

Relationship between rainfall and groundwater level using time-lagged regression

Youl Aman Nazeri¹, Nader Jandaghi^{*2}, Mojtaba Ghareh Mahmoodlu³,
Majid Azimmohseni⁴

1. M.Sc. Graduate in Watershed Management, Dept. of Rangeland and Watershed Management, Faculty of Agriculture and Natural Resources, University of Gonbad Kavous, Iran. E-mail: attasadi4@gmail.com
2. Corresponding Author, Assistant Prof. in Engineering Hydrology, Dept. of Rangeland and Watershed Management, Faculty of Agriculture and Natural Resources, University of 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, University of 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: 02.22.2023
Revised: 05.31.2023
Accepted: 06.07.2023

Keywords:
ANFIS,
Artificial Neural Network,
Groundwater Level,
Rainfall,
Transfer Function

ABSTRACT

Background and Objectives: In Iran, the climatic conditions are such that even in the rainiest areas of the country, there is a need for groundwater resources, and this demand is increasing every year. Since, groundwater is one of the most valuable water resources in Iran, it is very necessary to predict its changes in order to use it optimally with the aim of sustainable development. One of the most complex hydrological processes in nature is the rainfall-groundwater level process, which is affected by various physical and hydrological parameters. Although, various models have been presented to predict the changes in the groundwater level using the rainfall patterns, but less attention has been paid to the transfer function model. Hence, the main objective of this research is to introduce and use the transfer function (TF) model to predict the monthly groundwater level using rainfall data and to compare its results with ANFIS and Artificial Neural Network (ANN) models.

Material and Methods: In the present study, 30-year data (1992-2021) of meteorological stations and observation wells in three watersheds of Galikesh, Ramian and Mohamadabad were used to model the rainfall and groundwater level. These watersheds are located in the eastern, central and western branches, of the Gorganroud river basin, respectively. Since, monthly rainfall and groundwater level data are time-dependent, these data were first arranged as time series. Then, considering that the years closer to the present time have more accurate information about the situation of this time, the years were considered as a forward process in artificial neural networks. The model fitting and prediction of the groundwater level values using rainfall data for the next 12 months was performed with applying three models: Artificial Neural Network (ANN), Adaptive neuro fuzzy inference system (ANFIS), and transfer function (TF). For this purpose, MINITAB SAS, SPSS, and R software were used. Next step, the validation of the values predicted by the models was evaluated using three indices Mean Absolute Distance (MAD), Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE).

Results: The results of the autocorrelation plots of the groundwater level of the wells revealed that all time series have a seasonal trend with a period of

12 months. Based on the cross-correlation plots, it was also found that rainfall has direct effect on the groundwater level in the two watersheds of Galikesh and Mohamadabad with lag time of three months and in the Ramian watershed with a delay of one month. The validation results of the models using three indexes MAD, RMSE and MAPE revealed that the artificial neural network model for predicting the groundwater level using monthly rainfall data in all three investigated watersheds had the most appropriate performance (RMSE=0.0778, 0.0243, 0.0532m) and the ANFIS model is ranked as second (RMSE=0.1841, 0.0832, 0.1012m). Although the transfer function model was less accurate than the other two methods (RMSE=0.5711, 0.5023, 0.3234m), this model has performed well in fitting the monthly groundwater level values. This model is very effective in identifying the delay in the impact between the input and output variables, as well as expressing the model based on which the impact of rainfall can be expressed as a model.

Conclusion: The results of this research showed that all three models of artificial neural network, ANFIS and transfer function can be used to predict the groundwater level using monthly rainfall values. Consecutive overestimation and underestimation, which increases the error and decreases the performance of the models, was not observed for the models. Also, all models perform well in detecting trends and data changes. However, the artificial neural network model is more accurate than the other models. In addition, when forward process is used in artificial neural network modeling, compared to the case where the complete series of data is used, the efficiency of the model was significantly improved.

Cite this article: Nazeri, Youl Aman, Jandaghi, Nader, Ghareh Mahmoodlu, Mojtaba, Azimmohseni, Majid. 2023. Relationship between rainfall and groundwater level using time-lagged regression. *Journal of Water and Soil Conservation*, 30 (2), 27-49.



© The Author(s).

