسیستم‌ها دارند بسیار متأثر از شرایط بارش می‌باشند. بنابراین، نظارت و مدیریت دقیق رودخانه‌ها برای حفظ منابع آب و جلوگیری از مخاطراتی مانند سیلاب‌ها و خشک‌سالی‌ها از اهمیت زیادی برخوردار است (۴). برای پیش‌بینی و مدیریت دقیق منابع آب، پایداری اکوسیستم و همچنین کاهش اثرات خشک‌سالی و سیلاب، مدل‌سازی رواناب که بتواند این نوسانات و تعاملات پیچیده را به خوبی نمایش دهد، نقش حیاتی دارد (۵).

روند بارش و الگوی جریان سطحی و رودخانه‌ای از یک سیستم دینامیک غیرخطی پیروی می‌کند. بررسی و پیش‌بینی ارتباط غیرخطی بین بارش و رواناب، به‌ویژه جریان‌های زیرسطحی، نیازمند به مدل‌های پیشرفته و منعطف است که بسیاری از مدل‌ها این ویژگی را ندارند (۶). به‌طورکلی روش‌های تجربی و مرسوم هیدرولوژیکی برای پیش‌بینی مقادیر

بارش، رواناب و غیره مبتنی بر مدل‌های عددی و آماری هستند. این روش‌ها از نظر محاسباتی هزینه‌بر هستند زیرا شامل حجم قابل‌توجهی از داده‌ها و متغیرها می‌باشند (۷ و ۸). در سال‌های اخیر، هوش مصنوعی به‌طور گسترده برای مطالعات منابع آب مورد استفاده قرار گرفته است، زیرا در آن امکان درک وقوع و توزیع متغیرهای محیطی مانند بارش و رواناب را فراهم می‌کنند. هوش مصنوعی شامل داده‌کاوی، یادگیری ماشین و یادگیری عمیق است که به ایجاد همبستگی، روند و پیش‌بینی پدیده‌های محیطی کمک می‌کنند (۹ و ۱۰). پیش‌بینی بارش و رواناب با فراهم کردن هشدارهای به‌موقع در مورد وقوع سیل و کمک به تنظیم جریان خروجی از منابع آب در هنگام پایین بودن تراز جریان آب رودخانه، کمک می‌کند تا تصمیم‌گیری در مدیریت منابع آب به‌صورت آگاهانه و مبتنی بر داده انجام شود (۱۱). با توجه به موارد بالا و اهمیت پیش‌بینی جریان آب در رودخانه‌ها که از لحاظ مختلف دارای اهمیت است، پیدا کردن روش و مدلی مناسب در این خصوص ضروری است (۱۲). در پژوهش حاضر از مدل رگرسیون چندکی (QR) به‌همراه سه مدل شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی-فازی (ANFIS) و تابع انتقال (TF) برای مدل‌سازی بارش-رواناب استفاده شده است. لازم به توضیح است که مدل رگرسیون چندکی در حالتی که فرضیات مدل رگرسیون به نوعی برقرار نباشد که منجر به انحراف در نتایج رگرسیون می‌شود، به‌عنوان یک روش جایگزین به‌خوبی عمل می‌کند (۱۳). در ذیل به برخی مطالعات انجام شده در این زمینه اشاره می‌شود.

غفاری و وفاخواه (۲۰۱۳) در شبیه‌سازی فرآیند بارش-رواناب از مدل‌های ANN و ANFIS استفاده نموده و نتیجه گرفتند که مدل ANFIS در مقایسه با مدل ANN از دقت بیش‌تری برخوردار است (۱۴).

انوری (۲۰۲۴) در مدل‌سازی بارش و رواناب برای سد امیرکبیر نتیجه گرفتند که مدل ANN نسبت به مدل رگرسیون چندمتغیره برتری دارد (۲۲). میرزایی حسنلو و همکاران (۲۰۲۴) در تحلیل روند میانگین بارش در ایران بیان نمودند که مدل رگرسیون چندکی اطلاعات کامل‌تری را از میانگین سالانه بارش و شاخص‌های ارائه نموده است (۲۳).

امپالاس و همکاران (۲۰۱۰) با استفاده از مدل‌های ANN و ANFIS ارتفاع بارش را در کشور یونان مدل‌سازی نمودند. نتایج بیان‌گر عمل‌کرد رضایت‌بخش هر دو مدل بوده است (۲۴). فوتیوس و همکاران (۲۰۱۴) در پیش‌بینی رواناب رودخانه در یونان بیان نمودند که مدل QR به‌طورکلی تخمین‌های دقیقی از جریان رودخانه را ارائه می‌دهد (۲۵). عباس و همکاران (۲۰۱۹) در بررسی بارش‌های مرتبط با وقوع سیل و خشک‌سالی در دو کشور انگلیس و چین، نتیجه گرفتند که مدل QR می‌تواند الگوهایی را برای شرایط بسیار مرطوب و خشک نشان دهد (۲۶). ویلیام و همکاران (۲۰۱۹) با استفاده از مدل تابع‌انتقال برای تعیین توابع پاسخ پالسی در طیف فرکانس معیارهای بارش و تبخیر مربوط به پیرومترها در هلند استفاده کردند. یافته‌های حاصل از این پژوهش نشان داد که توزیع فضایی ویژگی‌های توابع پاسخ تکانه می‌تواند در ارزیابی آب زیرزمینی مؤثر باشد (۲۷). بین‌سامی و همکاران (۲۰۱۹) با استفاده از مدل‌های ANFIS و ANN، خطر سیل در رودخانه سند را بررسی و بیان نمودند که مدل ANFIS نتایج رضایت‌بخش‌تری داشته است (۲۸). کوتاری و همکاران (۲۰۱۹) اقدام به شبیه‌سازی جریان و رسوب‌دهی حوضه آبریز ساویتی با استفاده از مدل ANN و FL نمودند. نتایج بیانگر برتری مطلق الگوریتم ANN بوده است (۲۹). قربانی و همکاران (۲۰۲۳) در بررسی روند تغییرات دبی در حوضه آبریز

ابارشی و همکاران (۲۰۱۴) جهت پیش‌بینی تراز آب زیرزمینی در استان گلستان از سه مدل ANN، ANFIS و GA استفاده کردند. نتایج نشان داد که هر ۳ مدل دقت مناسبی داشته‌اند (۱۵). حقی‌زاده و همکاران (۲۰۱۵) جهت مدل‌سازی بارش-رواناب در خرم‌آباد از ۳ مدل MLP، ANFIS و MLR استفاده و نتیجه گرفتند که مدل ANFIS نسبت به دو مدل دیگر عمل‌کرد بهتری داشته است (۱۶). صادقیان و همکاران (۲۰۲۰) در پیش‌بینی خشک‌سالی در استان سمنان تلاش کردند تا مدل‌هایی مناسب برای پیش‌بینی خشک‌سالی ایجاد کنند. نتایج بیانگر دقت مناسب‌تر مدل ANFIS در مقایسه با مدل ANN بوده است (۱۷). فرودی‌صفت و همکاران (۲۰۲۱) در شبیه‌سازی پدیده سیل در حوضه آبریز رودخانه هلیل‌رود نتیجه گرفتند که مدل ANN نسبت به مدل‌های دیگر برتری دارد (۱۸). جندقی و همکاران (۲۰۲۱) در مدل‌سازی فرآیند بارش-رواناب در استان گلستان بیان نمودند که مدل تابع‌انتقال دقت پیش‌بینی را تا دو برابر نسبت به مدل SARIMA افزایش داده است (۱۲). قزل‌سغلی و همکاران (۲۰۲۲) در مدل‌سازی رواناب ماهانه در استان گلستان از ۴ روش ANN، SARIMA، ANFIS و GA استفاده و بیان نمودند دو مدل ANN و ANFIS به‌ترتیب عمل‌کرد مناسب‌تری نسبت به سایر مدل‌ها داشته‌اند. در این پژوهش برای تعیین تعداد سال‌های مؤثر از فرآیند پیش‌رو استفاده شده است (۱۹). ناظری و همکاران (۲۰۲۳) در مدل‌سازی بارش تراز آب زیرزمینی در استان گلستان از فرآیند پیش‌رو استفاده و بیان نمودند دو مدل ANN و ANFIS در مقایسه با مدل TF دارای دقت بیش‌تری بوده است (۲۰). سلامتیان و همکاران (۲۰۲۳) نتایج مدل‌سازی تراز آب زیرزمینی در دشت قم با استفاده از مدل ANFIS را رضایت‌بخش ارزیابی نمودند (۲۱). پورمحمدی و

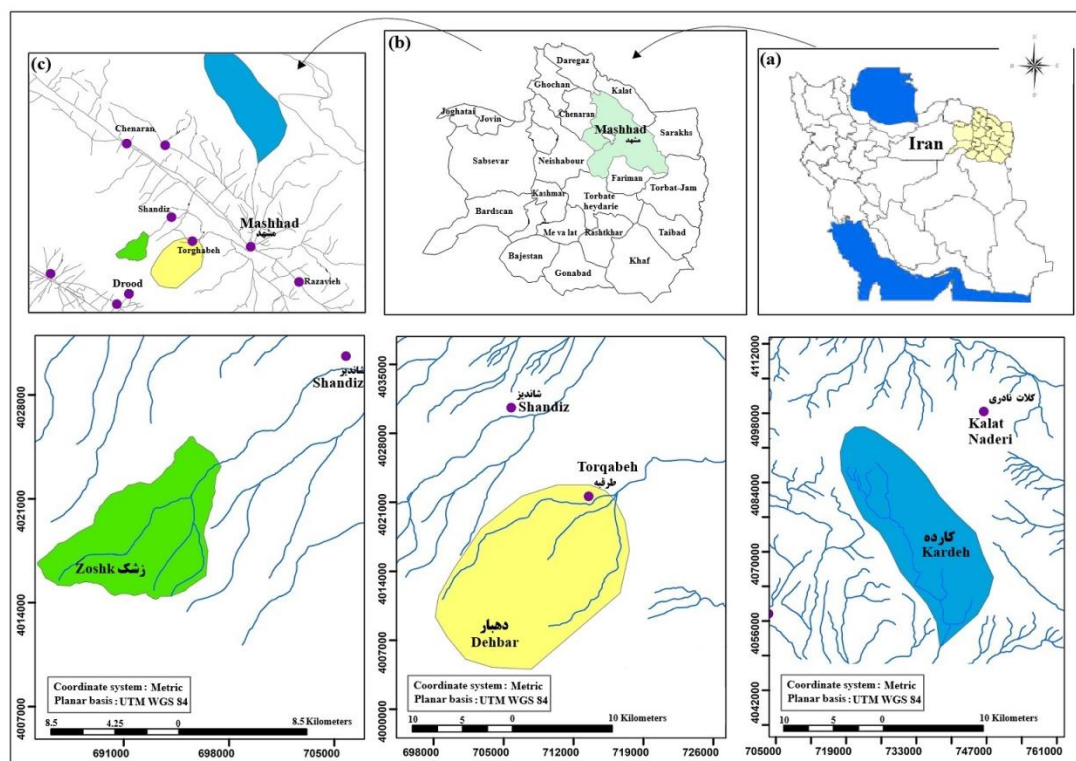
عمل‌کرد مدل‌های آماری و داده‌محور شامل رگرسیون چندکی، شبکه عصبی پرسپترون چندلایه، شبکه عصبی-فازی و تابع انتقال در شبیه‌سازی فرآیند بارش-رواناب در مناطق نیمه‌خشک و ارائه چارچوبی برای انتخاب بهینه مدل است.