DOI: 10.22069/jwsc.2023.21111.3624

Publisher: Gorgan University of Agricultural Sciences and Natural Resources

ارتباط بین بارش و تراز آب زیرزمینی با استفاده از رگرسیون تاخیر زمانی

یول آمان ناظری^۱، نادر جندقی^{۲*}، مجتبی قره‌محمودلو^۳، مجید عظیم محسنی^۴

۱. دانش‌آموخته کارشناسی ارشد آبخیزداری، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، ایران. رایانامه: attasadi4@gmail.com
۲. نویسنده مسئول، استادیار هیدرولوژی مهندسی، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه گنبد کاووس، ایران. رایانامه: nader.jandaghi@gmail.com
۳. دانشیار هیدروژئولوژی زیست‌محیطی، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه 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: در کشور ایران شرایط اقلیمی به‌گونه‌ای است که حتی در پرباران‌ترین مناطق کشور، به منابع آب زیرزمینی نیاز است و همه ساله این نیاز بیش‌تر می‌شود. از آنجا که آب‌های زیرزمینی یکی از ارزشمندترین منابع آب در کشور ایران به‌شمار می‌روند، پیش‌بینی تغییرات آن به منظور بهره‌برداری بهینه با هدف توسعه پایدار بسیار ضرورت است. یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی در طبیعت، فرآیند بارش-تراز آب زیرزمینی است که متأثر از پارامترهای مختلف فیزیکی و هیدرولوژیکی است. اگرچه مدل‌های مختلفی برای پیش‌بینی تغییرات تراز آب زیرزمینی با استفاده از الگوی بارش ارائه شده است اما به مدل تابع انتقال کم‌تر توجه شده است. از این‌رو هدف اصلی این پژوهش معرفی و استفاده از مدل تابع انتقال جهت پیش‌بینی تراز آب زیرزمینی ماهانه با استفاده از آمار بارش و مقایسه نتایج آن با مدل‌های شبکه عصبی- فازی و شبکه عصبی مصنوعی می‌باشد.
تاریخ دریافت: ۰۱/۱۲/۰۳ تاریخ ویرایش: ۰۲/۰۳/۱۰ تاریخ پذیرش: ۰۲/۰۳/۱۷	مواد و روش‌ها: در پژوهش حاضر از آمار ۳۰ ساله (۱۴۰۰-۱۳۷۱) ایستگاه‌های هواشناسی و چاه‌های مشاهده‌ای در ۳ حوضه آبخیز گالیکش، رامیان و محمدآباد جهت مدل‌سازی بارش-تراز آب زیرزمینی استفاده شد. این حوضه‌های آبخیز به ترتیب در سرشاخه‌های شرقی، مرکزی و غربی حوضه آبریز گرگانرود واقع شده‌اند. از آنجا که مقادیر بارش و تراز آب زیرزمینی ماهانه وابسته به زمان هستند، در ابتدا این داده‌ها به صورت سری زمانی مرتب شد. سپس، با توجه به این‌که سال‌های نزدیک‌تر به زمان حال اطلاعات دقیق‌تری از وضعیت این زمان دارند، سال‌ها به صورت فرآیند پیش‌رو در شبکه‌های عصبی مصنوعی در نظر گرفته شد. برازش مدل
واژه‌های کلیدی: بارش، تابع انتقال، تراز آب زیرزمینی، شبکه عصبی- فازی، شبکه عصبی مصنوعی	

و پیش‌بینی مقادیر تراز آب زیرزمینی با استفاده از داده‌های بارش برای ۱۲ ماه آینده به کمک سه مدل شبکه عصبی مصنوعی (ANN)، شبکه عصبی - فازی (ANFIS) و تابع انتقال (TF) انجام شد. برای این منظور از نرم‌افزارهای SAS، MINITAB، SPSS و R استفاده شد. در مرحله بعد اعتبارسنجی مقادیر پیش‌بینی شده توسط مدل‌ها با استفاده از ۳ شاخص میانگین قدرمطلق فاصله (MAD)، ریشه مربع میانگین خطا (RMSE) و میانگین قدرمطلق درصد خطا (MAPE) مورد ارزیابی قرار گرفت.

یافته‌ها: نتایج حاصل از نمودارهای خودهمبستگی نگار تراز آب زیرزمینی چاه‌ها نشان داد، تمامی سری‌های زمانی دارای روند فصلی با دوره ۱۲ ماهه هستند. بر اساس نمودارهای خودهمبستگی متقابل نیز مشخص شد که اثر مستقیم بارش بر تراز آب زیرزمینی در دو حوضه آبخیز گالیکش و محمدآباد با تاخیر ۳ ماهه و در حوضه آبخیز رامیان با تاخیر یک ماهه انجام شده است. نتایج اعتبارسنجی مدل‌ها با کمک ۳ شاخص MAD، RMSE و MAPE نشان داد که مدل شبکه عصبی مصنوعی جهت پیش‌بینی تراز آب زیرزمینی با استفاده از داده‌های بارش ماهانه در هر ۳ حوضه آبخیز مورد بررسی دارای مناسب‌ترین عملکرد می‌باشد (RMSE=۰/۰۷۷۸، ۰/۰۲۴۳، ۰/۰۵۳۲ m) و مدل شبکه عصبی - فازی (RMSE=۰/۱۰۱۲ m، ۰/۰۸۳۲، ۰/۱۸۴۱) در رتبه دوم قرار دارد. اگرچه مدل تابع انتقال نسبت به دو روش دیگر دقت کم‌تری داشت (RMSE=۰/۳۲۳۴، ۰/۵۰۲۳، ۰/۵۷۱۱). اما این مدل در برازش مقادیر تراز آب زیرزمینی ماهانه عملکرد مناسبی داشته است. این مدل در شناسایی تاخیر در تأثیرگذاری بین متغیرهای ورودی و خروجی و همچنین بیان مدلی که می‌توان بر اساس آن نحوه اثرگذاری بارش را به صورت یک مدل بیان کرد، بسیار مؤثر است.

نتیجه‌گیری: نتایج این پژوهش نشان داد که برای پیش‌بینی تراز آب زیرزمینی با کمک مقادیر بارش ماهانه، می‌توان از هر ۳ مدل شبکه عصبی مصنوعی، شبکه عصبی - فازی و تابع انتقال استفاده کرد. برای ۳ مدل مورد استفاده بیش‌برآوردی و کم‌برآوردی پیوسته که باعث افزایش خطا و کاهش عملکرد مدل‌ها می‌شود، مشاهده نشد. همچنین هر ۳ مدل در تشخیص روندها و تغییرات داده‌ها عملکرد مناسبی دارند. با این وجود عملکرد مدل شبکه عصبی مصنوعی نسبت به دو مدل دیگر از دقت بالاتری برخوردار است. علاوه بر این هنگامی که از عملکرد پیش‌رو در مدل‌سازی شبکه عصبی مصنوعی استفاده می‌شود نسبت به حالتی که از سری کامل داده‌ها استفاده می‌شود، کارایی مدل به نحو چشمگیری بهبود می‌یابد.

استناد: ناظری، یول آمان، جندقی، نادر، قره‌محمودلو، مجتبی، عظیم محسنی، مجید (۱۴۰۲). ارتباط بین بارش و تراز آب زیرزمینی با استفاده از رگرسیون تاخیر زمانی. *پژوهش‌های حفاظت آب و خاک*، ۳۰ (۲)، ۲۷-۴۹.