مواد و روش‌ها

منطقه مورد مطالعه در این پژوهش شامل سه حوضه زشک، دهبار و کارده بوده که در استان خراسان رضوی، شهرستان مشهد و بینالود واقع شده‌اند که به رودخانه کشف‌رود سرازیر می‌شوند (شکل ۱). حوضه آبخیز زشک با مساحت $71/4$ کیلومتر مربع یکی از سرشاخه‌های حوضه آبریز قره‌قوم در شمال شرق کشور بوده که در فاصله 20 کیلومتری از شهرستان مشهد واقع شده است. متوسط بارندگی سالانه آن 311 میلی‌متر می‌باشد (۳۳). حوضه آبخیز کارده با مساحت $616/9$ کیلومتر مربع در فاصله 40 کیلومتری شمال شرق مشهد واقع شده و قسمتی از آب شرب و کشاورزی شهر را تامین می‌کند. متوسط بارندگی سالانه در سطح حوضه در بخش جنوبی 350 میلی‌متر و در ارتفاعات شمالی به 640 میلی‌متر می‌رسد (۳۴). حوضه آبخیز دهبار با مساحت $252/46$ کیلومتر مربع در 10 کیلومتری غرب مشهد و در جنوب شهر طرقله قرار گرفته است. متوسط بارندگی سالانه این حوضه 245 میلی‌متر به دست آمده است (۳۵).

گرگان‌رود بیان نمودند دقت رگرسیون چندکی بیزی بالاتر از رگرسیون چندکی فرکانس‌گرا بوده است. با این وجود نتایج هر دو مدل رضایت‌بخش بوده است (۳۰). گونال و همکاران (۲۰۲۳) در پیش‌بینی ضریب رواناب تحت تأثیر فاکتورهای اقلیمی در آنتالیا نتیجه گرفت که مدل ANFIS ضرایب رواناب را با دقت استثنایی پیش‌بینی می‌کند (۳۱). شریفی و محمدی قالی (۲۰۲۴) جهت بررسی رابطه پارامترهای هواشناسی و تبخیر و تعرق مرجع روزانه از مدل‌های ML، QR و هم‌چنین روابط تجربی استفاده و مشخص شد دقت مدل‌های QR و ML بالاتر است (۳۲). نتایج بررسی‌های انجام شده بیانگر دقت متفاوت مدل‌های مورد استفاده در مناطق مختلف بوده که با توجه به نوع داده‌های ورودی و خروجی و هم‌چنین طول دوره آماری آن‌ها، منطقی به نظر می‌رسد.

فرآیند بارش و تبدیل آن به رواناب یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی است که به عوامل مختلفی بستگی دارد. امروزه این فرآیند و پیش‌بینی آن یکی از اساسی‌ترین مباحث علم هیدرولوژی محسوب شده که نقش حیاتی در اکثر فعالیت‌های مدیریت منابع آب ایفا می‌کند. تاکنون مدل‌های مختلفی برای پیش‌بینی و مدل‌سازی رواناب با استفاده از الگوی بارش ارایه شده است. لذا هدف اصلی این پژوهش، ابتدا شناسایی و تعیین بازه زمانی بهینه و تعداد سال‌های مؤثر در پیش‌بینی رواناب با بهره‌گیری از فرآیند پیش‌رو و سپس ارزیابی و مقایسه



شکل ۱- موقعیت جغرافیایی سه حوضه مورد مطالعه در ایران (a)، استان خراسان رضوی (b) و حوضه آبریز کشف‌رود (c).
Figure 1. Geographical location of three study watersheds in Iran: (a) Iran, (b) Khorasan Razavi Province, and (c) the Kashafroud River Basin.

هواشناسی و هیدرومتری منتخب از سال آبی ۱۳۷۶-۱۳۷۵ تا ۱۴۰۱-۱۴۰۰ (۲۶ ساله) انتخاب و مقادیر دبی متوسط و بارندگی ایستگاه‌ها به صورت ماهانه از شرکت آب منطقه‌ای استان خراسان رضوی جمع‌آوری شد. سپس با استفاده از آزمون چاو صحت و همگنی داده‌ها بررسی شد.

پس از تعیین موقعیت جغرافیایی، برای هر حوضه آبخیز یک ایستگاه هیدرومتری که در خروجی آن واقع شده به همراه یک ایستگاه هواشناسی که معرف شرایط بارش در آن آبخیز باشد، انتخاب شد (جدول ۱). پس از بررسی کیفیت داده‌های جمع‌آوری شده، دوره آماری مشترک برای ایستگاه‌های


جدول ۱- مشخصات ایستگاه‌های هواشناسی و هیدرومتری در ۳ حوضه آبخیز منتخب.

Table 1. Specifications of meteorological and hydrometric stations in the three selected watersheds.

ارتفاع (متر) Elevation (m)	Geographic coordinates (UTM)		نوع ایستگاه Station type	نام ایستگاه Station name	حوضه Watershed
	Y	X			
1279	4056093	740695	Climatological station	Karde dam	کارده
1322	4060437	738303	Hydrometric station	Karde	Kardeh
1822	4023742	697023	Climatological station	Zoshk-Khorasan	زشک
1692	4023333	697026	Hydrometric station	Zoshk-Khorasan	Zoshk
1251	4020751	716022	Rain gauge station	Hesar-Dehbar	دهبار
1249	4020977	715734	Hydrometric station	Hesar-Dehbar	Dehbar

مسائل یادگیری ماشین و به‌ویژه مسائل طبقه‌بندی و رگرسیون استفاده می‌شود (۳۶، ۳۷، ۳۸ و ۳۹). این نوع شبکه عصبی شامل چندین لایه است که شامل لایه ورودی، یک یا چند لایه پنهان و در نهایت یک لایه خروجی می‌باشد. لایه ورودی داده‌های ورودی را دریافت می‌کند. هر نورون در این لایه نمایانگر یکی از ویژگی‌های ورودی است. لایه‌های پنهان بین لایه ورودی و لایه خروجی قرار گرفته و وظیفه پردازش داده‌ها را بر عهده دارند. هر نورون در این لایه یک تابع فعال‌سازی دارد که به آن اجازه می‌دهد تا روابط غیرخطی را یاد بگیرد. تعداد لایه‌ها و نورون‌ها در هر لایه می‌تواند متفاوت باشد و بسته به مسأله خاص تعیین می‌شود. لایه خروجی نتایج نهایی را تولید می‌کند. تعداد نورون‌ها در لایه خروجی معمولاً به تعداد متغیرهای خروجی در مسأله رگرسیون بستگی دارد. ساختار کلی یک شبکه عصبی مصنوعی که در پیش‌بینی سری زمانی مورد استفاده قرار می‌گیرد در شکل ۲ نشان داده شده است (۴۰ و ۴۱).

با توجه به این‌که مقادیر بارش و رواناب ماهانه وابسته به زمان هستند، در ابتدا این داده‌ها به صورت سری زمانی مرتب شد. در این پژوهش برازش و مدل‌سازی مقادیر رواناب ماهانه با استفاده از داده‌های بارش با استفاده از مدل MLP، ANFIS، TF و QR انجام شد. شایان ذکر است که در پژوهش حاضر، جهت انجام محاسبات آماری از نرم‌افزارهای R، SAS، MINTAN و SPSS استفاده شد. مدل شبکه عصبی پرسپترون چندلایه^۱: شبکه‌های عصبی مصنوعی یک روش موثر در پیش‌بینی سری‌های زمانی می‌باشد. از مزیت‌های استفاده از این مدل‌ها این است که مبتنی بر فرضیه خاصی نبوده و در صورت وجود الگوهای تصادفی و غیرتصادفی در سری زمانی، کارایی لازم را دارند. در این پژوهش از مدل شبکه عصبی پرسپترون چندلایه یا MLP که یکی از ساده‌ترین و پرکاربردترین انواع شبکه‌های عصبی است، استفاده شده است. این مدل یکی از انواع مدل‌های یادگیری عمیق است که برای حل



شکل ۲- ساختار کلی یک شبکه عصبی مصنوعی در پیش‌بینی سری زمانی.

Figure 2. General structure of an artificial neural network in time series forecasting.

پیش‌بینی‌کننده در مدل شبکه عصبی مصنوعی به‌کار گرفته می‌شود. در این حالت مدل شبکه عصبی پرسپترون چندلایه را می‌توان به‌صورت رابطه ۱ نوشته شود (۴۲):

$$y_t = \sum_{j=1}^n \alpha_j f\left(\sum_{i=1}^m \beta_{ij} y_{t-j} + \beta_{0j}\right) + \sum_{j=0}^n \gamma_j g\left(\sum_{i=1}^m \delta_{ij} Z_{t-j} + \gamma_{0j}\right) + \varepsilon_t \quad (1)$$

گره‌های پنهان تا لایه خروجی و β_{ij} و δ_{ij} وزن مسیره‌های بین لایه ورودی و گره‌های پنهان را مشخص می‌کند.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

نشود. در نهایت مناسب‌ترین مدل شبکه عصبی برای سری داده‌ها انتخاب شد.

برای ساخت یک مدل مناسب شبکه عصبی مصنوعی، داده‌ها به سه دسته تقسیم می‌شوند. قسمت اول مشاهدات آموزشی است که برای برآورد پارامترهای مدل استفاده می‌شوند، قسمت دوم مشاهدات آزمایشی است که برای اعتبارسنجی درونی مدل مورد استفاده قرار می‌گیرند و قسمت سوم که در ابتدای تحلیل کنار گذاشته می‌شوند نهایتاً برای اعتبارسنجی بیرونی یا پیش‌بینی مدل مورد استفاده قرار می‌گیرد. در سری‌های زمانی متناوب، مشاهدات به‌صورت مضربی از دوره تناوب تقسیم‌بندی می‌شوند. در سری‌های زمانی متناوب پیشنهاد می‌شود که از یک دوره قبل و یا نهایتاً دو دوره قبل در پیش‌بینی استفاده گردد.

مدل شبکه عصبی-فازی^۱: مدل شبکه عصبی-فازی یا ANFIS نوعی مدل شبکه عصبی مصنوعی است که براساس سیستم فازی، وزن‌ها را به‌روزرسانی

در حالتی که رابطه بین دو سری زمانی مورد بررسی قرار می‌گیرد زمان‌های گذشته سری زمانی خروجی (y_{t-j}) و زمان‌های حال و گذشته سری زمانی ورودی (Z_{t-j}) به‌عنوان متغیرهای

که در آن، m تعداد گره‌های ورودی، n تعداد گره‌های پنهان، f و g توابع انتقال‌دهنده از ورودی به خروجی که معمولاً به‌صورت تابع سیگموئیدی در نظر گرفته می‌شود (رابطه ۲). همچنین α_j و γ_j وزن مسیره‌های

تاکنون انواع مختلفی از شبکه‌های عصبی مصنوعی ارائه شده است اما برای سری‌های زمانی عمدتاً از شبکه‌های عصبی پیش‌رو استفاده می‌شود. یکی از چالش‌های بزرگ در پیش‌بینی سری‌های زمانی انتخاب بیش‌ترین تأخیر مؤثر در پیش‌بینی می‌باشد. در این پژوهش مراحل زیر برای تعیین تعداد سال‌های مؤثر و مدل‌سازی شبکه‌های عصبی بر اساس فرآیند پیش‌رو انجام شد (۱۹ و ۲۰):

گام اول: داده‌های بارش دو سال آخر و داده‌های رواناب سال قبل به‌عنوان متغیر پیش‌بینی کننده در نظر گرفته شد و مقادیر پیش‌بینی رواناب تعیین و سپس شاخص RMSE برای مقادیر پیش‌بینی محاسبه گردید.

گام دوم: علاوه بر داده‌های فوق، مقادیر بارش و رواناب سال سوم نیز به مدل اضافه و پیش‌بینی انجام شد. سپس مقدار RMSE محاسبه گردید.

گام سوم: اضافه کردن سال‌های گذشته در پیش‌بینی تا مرحله‌ای انجام شد که دیگر تغییر محسوسی در نتایج شاخص RMSE مربوط به مقادیر پیش‌بینی ایجاد

می‌گیرد. به عبارت دیگر هر مسیر از لایه ورودی تا لایه‌های پنهان و لایه‌های پنهان تا لایه خروجی، با یک درجه عضویت می‌تواند منجر به پیش‌بینی سری زمانی گردد (۴۵). در هنگام استفاده از این روش دقت محاسبات می‌تواند افزایش یابد زیرا که انعطاف‌پذیری شبکه عصبی مصنوعی افزایش یافته است. در مدل شبکه عصبی-فازی تابع عضویت معمولاً به صورت تابعی زنگوله‌ای شکل در نظر گرفته می‌شود (رابطه ۳):

$$\mu(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (3)$$

مدل سازی و پیش‌بینی سری زمانی پاسخ شرکت می‌کنند (۴۷). مدل تابع انتقال یک رابطه دینامیکی بین یک سری زمانی به عنوان متغیر پاسخ و یک یا چند سری زمانی به عنوان متغیر پیش‌بینی کننده برقرار می‌کند (۴۸). این مدل با در نظر گرفتن تاخیر رابطه بین سری‌های زمانی به پیش‌بینی سری زمانی پاسخ می‌پردازد. مدل تابع انتقال با یک سری زمانی پیش‌بینی کننده به صورت رابطه ۴ ارایه شده است:

$$\nabla^{d_1} \nabla_{T_1}^{D_1} Y_t = \mu + \frac{Cw(B)}{\delta(B)} B^b \nabla^{d_2} \nabla_{T_2}^{D_2} X_t + \eta_t \quad (4)$$

ارتباط بین دو سری زمانی، در این تاخیر اتفاق می‌افتد. انتظار می‌رود که b یک عدد نامنفی باشد که نشان‌دهنده این است که زمان‌های حال و گذشته سری زمانی ورودی در پیش‌بینی سری زمانی خروجی مؤثر هستند. مقدار b از تابع خودهمبستگی متقابل قابل تشخیص می‌باشد. هم‌چنین مقادیر r و s نیز براساس تابع انتقال متقابل تعیین می‌شود (۴۹). برای بررسی نکویی برازش یک تابع انتقال با یک سری زمانی ورودی از دو آماره استفاده می‌شود که در روابط ۵ و ۶ ارایه شده است:

می‌کند. این روش توسط تاکاگی-سوگنو در اوایل ۱۹۹۰ ایجاد شده است. از آن‌جاکه این سیستم، شبکه‌های عصبی و مفاهیم منطق فازی را ترکیب می‌کند، می‌تواند از امکانات هر دو آن‌ها در یک مدل بهره‌برد (۴۳ و ۴۴). نحوه مدل‌سازی این روش شبیه شبکه‌های عصبی مصنوعی بوده با این تفاوت که انتخاب مسیر بر اساس منطق فازی و یک تابع عضویت که توسط داده‌ها برآورد می‌شود، انجام

که در آن، پارامترهای a_i ، b_i و c_i توسط داده‌ها برآورد و یا آموزش داده می‌شوند (۴۶). برای مدل‌سازی شبکه عصبی-فازی از بسته نرم‌افزاری frbs در محیط نرم‌افزار R و بر اساس روش وانگ و مندل استفاده گردید.

مدل تابع انتقال^۱: مدل تابع انتقال یا TF یک رگرسیون تاخیر زمانی است که علاوه بر داده‌های سری ورودی، سری زمانی پاسخ در زمان‌های گذشته نیز در

که در آن، μ و C اعداد ثابت، η_t سری زمانی باقی‌مانده مدل و $w(B)$ و $\delta(B)$ دو چندجمله‌ای از عملگر پسررو می‌باشند. بنابراین هر تابع انتقال با D_2 ، T_2 ، D_1 ، T_1 و d_1 پارامترهای r ، s و b که در آن r و s درجه چندجمله‌ای‌های $w(B)$ و $\delta(B)$ است، تعیین می‌شود. پارامترهای D_2 ، T_2 ، D_1 ، T_1 و d_1 مانند برازش مدل SARIMA برای هر سری زمانی به‌طور جداگانه تعیین می‌شود. لازم به توضیح است که دوره تناوب دو سری زمانی ممکن است متفاوت باشد. پارامتر b تاخیری است که بیش‌ترین

$$Q_1 = n \sum_{i=1}^k r_i^2(\eta_t, X_t) \quad (5)$$

$$Q = n \sum_{i=1}^k r_i^2(\eta_t, \eta_t) \quad (6)$$

به‌ویژه زمانی که توزیع سری زمانی غیرعادی است یا سری زمانی دارای ناهمسانی واریانس در طول زمان را نشان می‌دهد. با برازش مدل‌های QR می‌توان تصویر کامل‌تری از توزیع پیش‌بینی به‌دست آورد که می‌تواند برای مدیریت ریسک و تصمیم‌گیری مفید باشد. هم‌چنین رگرسیون چندکی این امکان را فراهم می‌کند که به‌جای میانگین یا میانه، چندک‌های سری زمانی هدف مدل قرار گیرد. این موضوع زمانی مفید است که نقاط اکستریم نیز اهمیت داشته باشد و نه فقط گرایش مرکزی (۵۰). در یک مدل رگرسیونی با متغیر پیش‌بینی‌کننده X و متغیر پاسخ Y یک مدل رگرسیون چندکی به‌صورت رابطه ۷ تعریف می‌شود (۲۶ و ۵۱):

$$y = a^{(\tau)} + b^{(\tau)}x + \varepsilon \quad (7)$$

در حالت کلی اگر در مدل مورد استفاده بیش از یک متغیر پیش‌بینی‌کننده حضور داشته باشد، مدل رگرسیون چندکی به‌صورت رابطه ۸ می‌باشد:

$$y = \beta_0^{(\tau)} + \beta_1^{(\tau)}x_1 + \dots + \beta_k^{(\tau)} + \varepsilon \quad (8)$$

(رابطه ۹):

$$y = X\beta^{(\tau)} + \varepsilon \quad (9)$$

رابطه ۱۰ حاصل می‌شود:

که در آن، $r_i(\eta_t, X_t)$ تابع خودهمبستگی متقابل بین سری زمانی باقی‌مانده و سری زمانی ورودی و $r_i(\eta_t, \eta_t)$ تابع خودهمبستگی سری زمانی باقیمانده می‌باشد. آماره رابطه ۵ یک معیار مهم برای برازش تابع انتقال است که نشان می‌دهد سری زمانی باقی‌مانده دیگر به سری زمانی ورودی مرتبط نیست در نتیجه مدل برازش مناسبی از این لحاظ داشته است. آماره رابطه ۶ بر اساس برازش مدل مناسب به سری زمانی باقی‌مانده شکل گرفته است. مدلی از تابع انتقالی برازش داده شده مناسب است که هر دو ویژگی بالا را به‌طور هم‌زمان داشته باشد. این بررسی با کمک نرم‌افزارهای SAS و MINITAB انجام شد.

مدل رگرسیون چندکی^۱: رگرسیون چندکی یا QR یک تکنیک مهم در پیش‌بینی سری‌های زمانی است،

که در آن، $a^{(\tau)}$ و $b^{(\tau)}$ ضرایب رگرسیون چندکی در چندک τ می‌باشند به‌طوری‌که $0 < \tau < 1$ می‌باشد. این ضرایب برای کلیه چندک‌ها قابل محاسبه می‌باشد.

مدل رابطه ۸ را می‌توان به‌صورت ماتریسی نوشت

که در آن، $\beta^{(\tau)}$ بردار پارامترهای مدل می‌باشد. براساس n مشاهده، برآورد پارامترها از مینیمم کردن

$$L = \tau \sum_{y_i > X_i \beta^{(\tau)}} |y_i - X_i \beta^{(\tau)}| + (1 - \tau) \sum_{y_i \leq X_i \beta^{(\tau)}} |y_i - X_i \beta^{(\tau)}| \quad (10)$$

اعتبارسنجی مدل‌ها: از تعداد سال‌های آماری مورد بررسی در حوضه‌های مورد بررسی، تمامی سال‌ها در آزمون‌ها و مدل‌ها و سری زمانی و یک سال آن برای اعتبارسنجی مدل مورد استفاده قرار گرفت. برای این مقایسه از توابع فاصله بین مقادیر واقعی و مقادیر پیش‌یابی شامل RMSE، MAE و R^2 (روابط ۱۱ تا ۱۳) استفاده شد (۵۲).

$$MAE = \frac{\sum_{t=1}^n |\hat{Y}_t - Y_t|}{n} \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{t=1}^m (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^m (Y_t - \bar{Y})^2} \quad (13)$$