DOI: 10.22069/jwsc.2023.21111.3624



© نویسندگان

ناشر: دانشگاه علوم کشاورزی و منابع طبیعی گرگان

مقدمه

اهمیت آب‌های زیرزمینی و مدیریت آن به‌عنوان یکی از مهم‌ترین منابع تأمین آب شیرین در مناطق خشک و نیمه‌خشک مانند کشور ایران امری ضروری و حیاتی است. سطح ایستابی تحت‌تأثیر پارامترهای مختلفی از جمله میزان بارش، تبخیر و تعرق، دما، رطوبت هوا، الگوی کشت، میزان تغذیه از منابع آبی و پارامترهای منطقه‌ای مانند میزان نفوذپذیری خاک، توانایی نگهداری آب و برداشت از منابع زیرزمینی در حال تغییر است. در میان عناصر اقلیمی، بارش بیش‌ترین نوسان را داشته و سیستم‌های آبی زیرزمینی عمدتاً تحت‌تأثیر الگوهای بارش در یک منطقه قرار دارند. در حوضه‌های بسیار نفوذپذیر، سیستم‌های آبی زیرزمینی به سرعت نسبت به افزایش بارش واکنش نشان داده و سطح آب زیرزمینی افزایش می‌یابد (۱). از سوی دیگر، دخالت‌های طبیعی و انسانی، این ارتباط را تغییر داده و الگوی غیرمنتظره‌ای را ایجاد می‌کند. در چنین شرایطی، درک ارتباط بین بارش و سطح آب زیرزمینی مشابه آنچه که بین بارندگی و رواناب در رودخانه‌ها مشاهده می‌شود، مشکل است (۲).

در کشور ایران شرایط اقلیمی به‌گونه‌ای است که حتی در پرباران‌ترین مناطق کشور، به منابع آب زیرزمینی نیاز است و همه ساله این نیاز بیشتر می‌شود، به‌ویژه این‌که در زمان وقوع خشکسالی‌ها مسائل و مشکلات ناشی از آن‌ها افزایش می‌یابد. آب‌های زیرزمینی ارزشمندترین منابع آب در کشور ایران به‌شمار می‌روند، بنابراین شناخت و پیش‌بینی تغییرات این منابع به منظور تدوین برنامه بهره‌برداری بهینه با هدف توسعه پایدار به‌خصوص در مناطق خشک و نیمه‌خشک بسیار ضرورت دارد. بدین منظور یافتن تأثیرات بارندگی و بررسی تغییرات آن بر سطح آب‌های زیرزمینی ضروری است (۳).

از آن‌جا که روابط بین سری‌های زمانی ممکن است به صورت هم‌زمان نباشد و با تأخیر زمانی همراه باشد، برای بیان این ارتباط به مدل‌هایی نیاز است که بتوان علاوه بر در نظر گرفتن زمان‌های گذشته متغیر پاسخ، زمان‌های حال و گذشته سری زمانی پیش‌بینی‌کننده را در مدل در نظر بگیرد. رگرسیون تأخیر زمانی همه مدل‌ها چه خطی و چه غیرخطی را شامل شده که می‌تواند این روابط را در نظر بگیرد (۴). مدل تابع انتقال (TF) یک مدل خطی تأخیر زمانی می‌باشد که در این پژوهش به همراه ۲ مدل تأخیری دیگر شامل شبکه عصبی مصنوعی (ANN) و مدل ترکیبی شبکه‌های عصبی- فازی (ANFIS) برای پیش‌بینی با دقت بالا استفاده شده شد (۵، ۶، ۷ و ۸).

محتشم و همکاران (۲۰۱۷) جهت پیش‌بینی تراز آب زیرزمینی در دشت بیرجند بیان نموده‌اند که استفاده از مدل شبکه عصبی مصنوعی جهت پیش‌بینی تراز آب زیرزمینی برای ۱۲ ماه آینده نسبت به سایر روش‌ها از دقت بالاتری برخوردار است (۹). مختاری و همکاران (۲۰۱۳) در پیش‌بینی تراز آب زیرزمینی دشت شبستر نتیجه گرفتند که با استفاده از مدل شبکه عصبی مصنوعی می‌توان مقادیر تراز آب زیرزمینی ماهانه را برای ۳ سال آینده با دقت مناسبی پیش‌بینی نمود (۱۰). ابارشی و همکاران (۲۰۱۴) جهت پیش‌بینی نوسانات تراز آب زیرزمینی در حوضه زرین‌گل واقع در استان گلستان از سه مدل شبکه عصبی مصنوعی، عصبی- فازی و بیان ژن استفاده کردند. نتایج آن‌ها نشان داد که هر ۳ مدل به طور موفقیت‌آمیزی توانسته‌اند تراز آب زیرزمینی را پیش‌بینی کند به طوری‌که در بهترین حالت اجرای مدل برای روش برنامه‌ریزی ژن، بالاترین مقدار ضریب تعیین برای هر ۳ چاه مورد بررسی بالای ۰/۸ تعیین شد (۱۱). سعیدی رضوی و عرب (۲۰۱۹) در پیش‌بینی