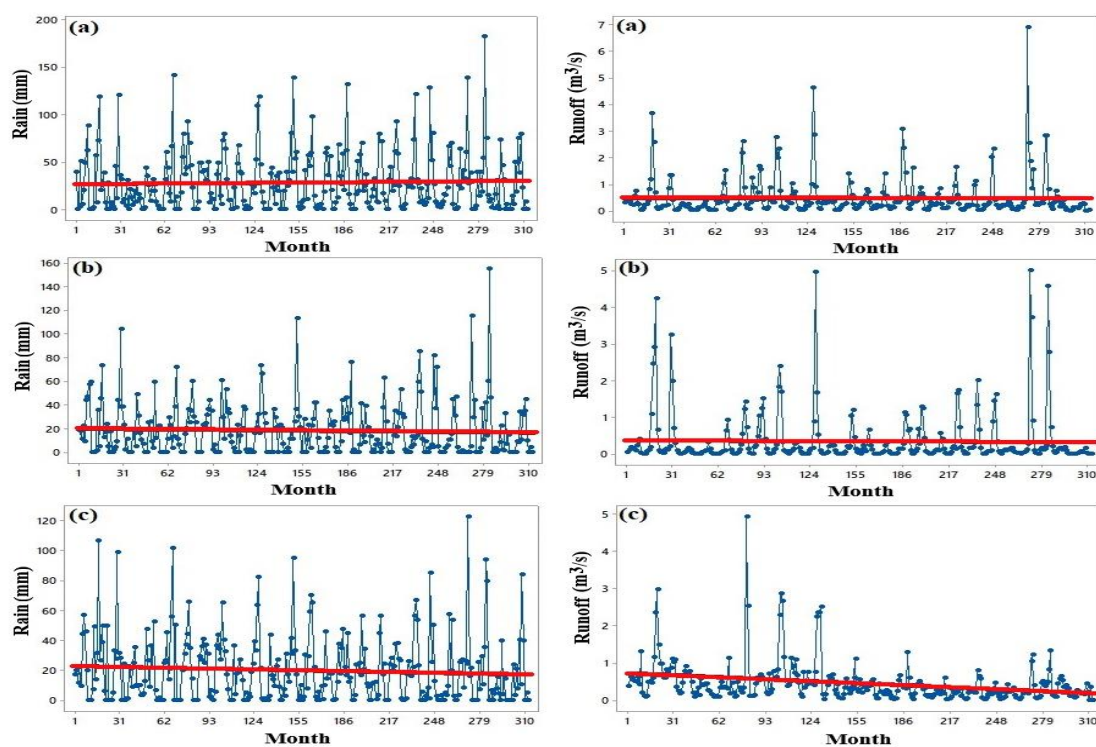
چپ) مشخص شد مقادیر بارش ماهانه در ایستگاه‌های هواشناسی واقع در حوضه‌های آبخیز زشک و دهبار فاقد روند بوده اما در ایستگاه هواشناسی واقع در حوضه آبخیز کارده یک روند نزولی خفیف مشاهده شد. هم‌چنین در بررسی نمودار روند رواناب (شکل ۳، سمت راست) مشخص شد مقادیر رواناب متوسط ماهانه در حوضه‌های آبخیز زشک و دهبار فاقد روند بوده اما در حوضه آبخیز کارده یک روند نزولی داشته است.

برای استفاده از رگرسیون چندکی در پیش‌بینی سری زمانی، مقادیر سری‌های زمانی در زمان‌های گذشته به‌عنوان متغیرهای پیش‌بینی‌کننده در نظر گرفته می‌شود. برای برازش رگرسیون چندکی از بسته **quantreg** در نرم‌افزار **R** استفاده شد.

در این روابط، \hat{Y}_t مقدار متغیر پیش‌یابی شده توسط مدل، Y_t مقدار متغیر مشاهده شده، t شماره مشاهده و n تعداد مشاهدات است.

نتایج و بحث

در این پژوهش، برازش مدل و پیش‌بینی مقادیر رواناب ماهانه با استفاده از داده‌های بارش برای ۱۲ ماه آینده در ۳ حوضه آبخیز با استفاده از چهار مدل ANFIS، MLP، TF و QR انجام و سپس عمل‌کرد این مدل‌ها با شاخص‌های مختلف مورد ارزیابی قرار گرفت. در بررسی نمودار روند بارش (شکل ۳، سمت

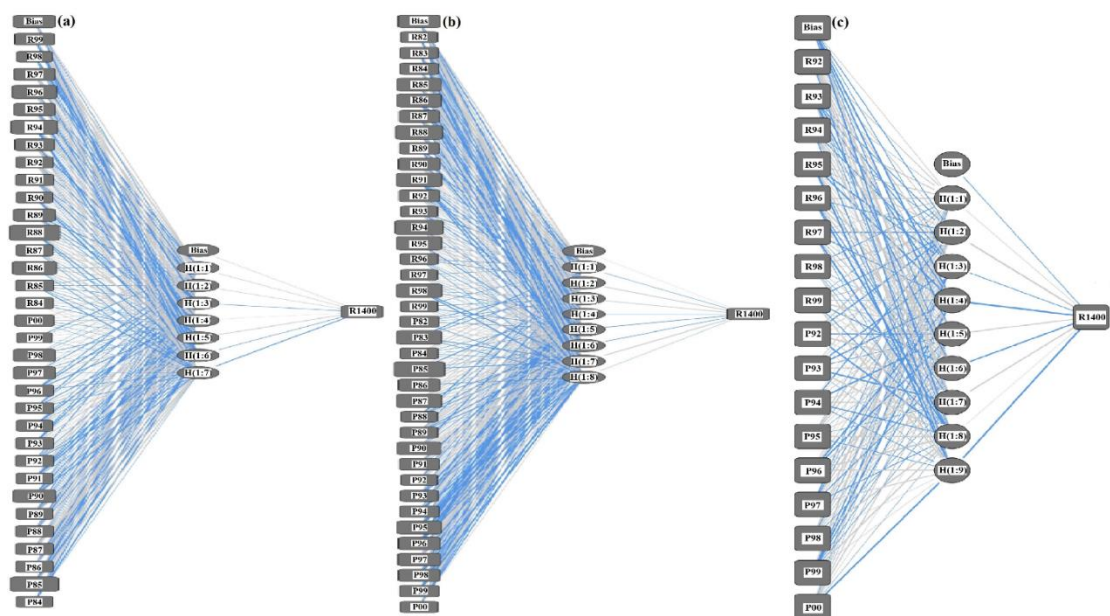


شکل ۳- نمودارهای روند تغییرات بارش (سمت چپ) و رواناب (سمت راست) ماهانه در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 3. Monthly variation trends of rainfall (left) and runoff (right) in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.

ماهانه ۱۷ سال گذشته به‌عنوان تعداد سال‌های مؤثر و متغیرهای پیش‌بینی‌کننده وارد مدل شده و بهترین عمل‌کرد را داشته است. بر این اساس در حوضه‌های آبخیز دهبار و کارده تعداد سال‌های مؤثر به‌ترتیب ۱۹ و ۹ سال گذشته تعیین شد.

در مدل‌سازی شبکه عصبی MLP با در نظر گرفتن این موضوع که سال‌های نزدیک‌تر به وضعیت حال اطلاعات دقیق‌تری از وضعیت این زمان دارند، سال‌ها به‌صورت فرآیند پیش‌رو در مدل‌سازی استفاده و تعداد سال‌های مؤثر تعیین شد. مطابق با شکل ۴a در آبخیز زشک مقادیر بارش و رواناب

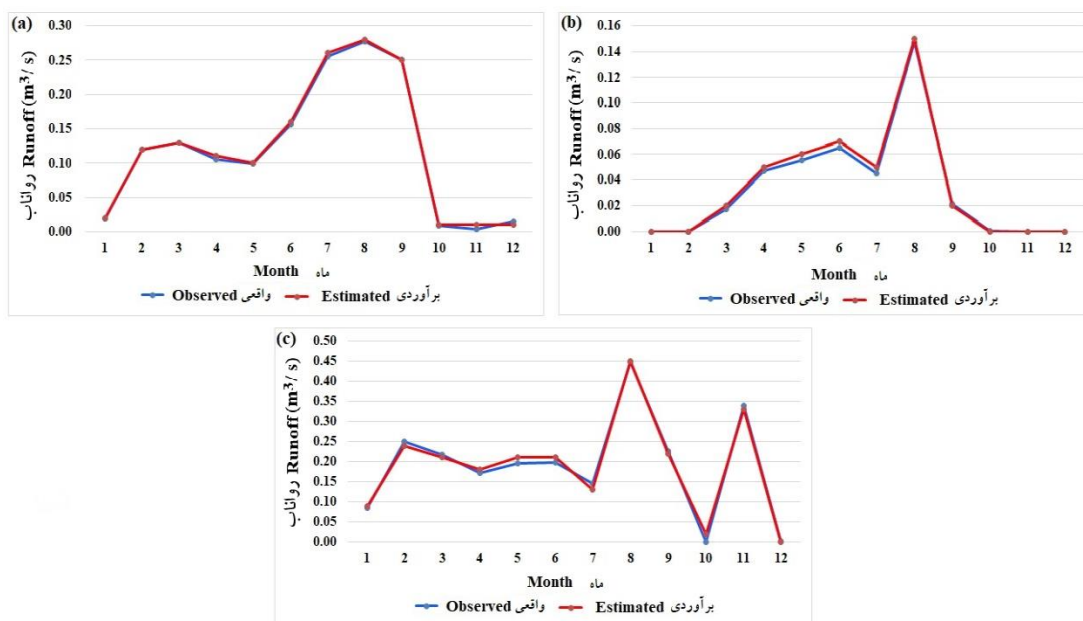


شکل ۴- ساختار مدل شبکه عصبی MLP در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 4. Structure of the MLP neural network model in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.

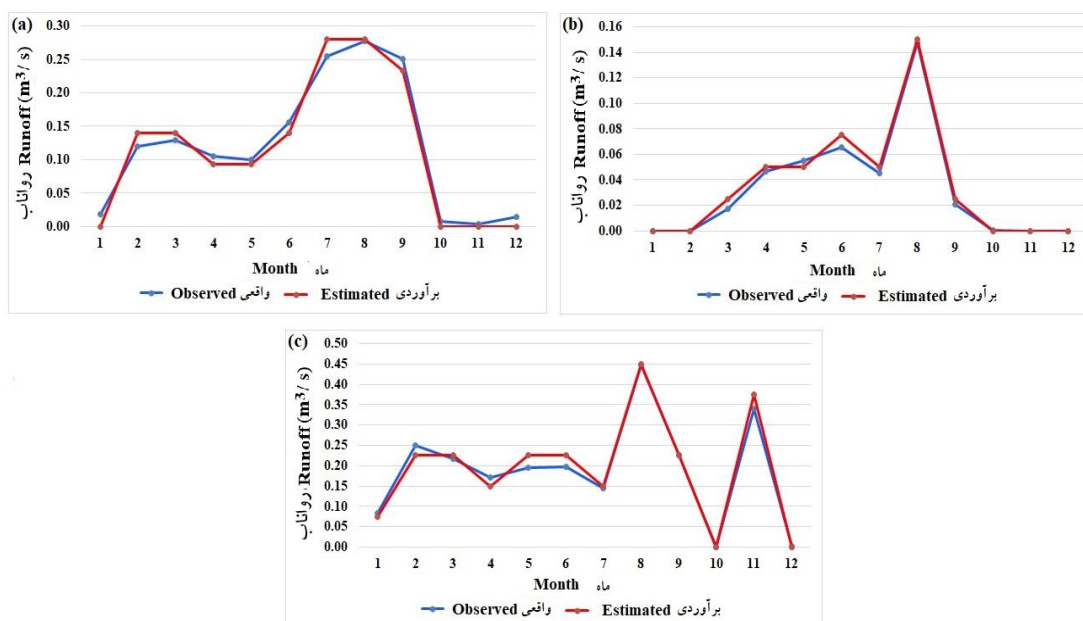
شکل ۶ مقادیر واقعی و برآوردشده رواناب ماهانه توسط مدل ANFIS را در سه حوضه آبخیز مورد مطالعه نشان می‌دهد. بر اساس این شکل، عملکرد مدل ANFIS در هر سه حوضه مشابه مدل MLP ارزیابی شده و توانسته است روند تغییرات را با دقت مناسبی شناسایی کند. در هر دو مدل، شواهدی از بیش‌برآوردی یا کم‌برآوردی سیستماتیک که منجر به افزایش خطا شود، مشاهده نگردید. علاوه بر این، نتایج نشان داد که مدل ANFIS در ماه‌های فروردین تا تیر (مطابق با ماه‌های ۷ تا ۱۰ داده‌های سری زمانی) در هر سه حوضه عملکرد دقیق‌تری نسبت به سایر ماه‌ها داشته است.

شکل ۵ مقادیر واقعی و برآوردشده رواناب ماهانه توسط مدل شبکه عصبی پرسپترون چندلایه (MLP) را در سه حوضه آبخیز مورد مطالعه نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، مدل MLP عملکرد بسیار مطلوبی در شناسایی روندها، برازش و مدل‌سازی رابطه بارش-رواناب ماهانه در هر سه حوضه آبخیز داشته است. افزایش دقت و کارایی مدل MLP در این مطالعه را می‌توان به استفاده از رویکرد فرآیند پیش‌رو در مدل‌سازی نسبت داد؛ به‌گونه‌ای که نتایج حاصل از این رویکرد در مقایسه با استفاده از سری زمانی کامل داده‌ها به‌طور قابل‌ملاحظه‌ای بهبود یافته است.



شکل ۵- نمودار مقایسه رواناب ماهانه واقعی و برآوردی توسط مدل MLP در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 5. Comparison of observed and estimated monthly runoff using the MLP model in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.



شکل ۶- نمودار مقایسه رواناب ماهانه واقعی و برآوردی توسط مدل ANFIS در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 6. Comparison of observed and estimated monthly runoff using the ANFIS model in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.

بارش ماهانه در ایستگاه‌های هواشناسی منتخب در جدول ۲ ارایه شده است. مقادیر معنی‌داری نشان می‌دهد که در سری‌های زمانی باقی‌مانده مدل‌ها، همبستگی وجود ندارد در نتیجه مدل‌ها به‌خوبی برازش داده شده‌اند.

مدل‌سازی تابع انتقال در سه مرحله پیش‌صافی، همبستگی متقابل و برازش مدل انجام شد. برای پیش‌صافی کردن بین سری‌های زمانی ورودی (بارش) و خروجی (رواناب)، یک مدل باکس و جنکینز برای مقادیر بارش در حوضه‌های آبخیز زشک، دهبار و کارده برازش شد. بهترین مدل برازش شده به داده‌های

جدول ۲- نتایج مدل‌سازی باکس و جنکینز برای سری زمانی بارش ماهانه در سه حوضه آبخیز منتخب.

Table 2. Results of Box-Jenkins modeling for the monthly rainfall time series in three selected watersheds.

مقدار معنی‌داری Significant value	مدل باکس و جنکینز Box and Jenkins model	نام حوضه آبخیز Watershed Name
0.538	$(0, 0, 2) \times (0, 1, 2)_{12}$	زشک Zoshk
0.719	$(0, 0, 3) \times (0, 1, 1)_{12}$	دهبار Dehbar
0.723	$(0, 0, 1) \times (0, 1, 2)_{12}$	کارده Kardeh

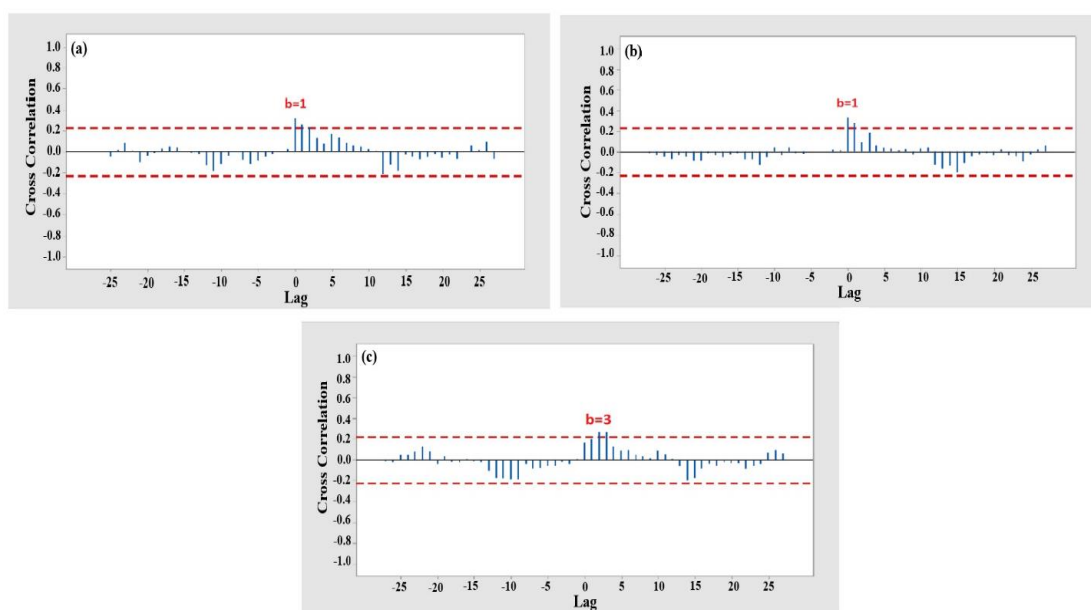
چرخه هیدرولوژیکی نسبت داد. یافته‌های این مطالعه با نتایج پژوهش ناظری و همکاران (۳۲) هم‌راستا است؛ آنان نیز تأثیر بارش‌های جوی با تأخیر چندماهه بر تغییرات تراز آب زیرزمینی را گزارش کرده‌اند.

نتایج برازش و مدل‌سازی تابع انتقال در سه آبخیز مورد مطالعه در جدول ۳ ارایه شده است. در این مطالعه پارامترهای تابع انتقال با ترسیم نمودارهای خودهمبستگی متقابل تعیین شده است. در مدل‌سازی تابع انتقال به سری زمانی مقادیر باقی‌مانده‌ها، مدل‌های مناسب برازش داده شد. چنانچه مقادیر معنی‌داری محاسباتی بزرگ‌تر از ۰/۰۵ باشد، مدل برازش داده شده پذیرفته می‌شود. با توجه به سطح مقادیر معنی‌داری که بسیار بالاتر از ۰/۰۵ می‌باشد، هم مدل تابع انتقال و هم مدل سری زمانی مقادیر باقی‌مانده‌ها برای هر سه حوضه آبخیز زشک، دهبار و کارده به‌خوبی برازش شده و مدل‌ها پذیرفته می‌شود. پس از برازش مدل تابع انتقال، پیش‌بینی مقادیر رواناب با استفاده از داده‌های بارش برای ۱۲ ماه آینده

پس از برازش مدل پیش‌صافی، همان مدل بر داده‌های بارش و رواناب ماهانه اعمال شد. نمودار خودهمبستگی متقابل بین سری‌های زمانی بارش و رواناب پس از اعمال پیش‌صافی برای سه حوضه آبخیز منتخب در شکل ۷ ارائه شده است. وجود یک پیک معنی‌دار در هر سه نمودار، بیانگر وجود رابطه آماری بین بارش و رواناب در تمامی حوضه‌های مورد مطالعه بوده و این ارتباط به‌عنوان پیش‌شرط لازم برای استفاده از مدل تابع انتقال مطرح می‌شود. براساس نتایج شکل ۷، در دو حوضه آبخیز زشک و دهبار، بیش‌ترین همبستگی متقابل بین بارش و رواناب با یک تأخیر زمانی حداکثر یک‌ماهه مشاهده شد که نشان‌دهنده تأثیر مستقیم بارش بر رواناب با این بازه زمانی است. در مقابل، در حوضه آبخیز کارده، اثرگذاری بارش بر رواناب با حداکثر تأخیر سه‌ماهه رخ داده است. این تأخیر در حوضه کارده را می‌توان به شرایط کوهستانی منطقه، سهم بالاتر بارش برف نسبت به دو حوضه دیگر، و فرآیند کند ذوب برف در

کم‌برآوردی سیستماتیک که منجر به کاهش دقت پیش‌بینی شود، مشاهده نشد. با این‌حال، مقایسه نمودارهای حاصل از مدل‌سازی نشان می‌دهد که دقت مدل تابع‌انتقال نسبت به دو مدل ANFIS و MLP به‌طور محسوسی کمتر است.

انجام شد. نتایج نشان داد که مدل تابع‌انتقال، مشابه با دو مدل ANFIS و MLP، در مدل‌سازی، برازش و شناسایی روند تغییرات بارش-رواناب ماهانه در سه حوضه آبخیز مورد مطالعه، عمل‌کرد قابل‌قبولی ارائه کرده است (شکل ۸). در این مدل نیز، همانند مدل‌های ANFIS و MLP، شواهدی از بیش‌برآوردی یا



شکل ۷- نمودار خودهمبستگی متقابل بین سری‌های زمانی بارش و رواناب در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).
Figure 7. Crosscorrelation plot between the monthly rainfall and runoff time series in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.

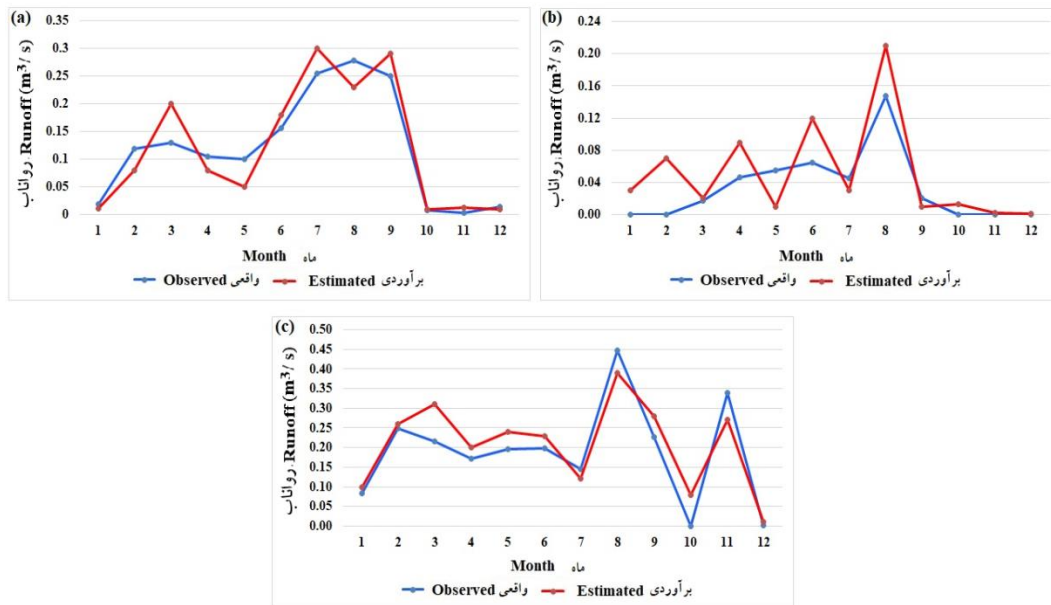
جدول ۳- نتایج برازش مدل TF به بارش-رواناب در ایستگاه‌های منتخب.