بوئین بیان نمودند اثر ریزش‌های جوی با تاخیر ۳ ماهه صورت گرفته است (۱۷). آموتها و پورچلوان (۲۰۱۱) جهت پیش‌بینی فصلی تراز آب زیرزمینی در کشور هند از دو مدل شبکه عصبی و ANFIS استفاده کردند. نتایج نشان داد که هر دو مدل قادر به پیش‌بینی تراز آب زیرزمینی با دقت کافی هستند با این حال، عملکرد مدل ANFIS مناسب‌تر بوده است (۱۸). امامقلی‌زاده و همکاران (۲۰۱۴) جهت پیش‌بینی تغییرات تراز آب زیرزمینی در دشت بسطام از مدل‌های ANN و ANFIS استفاده کردند. نتایج نشان داد هر دو مدل ANN و ANFIS توانایی پیش‌بینی تراز آب زیرزمینی را با دقت بالا دارند با این وجود مدل ANFIS عملکرد مناسب‌تری داشته است (۱۹). لوهانی و کریشان (۲۰۱۵) جهت مدل‌سازی بارش و تراز آب زیرزمینی ماهانه در هند از مدل شبکه عصبی مصنوعی استفاده نمودند. این داده‌ها با گام زمانی یک ماهه به‌عنوان ورودی به مدل شبکه عصبی مصنوعی معرفی شدند. نتایج نشان داد که بهترین و مناسب‌ترین پیش‌بینی را می‌توان با یک شبکه عصبی پیش‌رو استاندارد به‌دست آورد (۲۰). رشیدی و همکاران (۲۰۱۶) جهت پیش‌بینی تغییرات تراز آب زیرزمینی در دشت لیلخ از مدل‌های شبکه عصبی مصنوعی ANN و ANFIS استفاده کردند. نتایج نشان داد مدل دینامیکی ANN با سه پارامتر ورودی، دارای پیش‌بینی دقیق‌تری برای تغییرات تراز آب زیرزمینی بوده است (۲۱). موهاناساندرام و همکاران (۲۰۱۷) جهت مدل‌سازی نوسانات آب زیرزمینی بر اساس داده‌های بارش از مدل تابع انتقال وزنی استفاده نمودند. نتایج نشان داد استفاده از رویکرد وزنی در تابع انتقال به طور قابل‌ملاحظه‌ای دقت مدل را برای سناریوهای مختلف افزایش می‌دهد (۲۲). ویلیام و همکاران (۲۰۱۹) در مدل‌سازی اتوماتیک سری‌های زمانی برای پیرومترها در کشور

سطح آب زیرزمینی با استفاده از مدل‌های منطق فازی، شبکه عصبی و سری زمانی در دشت عجب‌شیر دریافتند مدل منطق فازی می‌تواند تراز سطح ایستابی را با دقت قابل‌قبولی پیش‌بینی نماید (۱۲). جندقی و همکاران (۲۰۲۱) جهت پیش‌بینی و مدل‌سازی فرآیند بارش و رواناب در استان گلستان از دو مدل SARIMA و تابع انتقال استفاده کردند. نتایج نشان داد مدل تابع انتقال دقت پیش‌بینی را تا دو برابر نسبت به مدل SARIMA افزایش داده است (۱۳). جندقی (۲۰۲۲) جهت مدل‌سازی تراز آب زیرزمینی در حوضه آبریز گرگانرود در استان گلستان از مدل شبکه عصبی مصنوعی استفاده نمود. نتایج نشان داد مقادیر پیش‌بینی شده توسط مدل در مقایسه با داده‌های مشاهداتی دارای عملکرد بسیار مناسبی بوده است (۱۴). قزل‌سغلی و همکاران (۲۰۲۲) جهت مدل‌سازی رواناب ماهانه، از ۴ روش باکس و جنکینز (SARIMA)، شبکه عصبی مصنوعی (ANN)، شبکه عصبی مصنوعی- فازی (ANFIS) و الگوریتم ژنتیک (GA) در ایستگاه‌های هیدرومتری حوضه آبریز قره‌سو استفاده کردند. برای بررسی ساختار شبکه عصبی مصنوعی از عملکرد پیش‌رو استفاده شد. نتایج نشان داد که دو مدل شبکه عصبی مصنوعی و شبکه عصبی- فازی به ترتیب دارای بهترین عملکرد بوده است (۱۵). جندقی (۲۰۲۳) در مدل‌سازی بارش ماهانه با استفاده از شبکه عصبی مصنوعی از فرآیند پیش‌رو استفاده و نتایج آن را با زمانی که سری کامل داده‌ها وارد مدل شده بودند، مقایسه کرد. نتایج نشان داد هنگامی که از فرآیند پیش‌رو (RMSE=1/2434 mm) استفاده شود، عملکرد مدل نسبت به ورود سری کامل داده‌ها (RMSE=5/61 mm) بهبود قابل‌ملاحظه‌ای یافته است (۱۶).

اسلامیان و همکاران (۲۰۰۹) با بررسی اثر تغییرات بارش بر منابع آب‌های زیرزمینی در دشت