Table 3. Fitting Results of the TF Model to Rainfall-Runoff Data at Selected Stations.

مقادیر معنی‌داری Significant values		مدل برازش شده به سری زمانی باقی‌مانده The model fitted to the residual time series	پارامترهای مدل تابع‌انتقال Parameters of the TF model			حوضه آبخیز Watershed
Correlation between the rainfall time series and the residuals	Correlation in the residual time series		s	r	b	
0.570	0.940	$(0, 0, 1) \times (0, 0, 2)_{12}$	2	2	1	زشک Zoshk
0.680	0.890	$(0, 0, 2) \times (0, 0, 2)_{12}$	2	2	1	دهبار Dehbar
0.800	0.940	$(0, 0, 2) \times (0, 0, 3)_{12}$	2	2	3	کارده Kardeh

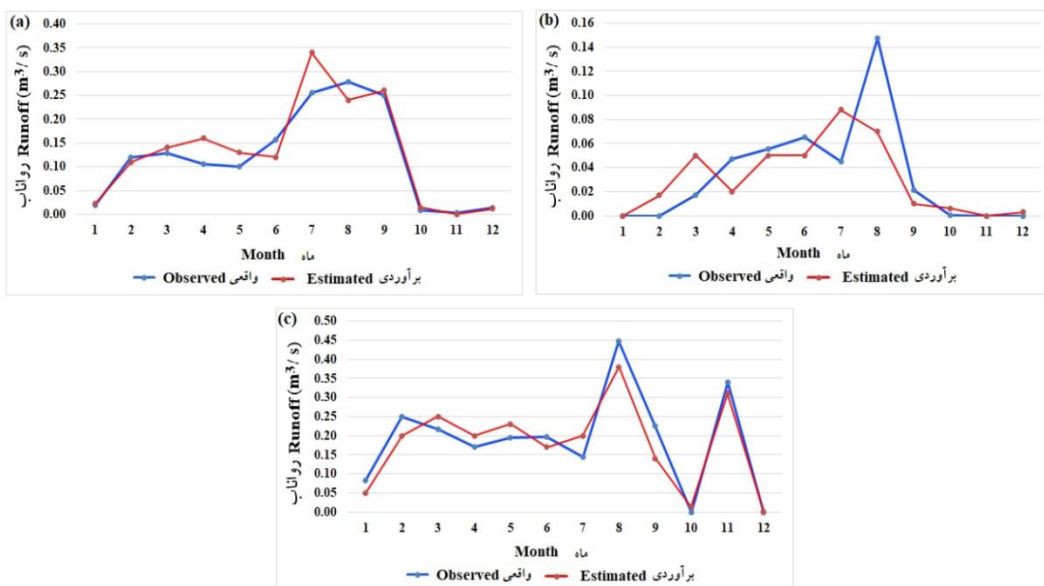
استفاده شد و بهترین مقدار چندک برای هر ماه مشخص گردید. شکل ۹ نمودار مقادیر رواناب واقعی و برآوردشده ماهانه توسط مدل QR را در سه حوضه آبخیز مورد بررسی در استان خراسان رضوی نشان می‌دهد.

در مرحله بعد اقدام به پیش‌بینی رواناب بر حسب بارش با استفاده مدل QR شد. برای این منظور، در ابتدا مدل QR به‌ازای چندک‌های ۰/۰۵ تا ۰/۹۵ با فواصل چندکی ۰/۰۵ برازش داده شد. برای پیش‌بینی ماه‌های آینده از مدل QR در چندک‌های مختلف



شکل ۸- نمودار مقایسه رواناب ماهانه واقعی و برآوردی توسط مدل TF در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 8. Comparison of observed and estimated monthly runoff using the TF model in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.



شکل ۹- نمودار مقایسه رواناب ماهانه واقعی و برآوردی توسط مدل QR در حوضه‌های آبخیز زشک (a)، دهبار (b) و کارده (c).

Figure 9. Comparison of observed and estimated monthly runoff using the QR model in the Zoshk (a), Dehbar (b), and Kardeh (c) watersheds.

کوتاری و همکاران (۲۷) هم‌راستا است؛ این مطالعات نیز به عمل‌کرد مطلوب شبکه‌های عصبی مصنوعی در مدل‌سازی سری‌های زمانی تأکید داشته‌اند.

پس از مدل MLP، مدل ANFIS بالاترین دقت را در پیش‌بینی مقادیر رواناب ماهانه در هر سه حوضه آبخیز مورد مطالعه نشان داد. مقدار خطای محاسبه‌شده برای مدل ANFIS بر اساس شاخص RMSE در حوضه‌های زشک، دهبار و کارده به ترتیب برابر با ۰/۰۱۴۶، ۰/۰۰۴۴ و ۰/۰۱۸۵ مترمکعب بر ثانیه بوده است. نتایج اعتبارسنجی بیانگر آن است که خروجی‌های مدل‌سازی رواناب ماهانه در دو روش MLP و ANFIS بسیار به یکدیگر نزدیک بوده و هر دو مدل در شناسایی روند تغییرات عمل‌کرد مطلوبی داشته‌اند. یافته‌های این پژوهش با نتایج مطالعات پیشین از جمله ابارشی و همکاران (۱)، حقی‌زاده و همکاران (۲۰)، قزل‌سفلی و همکاران (۱۴)، نظری و همکاران (۳۲)، سلامتیان و همکاران (۴۰)، گونال و همکاران (۱۸) و امپالاس و همکاران (۳۰) که همگی به دقت بالای مدل ANFIS در پیش‌بینی سری‌های زمانی و شباهت عمل‌کرد آن با مدل MLP اشاره داشته‌اند، هم‌راستا است. با این حال، یافته‌های این مطالعه با نتایج پژوهش‌های غفاری و وفاخواه (۱۳)، صادقیان و همکاران (۳۹) و بین‌سامی و همکاران (۷) که مدل ANFIS را نسبت به شبکه عصبی مصنوعی MLP مناسب‌تر گزارش کرده‌اند، هم‌خوانی ندارد.

با توجه به شکل ۹ می‌توان بیان نمود که مدل رگرسیون چندکی همانند سه مدل ANFIS، MLP و TF در مدل‌سازی، برازش و تشخیص روند تغییرات داده‌های بارش-رواناب ماهانه برای سه آبخیز مورد بررسی عمل‌کرد خوبی داشته است. در مدل رگرسیون چندکی نیز همانند سه مدل ANFIS، MLP و TF بیش‌برآوردی و کم‌برآوردی پیوسته که باعث کاهش عمل‌کرد مدل‌ها می‌شود، ملاحظه نشد. همچنین با توجه به مقایسه نمودارهای مدل‌سازی رگرسیون چندکی با سه مدل دیگر می‌توان به دقت پایین‌تر این مدل در مقایسه با دو مدل ANFIS و MLP پی برد اما با مدل TF تشابه بیش‌تری دارد.

سپس اعتبارسنجی مدل‌ها با استفاده از سه شاخص MAD، RMSE و R^2 انجام شد (جدول ۴). بر اساس نتایج ارائه‌شده در جدول ۴، مدل MLP در هر سه حوضه آبخیز زشک، دهبار و کارده بالاترین دقت را در پیش‌بینی مقادیر رواناب ماهانه بر اساس داده‌های بارش نشان داد. مطابق شاخص RMSE، مقادیر خطای محاسبه‌شده برای مدل MLP در حوضه‌های زشک، دهبار و کارده به ترتیب ۰/۰۰۳۲، ۰/۰۰۲۸ و ۰/۰۱۲۳ مترمکعب بر ثانیه بوده است. نتایج این مطالعه با یافته‌های پژوهش‌گران پیشین از جمله ابارشی و همکاران (۱)، فرودی‌صفت و همکاران (۱۱)، قزل‌سفلی و همکاران (۱۴)، پورمحمدی و انوری (۳۵)، نظری و همکاران (۳۲) و همچنین

جدول ۴- نتایج اعتبارسنجی مدل‌ها جهت پیش‌بینی رواناب ماهانه.

Table 4. Validation results of models to predict the monthly runoff.

نام مدل Model name				شاخص استاندارد	حوضه آبخیز
QR	TF	ANFIS	MLP	Standard indicators	Watershed
0.0344	0.0368	0.0146	0.0032	RMSE	زشک Zoshk
0.0241	0.0304	0.0131	0.0026	MAE	
0.8998	0.8865	0.9830	0.9992	R^2	
0.0293	0.0378	0.0044	0.0028	RMSE	دهبار Dehbar
0.0197	0.0293	0.0031	0.0020	MAE	
0.7191	0.07107	0.9923	0.9984	R^2	
0.0444	0.0510	0.0185	0.0123	RMSE	کارده Kardeh
0.0385	0.0434	0.0138	0.0016	MAE	
0.7880	0.8531	0.9814	0.9930	R^2	

داده‌اند. شاخص R^2 به‌عنوان یک معیار آماری، نسبت واریانس متغیر وابسته را که به‌وسیله متغیرهای مستقل مدل توضیح داده می‌شود، مشخص می‌کند. بر اساس مقادیر محاسبه‌شده این شاخص می‌توان نتیجه‌گیری کرد که در هر چهار مدل به‌کاررفته و در هر سه حوضه آبخیز، بخش قابل‌توجهی از واریانس متغیر وابسته به‌طور قابل‌قبولی توسط متغیرهای مستقل تبیین شده است. با وجود این، مقایسه عمل‌کرد مدل‌ها براساس تمامی شاخص‌ها نشان داد که از نظر دقت، مدل‌ها به‌ترتیب شامل روش‌های MLP، ANFIS، QR و در نهایت TF بوده‌اند.

نتیجه‌گیری

در این پژوهش، چهار مدل MLP، ANFIS، QR و TF برای پیش‌بینی رواناب ماهانه بر اساس داده‌های بارش در سه آبخیز زشک، دهبار و کارده در استان خراسان رضوی طی ۲۶ سال به‌کار گرفته شد. عمل‌کرد مدل‌ها با شاخص‌های RMSE، MAD و R^2 ارزیابی شد. تحلیل‌ها نشان داد سری‌های زمانی بارش و رواناب ساختار متفاوتی دارند و خودهمبستگی متقابل، ارتباط معنادار بارش و رواناب را با تأخیر حداکثر یک ماه در آبخیزهای زشک و دهبار و سه ماه در آبخیز کارده نشان داد.

به‌طورکلی، نتایج حاصل از ارزیابی سه شاخص عمل‌کرد نشان داد که دو مدل MLP و ANFIS از دقت بالایی در برازش و پیش‌بینی کوتاه‌مدت رواناب ماهانه بر اساس داده‌های بارش در منطقه مورد مطالعه برخوردار هستند. شایان ذکر است که به‌کارگیری فرآیند پیش‌رو و تعیین تعداد سال‌های مؤثر، نقش قابل‌توجهی در بهبود عملکرد این مدل‌ها ایفا کرده است. اگرچه دو مدل QR و TF نسبت به مدل‌های MLP و ANFIS دقت کم‌تری داشتند، اما در شناسایی روند تغییرات و پیش‌بینی رواناب عمل‌کرد

پس از مدل‌های MLP و ANFIS، مدل رگرسیون چندکی بالاترین دقت را در هر سه حوضه آبخیز مورد مطالعه نشان داد (جدول ۴). مقدار خطای محاسبه‌شده برای مدل QR براساس شاخص RMSE در حوضه‌های زشک، دهبار و کارده به‌ترتیب ۰/۰۳۴۴، ۰/۰۲۹۳ و ۰/۰۴۴۴ مترمکعب بر ثانیه بوده است. با توجه به نوسانات شدید بارش در استان خراسان رضوی، انتظار می‌رفت دقت مدل QR که برای مقادیر حدی (اکستریم) از رویکردهای متفاوتی نسبت به مقادیر میانی استفاده می‌کند، بالاتر باشد؛ با این حال، نتایج نشان داد که دقت این مدل در مقایسه با دو مدل MLP و ANFIS به‌طور محسوسی کم‌تر بوده است. یافته‌های این پژوهش با نتایج مطالعات میرزایی حسنلو و همکاران (۲۹)، فوتیوس و همکاران (۱۲)، عباس و همکاران (۲)، قربانی و همکاران (۱۵) و شریفی و محمدی‌قالنی (۴۳) که همگی به عمل‌کرد قابل‌قبول مدل QR در مدل‌سازی سری‌های زمانی تأکید کرده‌اند، هم‌راستا است.

مدل TF مشابه مدل QR، نتایج نسبتاً مطلوبی در شناسایی روند، ارزیابی دقت و کارایی مدل ارائه داده است؛ با این حال، در مقایسه با سه مدل دیگر، ضعیف‌ترین عمل‌کرد را نشان داده است. نتایج اعتبارسنجی بیان‌گر شباهت قابل‌توجه نتایج مدل‌سازی رواناب ماهانه بین دو روش TF و QR بوده است. براساس شاخص RMSE، مقادیر خطای محاسبه‌شده مدل TF در حوضه‌های آبخیز زشک، دهبار و کارده به‌ترتیب ۰/۰۳۶۸، ۰/۰۳۷۸ و ۰/۰۵۱۰ مترمکعب بر ثانیه بوده است. یافته‌های این مطالعه با نتایج پژوهش‌های جندقی و همکاران (۲۳)، ناظری و همکاران (۳۲) و ویلیام و همکاران (۴۶) که همگی بر عمل‌کرد قابل‌قبول مدل TF تأکید داشته‌اند، هم‌راستا است.

نتایج دو شاخص MAE و R^2 نیز کاملاً مشابه نتایج شاخص RMSE بوده و روند یکسانی را نشان

تقدیر و تشکر

نویسندگان قدردان پشتیبانی همه‌جانبه و فراهم آوردن زیرساخت‌های پژوهشی توسط دانشگاه گنبد کاووس هستند که بدون آن، انجام این مطالعه میسر نمی‌گردید.

داده‌ها و اطلاعات

داده‌های این پژوهش مربوط به پایان‌نامه فوق‌لیسانس نویسنده اول می‌باشد که با مکاتبه با نویسنده مسئول قابل دسترسی می‌باشند.

تعارض منافع

در این مقاله تعارض منافی وجود ندارد و این مسأله مورد تأیید همه نویسندگان است.

مشارکت نویسندگان

نویسنده اول: دسترسی به داده‌ها و داده‌برداری، آماده‌سازی داده‌ها، مشارکت در آنالیزها. نویسنده دوم: طرح پژوهش و روش‌شناسی، انجام محاسبات، مشارکت در آنالیزها. نویسنده سوم: اصلاح و نهایی‌سازی مقاله و مشارکت در آنالیزها. نویسنده چهارم: اصلاح و نهایی‌سازی مقاله و مشارکت در آنالیزها.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر عملی رعایت نموده‌اند و این موضوع مورد تأیید همه آن‌ها می‌باشد.

حمایت مالی

این پژوهش در قالب یک پایان‌نامه کارشناسی ارشد ذیل حمایت دانشگاه گنبد کاووس انجام شده است.

رضایت‌بخشی ارائه کردند. دقت پایین‌تر روش QR در پیش‌بینی سری‌های زمانی رواناب ماهانه نسبت به روش‌های شبکه عصبی ناشی از تغییرپذیری زیاد داده‌های مشاهده‌ای است. همچنین، عمل‌کرد ضعیف‌تر مدل TF در مقایسه با سایر روش‌ها به ساختار خطی و ساده این مدل مربوط می‌شود، زیرا این مدل توانایی لازم برای شناسایی و مدل‌سازی روابط غیرخطی میان متغیرها را ندارد. در هیچ‌یک از مدل‌های مورد استفاده، شواهدی از بیش‌برازش یا کم‌برازش سیستماتیک که می‌تواند منجر به کاهش دقت و کارایی مدل شود، مشاهده نشد. مدل TF از این نظر دارای اهمیت است که با شناسایی تأخیر میان اثرگذاری متغیرهای ورودی و خروجی، چارچوبی مناسب برای مدل‌سازی فرآیند محور بارش-رواناب فراهم می‌کند. بر این اساس، پیشنهاد می‌شود در پژوهش‌های آتی، از مدل TF به‌عنوان یک مدل مقدماتی جهت آموزش شبکه‌های عصبی بهره‌گیری شود تا امکان لحاظ‌کردن تأخیر زمانی میان سری‌های ورودی و خروجی در فرآیند پیش‌بینی فراهم گردد. علاوه‌براین، با توجه به مزیت مدل QR در ارائه پیش‌بینی‌های احتمالاتی و تعیین بازه‌های اطمینان به‌جای مقادیر نقطه‌ای، توصیه می‌شود در مطالعات آینده توجه بیشتری به مدل‌سازی احتمالاتی و تحلیل عدم قطعیت در پیش‌بینی سری‌های زمانی معطوف گردد. همچنین، استفاده از مدل‌های ترکیبی برای بهره‌گیری هم‌زمان از مزایای مدل‌های مختلف، در نظر گرفتن سناریوهای تغییر اقلیم برای ارزیابی اثرات احتمالی تغییر شرایط محیطی، و توسعه مدل‌ها با داده‌های سنجش‌ازدور برای پوشش مناطق با داده محدود، می‌تواند دقت پیش‌بینی، قابلیت تعمیم‌پذیری و کاربردپذیری مدل‌ها در مطالعات آینده را به‌طور چشم‌گیری بهبود بخشد.

منابع

1. Riazi, M., Bateni, S. M., Jun, C., Farooque, A. A., Khosravi, K., & Abolfathi, S. (2025). Enhancing rainfall-runoff simulation in data-poor watersheds: integrating remote sensing and hybrid decomposition for hydrologic modelling. *Water Resources Management*. **Doi:10.1007/s11269-025-04215-5 ISSN 0920-4741.**
2. Yan, J., Xu, T., Yu, Y., & Xu, H. (2021). Rainfall forecast model based on the TabNet model. *Water*, 13, 1272. **Doi.org/10.3390/w13091272.**
3. Zhang, X., Li, F., & Yuan, X. (2023). Assessment model of rainwater resource utilization and influencing factors in arid and semiarid areas. *Natural Resources Modeling*, 36(2), 1-25. **Doi.org/10.1111/nrm.12366.**
4. Gorganli Davaji, A., Jandaghi, N., G. Mahmoodlu, M., & Nick Ghogh, Y. (2021). Effect of natural flood spreading of March 2019 on the quantitative and qualitative characteristics of groundwater in floodplain at the end of Gorganroud basin. *Ecohydrology*, 8(2), 535-550. **Doi: 10.22059/ije.2021.320806.1483.** [In Persian]
5. Wang, Q., Sun, Y., Guan, Q., Du, Q., Zhang, Z., Zhang, J., & Zhang, E. (2024). Exploring future trends of precipitation and runoff in arid regions under different scenarios based on a bias-corrected CMIP6 model. *Journal of Hydrology*, 360, 130666. **Doi.org/10.1016/j.jhydrol.2024.130666.**
6. Rodríguez-Carrillo, J. A., González-Trinidad, J., Raul Ulices Silva-Avalos, R.U., Júnez-Ferreira, H. E., Moreno-Chavez, G., Robles-Rovelo, C. O., & Contreras-Rodríguez, A. R. (2025). Spatial rainfall estimation applying machine learning techniques in a semi-arid basin. *Hydroinformatics*, 27(1), 69-87. **Doi.org/10.2166/hydro.2024.253.**
7. Gu, J., Liu, S., Zhou, Z., Chalov, S., & Zhuang, Q. (2022). A stacking ensemble learning model for monthly rainfall prediction in the Taihu Basin, China, *Water*, 14, 492. **Doi.org/10.3390/w14030492.**
8. Kashiwao, T., Nakayama, K., Ando, S., Ikeda, K., Lee, M., & Bahadori, A. (2017). A neural network-based local rainfall prediction system using meteorological data on the internet: A case study using data from the Japan meteorological agency. *Applied Soft Computing*, 56, 317-330. **Doi.org/10.1016/j.asoc.2017.03.015.**
9. Afrifa, S., Zhang, T., Appiahene, P., & Varadarajan, V. (2022). Mathematical and machine learning models for groundwater level changes: A systematic review and bibliographic analysis. *Future Internet*, 14(9), 259. **Doi.org/10.3390/fi14090259.**
10. Liyew, C., & Melese, H. (2021). Machine learning techniques to predict daily rainfall amount. *Journal of Big Data*, 8, 1-11. **Doi.org/10.1186/s40537-021-00545-4.**
11. Besaw, L. E., Rizzo, D. M., Bierman, P. R., & Hackett, W. R. (2010). Advances in ungauged stream flow prediction using artificial neural networks. *Journal of Hydrology*, 1(4), 27-37. **Doi:10.1016/j.jhydrol.2010.02.037.**
12. Jandaghi, N., Azimmohseni, M., & Ghareh Mahmoodlu, M. (2021). Rainfall-runoff process modeling using time series transfer function. *Environmental Erosion Research Journal*, 11(2), 111-128. **Doi: 20.1001.1.22517812.1400.11.2.5.5.** [In Persian]
13. Weekaew, J., Ditthakit, P., Kittiphattanabawon, N., & Pham, Q. B. (2024). Quartile regression and ensemble models for extreme events of multi-time step-ahead monthly reservoir inflow forecasting. *Water*, 16(23), 3388. **Doi.org/10.3390/w16233388.**
14. Ghafari, G., & Vafakhah, M. (2013). Simulation of rainfall-runoff process using artificial neural network and adaptive neuro-fuzzy interface system