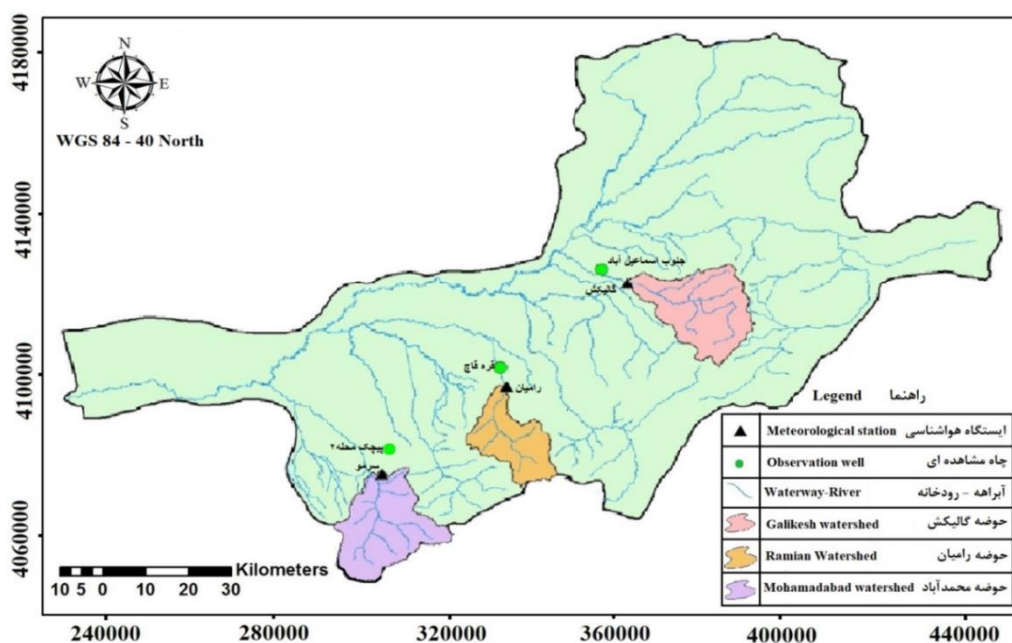
مدل تابع انتقال جهت پیش‌بینی تراز آب زیرزمینی ماهانه با استفاده از آمار بارش و مقایسه نتایج آن با مدل‌های شبکه عصبی-فازی و شبکه عصبی مصنوعی (با استفاده از الگوریتم پیش‌رو برای تعیین تعداد سال‌های مؤثر) در سرشاخه‌های حوضه آبریز گرگانرود در استان گلستان می‌باشد.

مواد و روش‌ها

حوضه آبریز گرگانرود اصلی‌ترین حوضه آبریز در استان گلستان محسوب شده که دارای بیش‌ترین مساحت و آبدهی می‌باشد. طول رودخانه اصلی این حوضه ۳۳۳ کیلومتر با امتداد شرقی- غربی بوده و ۶۷ درصد از منابع آب سطحی استان معادل ۸۲۸ میلیون مترمکعب در این حوضه جریان دارد (۲۵). در این پژوهش به منظور بررسی ارتباط بین بارش و تراز آب زیرزمینی، سه زیرحوضه از سرشاخه‌های آبریز گرگانرود شامل گالیکش، محمدآباد و رامیان مطابق شکل ۱ انتخاب شدند. در محدوده هر حوضه آبخیز یک ایستگاه باران‌سنجی تعیین شد. هم‌چنین در خروجی هر زیرحوضه، یک چاه که معرف تغییرات تراز آب زیرزمینی می‌باشد مشخص شد. در این پژوهش پس از بررسی آمار بارندگی ایستگاه‌های هواشناسی و هم‌چنین تراز آب زیرزمینی چاه‌های موجود در محدوده مورد مطالعه، دوره آماری مشترک ۳۰ ساله (۱۴۰۰-۱۳۷۱) انتخاب و داده‌های موردنظر به‌صورت ماهانه از شرکت سهامی آب منطقه‌ای گلستان تهیه شد.

هلند، جهت استخراج توابع پاسخ تکانه‌ای در دامنه فرکانس مقادیر بارش و تبخیر برای هر پیرومتر از مدل تابع انتقال استفاده نموده‌اند. نتایج نشان داد الگوهای فضایی ویژگی‌های توابع پاسخ تکانه‌ای می‌تواند در تجزیه و تحلیل سیستم آب زیرزمینی مؤثر باشد (۲۳). سالم (۲۰۲۱) در پیش‌بینی مقادیر بارش ماهانه بر اساس مدل تابع انتقال با چند ورودی (رطوبت و دمای متوسط ماهانه) در عربستان سعودی، بیان نمود که برای این نوع خاص از داده‌ها، مدل‌های تابع انتقال عملکرد بسیار مؤثری داشته است (۲۴). نتایج بررسی‌های انجام شده بیانگر دقت متفاوت مدل‌های مورد استفاده در مناطق مختلف بوده که با توجه به تفاوت نوع داده‌های ورودی و خروجی و هم‌چنین طول دوره آماری آن‌ها، منطقی به نظر می‌رسد.

یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی در طبیعت، فرآیند بارش- تراز آب زیرزمینی است که از پارامترهای مختلف فیزیکی و هیدرولوژیکی تأثیر می‌پذیرد. درک و پیش‌بینی فرآیندهای بارش و نفوذ آن به منابع آب زیرزمینی که از منابع اصلی تامین آب شیرین در ایران می‌باشد، یکی از اساسی‌ترین مباحث علم هیدرولوژی در حوضه‌های آبخیز محسوب می‌شود. تاکنون مدل‌های مختلفی برای پیش‌بینی تغییرات تراز آب زیرزمینی با استفاده از الگوی بارش ارائه شده است اما در این بین به مدل تابع انتقال کم‌تر توجه شده است. این مدل تاخیر زمانی، تأثیرگذاری بارش بر تراز آب زیرزمینی را به بهترین شکل ممکن بررسی نموده که سایر مدل‌ها این قابلیت را ندارند. بنابراین هدف اصلی این پژوهش معرفی و استفاده از



شکل ۱- موقعیت ۳ زیرحوضه مورد مطالعه در حوضه آبریز گرگانرود.

Figure 1. Location of the 3 studied watersheds in the Gorganrood river basin.

قرار می‌گیرد (۲۶). مدل‌های شبکه‌های عصبی مصنوعی به دلیل نوع طراحی آن‌ها دارای انعطاف‌پذیری بسیار خوبی بوده که در شرایط مختلف دارای عملکرد مناسبی می‌باشد. این مدل‌ها مبتنی بر هیچ فرضیه خاصی نیست که از مزیت‌های این روش محسوب می‌شود. همچنین طراحی آن‌ها به گونه‌ای است که با وجود هر روندی چه خطی چه غیرخطی، چه فصلی و چه غیرفصلی قابل استفاده می‌باشند. در صورت تغییر در الگوی‌های زمانی، شبکه‌های عصبی به خوبی آن‌ها را شناسایی کرده و نیازی به حذف روند و روند فصلی از داده وجود ندارد. همچنین می‌توان به‌طور مستقیم با داده‌های اصلی سری‌های زمانی مدل‌سازی را انجام داد. اگر چه انواع مختلفی از شبکه‌های عصبی مصنوعی ارائه شده است اما در سری‌های زمانی معمولاً از شبکه‌های عصبی پیش‌رو استفاده می‌شود (۲۷).