- (Case study: Hijighushan watershed). *Journal of Watershed Management*, 4(8), 120-136. <http://jwmr.sanru.ac.ir/article-1-321-fa.html>. [In Persian]
15. Abareshi, F., Meftah Halghi, M., Sanikhani, H., & Dehghani, A. A. (2014). Comparison of three intelligence techniques for predicting water table depth fluctuations (Case study: Zarringol plain). *Journal of Water and Soil Conservation*, 21(1), 163-180. **Doi: 20.1001.1.23222069.1393.21.1.9.4.** [In Persian]
 16. Haghizadeh, A., Mohammadlou, M., & Noori, F. (2015). Simulation of rainfall-runoff process using multilayer perceptron and adaptive neuro-fuzzy interface system and multiple regression (Case Study: Khorramabd Watershed). *Ecohydrology*, 2(2), 233-243. **Doi: 10.22059/ije.2015.56243.** [In Persian]
 17. Sadeghian, M., Karami, H., & Mousavi, S. F. (2020). Evaluating the performance of time-series, neural network and neuro-fuzzy models in prediction of meteorological drought (Case study: Semnan synoptic station). *Journal of Irrigation Sciences and Engeneering*, 43(2), 1-18. **Doi.org/10.22055/jise.2017.17729.1283.** [In Persian]
 18. Foroodi Safat, E., Ahmadi, M. M., Qaderi, K., & Golestani Kermani, S. (2021). Evaluation of two combined hydrological-black box models for flood forecasting in Halilrud river basin. *Ecohydrology*, 8(2), 397-402. **Doi: 10.22059/ije.2021.314315.1430.** [In Persian]
 19. Ghezelsofli, H., Jandaghi, N., Ghareh Mahmoodlu, M., Azimmohseni, M., & Seyedian, M. (2022). Modeling and forecasting of monthly runoff in the time domain (Case study: River basin Gharasou). *Environmental Erosion Research*, 12(3), 165-189. **Doi: 20.1001.1.22517812.1401.12.3.6.5.** [In Persian]
 20. Nazeri, Y., Jandaghi, N., Ghareh Mahmoodlu, M., & Azimmohseni, M. (2023). Relationship between rainfall and groundwater level using time-lagged regression. *Journal of Water and Soil Conservation*, 30(2), 27-49. **Doi: 10.22069/jwsc.2023.21111.3624.** [In Persian]
 21. Salamatian, S. A., Abrari, H., & Nazari, A. (2023). Predicting the groundwater level by adaptive neuro-fuzzy inference system (Case study: Qom plain). *Journal of Irrigation Sciences and Engeneering*, 13(3), 285-304. **Doi: 10.22125/iwe.2023.169890.** [In Persian]
 22. Poormohammadi, S., & Anvari, S. (2024). Forecasting runoff using statistical methods, artificial intelligence, and meteorological models (Case study: Amirkabir Dam). *Water and Soil Management and Modeling*, 4(2), 105-120. **Doi:10.22098/mmws.2023.12217.1210.** [In Persian]
 23. Mirzaei Hassanlu, A., Erfanian, M., Javan, K., & Najafi, M. R. (2024). Trend Analysis of Precipitation Extreme Indices in Iran Based on Quantile Regression Model. *Environment and Water Engineering*, 10(4), 541-557. **Doi.org/10.22034/ewe.2024.441177.1912.** [In Persian]
 24. Mpallas, L., Tzimopoulos, C., & Evangelidis, C. (2010). Rainfall data calculation using artificial neural networks and adaptive neuro-fuzzy inference systems. *WIT Transactions on Ecology and the Environment*, 134, 133-144. **Doi: 10.2495/SI100121.**
 25. Fotios, M., Kitikidou, K., Paparrizos, S., & Potouridis, S. (2014). Stream flow quantile regression modelling using land use information in the Sperchios River basin (Central Greece). *Carpathian Journal of Earth and Environmental Sciences*, 9(1), 5-10.
 26. Abbas, S. A., Xuan, Y., & Song, X. (2019). Quantile regression based methods for investigating rainfall trends associated with flooding and drought conditions. *Water Resources Management*, 33, 4249-4264. **Doi.org/10.1007/s11269-019-02362-0.**
 27. Willem, J. Z., Stefanie, A. R. B., Aris, L., & Wilbert, L. B. (2019). Automated time series modeling for piezometers in the national database of the Netherlands.

- Groundwater*, 57(6), 834-843. **Doi.org/10.1111/gwat.12819.**
28. Bin Sami, S., Siddiqi, T.A., & Iqbal, M. J. A. (2019). Neuro-fuzzy modeling for the hydrological time series of floods of River Indus of Pakistan. *International Journal of Hydrology*, 3(2), 138-147. **Doi:10.15406/ijh.2019.03.00175.**
 29. Kothari, M., & Gharde, K. D. (2019). Application of ANN and Fuzzy logic algorithms for streamflow modelling of Savitri catchment. *Indian Academy of Sciences*, 124(5), 933-943. **Doi: 10.1007/s12040-015-0592-7.**
 30. Ghorbani, K., Salarijazi, M., Bararkhanpour, S., & Rezaei Ghaleh, L. (2023). Comparison of bayesian and frequentist quantile regressions in studying the trend of discharge changes in several hydrometric stations of the Gorganroud basin in Iran. *Journal of Water and Climate Change*. 14(10), 3753-3769. **Doi.org/10.2166/wcc.2023.305.**
 31. Gunal, A. Y., & Mehdi, R. (2023). Prediction of runoff coefficient under effect of climate change using Adaptive Neuro Inference System. *Journal of University of Babylon for Engineering Sciences*, 31(4), 261-40.
 32. Sharifi, S., & Mohammadi Ghalehi, M. (2024). Revealing accuracy in climate dynamics: enhancing evapotranspiration estimation using advanced quantile regression and machine learning models. *Applied Water Science*, 14, 162. **Doi.org/10.1007/s13201-024-02211-5.**
 33. Shamkoueyan, H., Davary, K., & Fereshteh Poor, M. (2023). Assessing flood susceptibility by adopting remote sensing techniques and fuzzy-AHP method (Case study: Zoshk watershed, Shandiz). *Iranian Water Research Journal*, 16(4), 11-22. **Doi:10.22034/iwrj.2022.13882.2401.** [In Persian]
 34. Poursoltani, M., Kazemi Zanjani Lotfabadi, N., & Fazel Valipour, M. (2020). The effect of sedimentary units on composition and quality of water: an example from the Kardeh catchment, northeast of Mashhad, Iran. *Sedimentary Facies*, 12(1), 35-53. **Doi; magiran.com/p2150105.** [In Persian]
 35. Nafarzadegan, A. R., Mohammadifar, A. A., Vagharfard, H., & Foruzanfard, M. (2019). Integration of multi-criteria decision-making models and regional flood analysis technique for sub-basin prioritization in flood control (Case study: Dehbar watershed, Khorāsān). *Geography & Environmental Hazards*, 8(2), 27-45. **Doi:10.22067/geo.v0i0.76607.** [In Persian]
 36. Farooq, M. U., Khan, H., Arshad, M., Usama, M., Khan, M. I., Hussain, S., & Hamid, A. (2024). Unveiling the biosorption performance of silk fibroin fiber for Pb (II) and Cr (VI) removal: Machine learning and DFT analysis. *Journal of Water Process Engineering*, 68, 106312. **Doi.org/10.1016/j.jwpe.2024.106312.**
 37. Heaton, J. Goodfellow, J., Bengio, Y., & Courville, A. (2018). Deep learning. *Genet Program Evolvable Mach*. 19, 305-307. **Doi.org/10.1007/s10710-017-9314-z.**
 38. Isik, H., & Akkan, T. (2024). Water quality assessment with artificial neural network models: performance comparison between SMN, MLP and PS-ANN methodologies. *Arabian Journal for Science and Engineering*, 50, 369-387. **Doi.org/10.1007/s13369-024-09238-5.**
 39. Sarafaraz, J., Kaleybar, F. A., Karamjavan, J. M., & Habib-zadeh, N. (2024). Predicting river water quality: An imposing engagement between machine learning and the QUAL2Kw models (Case study: Aji-Chai, river, Iran). *Results in Engineering*, 21, 101921. **Doi.org/10.1016/j.rineng.2024.101921.**
 40. Xu, J., Mo, Y., Zhu, S., Wu, J., Jin, G., Wang, Y. G., Ji, Q., & Li, L. (2024). Assessing and predicting water quality index with key water parameters by machine learning models in coastal cities, China. *Heliyon*, 10, e33695. **Doi.org/10.1016/j.heliyon.2024.e33695.**

41. Khan, M. Z., & Khan, M. F. (2019). Application of ANFIS, ANN and fuzzy time series models to CO₂ emission from the energy sector and global temperature increase. *International Journal of Climate Change Strategies and Management*, 11(5), 622-642. **Doi.org/10.1108/IJCCSM-01-2019-0001.**
42. Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European journal of operational research*, 160(2), 501-514. **Doi.org/10.1016/j.ejor.2003.08.037.**
43. Abraham, A. (2005). Adaptation of fuzzy inference system using neural learning, in Nedjah, Nadia; de Macedo Mourelle, Luiza (eds.), *Fuzzy systems engineering: theory and practice, studies in fuzziness and soft computing*, Vol. 181, Germany: Springer Verlag, 53-83, **Doi: 10.1007/11339366_3.**
44. Ordenshiya, K. M., & Revathi, G. K. (2025). A comparative study of traditional machine learning and hybrid fuzzy inference system machine learning models for air quality index forecasting. *International Journal of Data Science and Analytics*, **Doi.org/10.1007/s41060-025-00720-3.**
45. Mualla, K. G. (2024). ANFIS based reference evapotranspiration (ETO) estimation using limited and different climate parameters. *Agricultural Water Management*, 8(4), 1022-1033. **doi.org/10.5281/zenodo.13761632.**
46. Jin, X. B., Wang, J. F., Zhang, H. Y., & Cao, L. H. (2013). ANFIS model for time series prediction. *In Applied Mechanics and Materials*, 385, 1411-1414. Trans. Tech. Publications Ltd. **Doi:10.4028/www.scientific.net/AMM.385-386.1411.**
47. Guo, M., Wu, F., Fan, Z., Lu, H., & Rao, R. (2024). Parametric Analytical Modulation Transfer Function Model in Turbid Atmosphere with Application to Image Restoration. *Remote Sensing*, 16(21), 3998. **Doi.org/10.3390/rs16213998.**
48. Ding, R., Yang, C., Mei, R., Yang, H., Ji, J., & Shi, Q. (2023). Research on simplified modeling of large-scale wind farms based on equivalent transfer function and aggregate equivalent. *Frontiers in Energy Research*, 10, 1098025. **Doi: 10.3389/fenrg.2022.1098025.**
49. Bowerman, B. L., & O'Connell, R. (1993). *Forecasting and time series: An applied approach*, Third edition, Amazon Publication, 722 p.
50. Esen, Ö., Yıldırım, D. Ç., & Yıldırım, S. (2024). A quantile regression approach to assess the impact of water-related environmental innovations on water stress. *Technological Forecasting and Social Change*, 203, 123343. **Doi.org/10.1016/j.techfore.2024.123343.**
51. Xu, M. (2023). Quantile regression model and its application research. *Academic Journal of Science and Technology*, 8(3), 172-176. **Doi: https://doi.org/10.54097/vt1qpm59.**
52. Yu, S., Qin, H., & Ding, W. (2023). Modeling the effects of vegetation dynamics on the hydrological performance of a bioretention system. *Journal of Hydrology*, 620, Part B, 129473. **Doi.org/10.1016/j.jhydrol.2023.129473.**