در حالتی که رابطه بین دو سری زمانی مورد بررسی قرار می‌گیرد زمان‌های گذشته سری زمانی

با توجه به این‌که مقادیر بارش و تراز آب زیرزمینی ماهانه وابسته به زمان هستند، در ابتدا این داده‌ها به صورت سری زمانی مرتب شد. جهت مدل‌سازی مقادیر بارش و تراز آب زیرزمینی ماهانه از ۳ روش شبکه عصبی مصنوعی (ANN)، شبکه عصبی مصنوعی- فازی (ANFIS) و تابع انتقال (TF) در ۳ حوضه منتخب استفاده شد. پس از مدل‌سازی مقادیر تراز آب زیرزمینی ماهانه با استفاده از بارش ماهانه برای ۳ حوضه منتخب، با کمک مدل‌های (ANN)، (ANFIS) و (TF) اقدام به پیش‌بینی تغییرات تراز آب زیرزمینی ماهانه چاه‌های مورد بررسی برای ۱۲ ماه آینده شد. لازم به توضیح است در پژوهش حاضر، جهت انجام محاسبات آماری از نرم‌افزارهای SPSS، MINITAB، SAS و R استفاده شده است.

مدل شبکه عصبی مصنوعی: شبکه‌های عصبی یک روش الهام گرفته از طبیعت است که در بسیاری از مسائل از جمله مدل‌سازی و پیش‌بینی مورد استفاده

گرفته می‌شود. در این حالت مدل می‌تواند به صورت رابطه ۱ نوشته شود:

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

γ_j وزن مسیر گره‌های پنهان تا لایه خروجی و β_{ij} و δ_{ij} وزن مسیرها بین لایه ورودی و گره‌های پنهان را مشخص می‌کند (۲۸).

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

مدل شبکه عصبی - فازی: در این روش از ترکیبی از شبکه‌های عصبی مصنوعی و منطق فازی در پیش‌بینی سری زمانی استفاده می‌گردد. در سال‌های اخیر با ترکیب منطق فازی و شبکه عصبی ضمن ایجاد انعطاف‌پذیری بیشتر در آموزش شبکه، قدرت پیش‌بینی شبکه‌های عصبی افزایش چشمگیری پیدا کرده است (۲۹). نحوه مدل‌سازی این مدل شبیه شبکه‌های عصبی مصنوعی است با این تفاوت که انتخاب مسیر بر اساس منطق فازی و یک تابع عضویت که توسط داده‌ها برآورد می‌شود، انجام می‌شود. 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. این روش علاوه بر بالابردن انعطاف‌پذیری شبکه‌های عصبی، ریسک خطا را نیز کاهش می‌دهد (۳۰). تابع عضویت معمولاً به صورت تابعی زنگوله‌ای شکل در نظر گرفته می‌شود (رابطه ۳):

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

در محیط نرم‌افزار R 4.2 و با بسته frbs انجام خواهد شد.

خروجی (y_{t-j}) و زمان‌های حال و گذشته سری زمانی ورودی (Z_{t-j}) به‌عنوان متغیرهای پیش‌بینی‌کننده در مدل شبکه عصبی مصنوعی به‌کار

که در آن، m تعداد گره‌های ورودی، n تعداد گره‌های پنهان، f و g یک تابع انتقال‌دهنده از ورودی به خروجی که معمولاً به صورت سیگموئیدی در نظر گرفته شده و فرم معمول آن تابع لجستیک می‌باشد (رابطه ۲). α_j و

اگرچه شبکه‌های عصبی مصنوعی به‌طور گسترده‌ای در پیش‌بینی مدل‌های رگرسیونی مورد استفاده قرار گرفته‌اند، اما در مورد سری‌های زمانی کم‌تر به آن‌ها پرداخته شده است. 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 برای اعتبارسنجی درونی مدل مورد استفاده قرار گرفته و قسمت سوم برای اعتبارسنجی بیرونی یا پیش‌بینی مدل مورد استفاده قرار می‌گیرد. در سری‌های زمانی همبسته متناوب، مشاهدات به صورت مضربی از دوره تناوب تقسیم‌بندی شده و پیشنهاد می‌شود که از یک دوره قبل و یا نهایتاً دو دوره قبل در پیش‌بینی استفاده گردد. این بررسی در محیط نرم‌افزار SPSS 25 انجام شد.

که در آن، پارامترهای a_i ، b_i و c_i توسط داده‌ها برآورد و یا آموزش داده می‌شوند (۲۹). این بررسی

یک یا چند سری زمانی به‌عنوان متغیر پیش‌بینی‌کننده برقرار می‌کند. این مدل با در نظر گرفتن تاخیر رابطه بین سری‌های زمانی، به پیش‌بینی سری زمانی پاسخ می‌پردازد. مدل تابع انتقال با یک سری زمانی پیش‌بینی‌کننده به صورت رابطه ۴ ارایه شده است:

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

پارامتر b تاخیری است که بیش‌ترین ارتباط بین دو سری زمانی در این تاخیر اتفاق می‌افتد. مقدار پارامتر b از تابع خودهمبستگی متقابل قابل تشخیص می‌باشد. هم‌چنین مقادیر s, r نیز بر اساس تابع انتقال متقابل تعیین می‌شود. مراحل ساخت یک تابع انتقال را می‌توان در ۳ مرحله زیر خلاصه کرد (۳۲):

گام اول: یک مدل SARIMA به متغیر ورودی برازش شده و دقیقاً همین مدل بدون تغییر بر روی سری زمانی خروجی اعمال می‌شود که به آن پیش‌صافی کردن سری زمانی گفته می‌شود. با این تغییرات دو سری زمانی جدید حاصل شده که رابطه بین آن‌ها را بهتر نشان می‌دهند.

گام دوم: محاسبه تابع خودهمبستگی بین دو سری زمانی حاصل از گام اول برای شناسایی پارامترهای (b, s, r) .

گام سوم: برازش یک مدل SARIMA به سری زمانی باقی‌مانده، η_t و تعیین مدل نهایی تابع انتقال. پس از برازش یک مدل تابع انتقال، مدلی به صورت رابطه ۵ حاصل می‌شود:

$$Y_t = I_{Y_t} + I_{X_t} + I_{Z_t} \quad (5)$$

سری زمانی ورودی تفسیر شده و I_{Z_t} شرایط محیطی مؤثر بر تغییرات متغیر پاسخ می‌باشد. لازم به توضیح است که در رابطه ۵ چنانچه جمله I_{X_t} حذف شود

مدل تابع انتقال: تابع انتقال در واقع یک مدل نایستا پیشرفته سری زمانی است که علاوه بر داده‌های سری ورودی، بر روی باقی‌مانده‌های مدل نیز مدل مناسب برازش داده و برخلاف دیگر مدل‌های سری زمانی، یک مدل چندمتغیره است (۳۱). این مدل یک رابطه دینامیکی بین یک سری زمانی به‌عنوان متغیر پاسخ و

که در آن، μ و C اعداد ثابت، η_t سری زمانی باقی‌مانده مدل و $w(B)$ و $\delta(B)$ دو چندجمله‌ای از عملگر پس‌رو می‌باشند. بنابراین هر تابع انتقال با $(d_1, T_1, D_1, d_2, T_2, D_2)$ و پارامترهای (b, s, r) که در آن s, r درجه چندجمله‌ای‌های $w(B)$ و $\delta(B)$ است، تعیین می‌شود. $(d_1, T_1, D_1, d_2, T_2, D_2)$ مانند برازش مدل SARIMA برای هر سری زمانی به طور جداگانه تعیین می‌شود. در این بررسی تعیین روند با استفاده از روش میانگین متحرک انجام و برای حذف روند از تفاضلی کردن با مرتبه‌های d_1 و d_2 به ترتیب برای سری‌های زمانی خروجی و ورودی استفاده شد. برای شناسایی رفتار تناوبی سری‌های زمانی از تابع خودهمبستگی‌نگار و برای حذف روند در تشکیل مدل، از تفاضلی کردن فصلی با دوره تناوب شناسایی شده استفاده گردید. پارامترهای T_1 و T_2 به ترتیب دوره تناوب سری زمانی خروجی و ورودی و D_1 و D_2 مرتبه‌های تفاضلی کردن تناوبی برای حذف روند فصلی می‌باشند. لازم به توضیح است که دوره تناوب دو سری زمانی ممکن است متفاوت باشد.

که در آن، I_{Y_t} سهمی از تغییرات متغیر پاسخ است که توسط زمان‌های ماقبل خودش تفسیر می‌گردد. I_{X_t} سهمی از تغییرات در متغیر پاسخ است که توسط

برای بررسی نکویی برازش یک مدل SARIMA معمولاً از آماره Q باکس-پیرس و فرم‌های اصلاح شده آن استفاده می‌شود. این آماره به صورت رابطه ۶ محاسبه می‌شود:

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

برازش مناسب مدل می‌باشد. برای بررسی نکویی برازش یک تابع انتقال با یک سری زمانی ورودی از دو آماره استفاده می‌شود که در رابطه‌های ۷ و ۸ ارایه شده است:

$$Q_1 = n \sum_{i=1}^k r_i^2(\eta_t, X_t) \quad (7)$$

$$Q = n \sum_{i=1}^k r_i^2(\eta_t, \eta_t) \quad (8)$$

از داده‌های اصلی خارج شد و بقیه داده‌ها برای آموزش شبکه مورد استفاده قرار گرفت. سپس اعتبارسنجی مدل‌های مورد استفاده انجام شد. تاکنون شاخص‌های استاندارد مختلفی برای مقایسه مقادیر حاصل از مدل و مقادیر واقعی ارایه شده است که در روابط ۹ تا ۱۱ به بیان مهم‌ترین آن‌ها پرداخته می‌شود:

همان مدل SARIMA برای متغیر خروجی حاصل می‌شود. مدل‌سازی تابع انتقال در این پژوهش با استفاده از نرم‌افزارهای SAS 9.1 و MINITAB 17.3 انجام شد.

که در آن، $r_i(Z_t, Z_t)$ تابع خودهمبستگی سری زمانی باقی‌مانده را در گام یا تاخیر i ام نشان می‌دهد. آماره Q دارای توزیع مجانبی $\chi^2(k)$ می‌باشد. این آماره بر این اساس شکل گرفته که سری زمانی باقی‌مانده تا چه میزان تبدیل به نوفه سفیدشده و نشان‌دهنده

که در آن، $r_i(\eta_t, X_t)$ تابع خودهمبستگی متقابل بین سری زمانی باقی‌مانده و سری زمانی ورودی بوده و $r_i(\eta_t, \eta_t)$ تابع خودهمبستگی سری زمانی باقی‌مانده می‌باشد. مدلی از تابع انتقالی مناسب است که هر دو ویژگی بالا را به طور هم‌زمان داشته باشد. در مدل‌سازی‌ها اطلاعات سال آخر به عنوان اعتبارسنجی

الف) شاخص میانگین قدرمطلق فاصله

$$MAD = \frac{1}{m} \sum_{i=1}^m |Y_t - \hat{Y}_t| \quad (9)$$

ب) شاخص مربع میانگین خطا

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (Y_t - \hat{Y}_t)^2}{m}} \quad (10)$$

ج) شاخص میانگین قدرمطلق درصد خطا

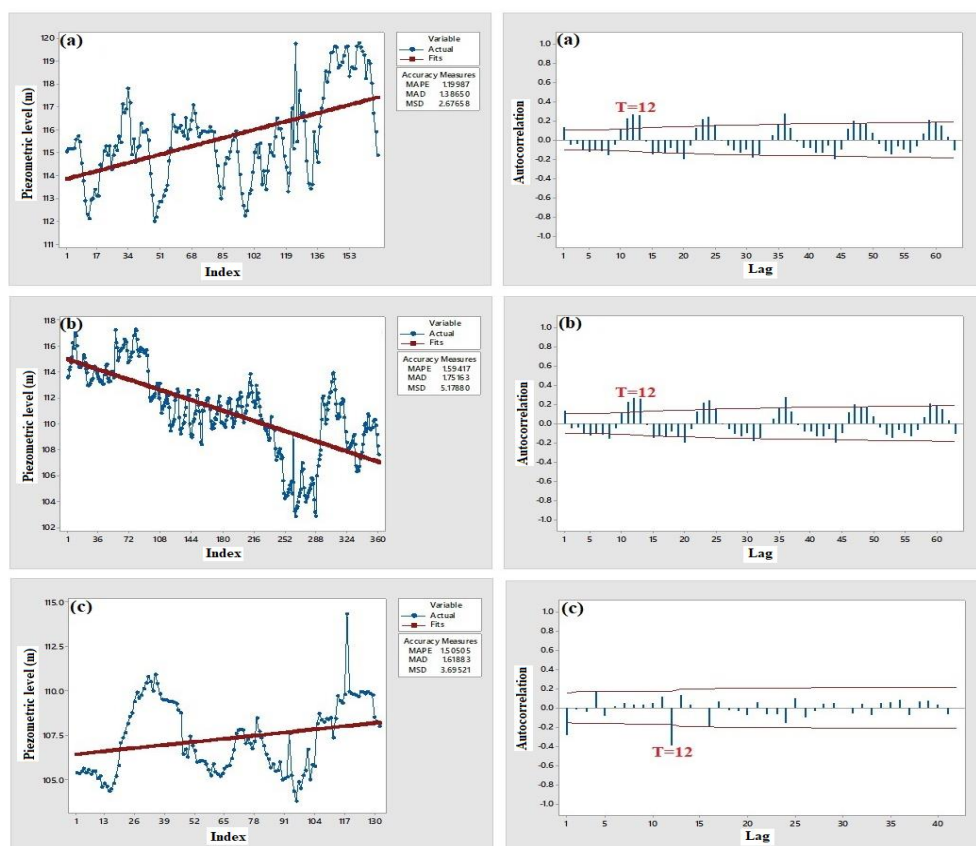
$$MAPE = \frac{\sum_{i=1}^m \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{m} \quad (11)$$

برای بررسی روند معمولی و فصلی تراز آب زیرزمینی ماهانه چاه‌های مورد بررسی در سه حوضه آبخیز گالیکش، رامیان و محمدآباد، نمودارهای روند و خودهمبستگی آن‌ها ترسیم گردید. با توجه به نمودارهای خودهمبستگی در شکل ۲ سمت راست مشخص شد که در هر سه چاه مورد بررسی، روند فصلی با دوره تناوب ۱۲ ماه در تراز آب زیرزمینی وجود دارد. همچنین با توجه به نمودارهای روند در شکل ۲ سمت چپ، در دو چاه جنوب اسماعیل‌آباد و پیچک محله ۲ واقع در حوضه‌های آبخیز گالیکش و محمدآباد یک روند صعودی در تراز آب زیرزمینی مشاهده شد در حالی که در چاه قره‌قاج واقع در حوضه آبخیز رامیان روند نزولی مشاهده شد.

که در روابط فوق، \hat{Y}_t مقادیر برازش‌شده و یا پیش‌بینی‌شده توسط مدل، Y_t مقدار سری زمانی مشاهده‌شده در زمان t و m تعداد مقادیر برازش‌شده یا مقادیر پیش‌بینی می‌باشد.

نتایج و بحث

در این پژوهش، ابتدا با استفاده از سه مدل شبکه عصبی مصنوعی (ANN)، شبکه عصبی-فازی (ANFIS) و تابع انتقال (TF) در ۳ حوضه آبخیز گالیکش، رامیان و محمدآباد به ترتیب واقع در سرشاخه‌های شرقی، مرکزی و غربی حوضه آبریز گرگانرود اقدام به مدل‌سازی مقادیر تراز آب زیرزمینی ماهانه با استفاده از داده‌های بارش ماهانه گردید. سپس عملکرد این مدل‌ها با شاخص‌های مختلف مورد ارزیابی قرار گرفت.



شکل ۲- نمودارهای روند (سمت چپ) و خودهمبستگی (سمت راست) در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).
 Figure 2. Graphs of trend (left) and autocorrelation (right) in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

نشود. در نهایت مناسب‌ترین مدل شبکه عصبی برای سری داده‌ها انتخاب شد. از آنجا که هدف پیش‌بینی سری زمانی برای مقادیر آینده است، می‌توان مراحل فوق را با مقادیر سال آخر به‌عنوان متغیر پاسخ و سال‌های قبل از آن به‌عنوان متغیرهای پیش‌بینی‌کننده انجام و شبکه را آموزش داد. سپس می‌توان بر اساس آن شبکه، مقادیر پیش‌بینی را محاسبه کرد.

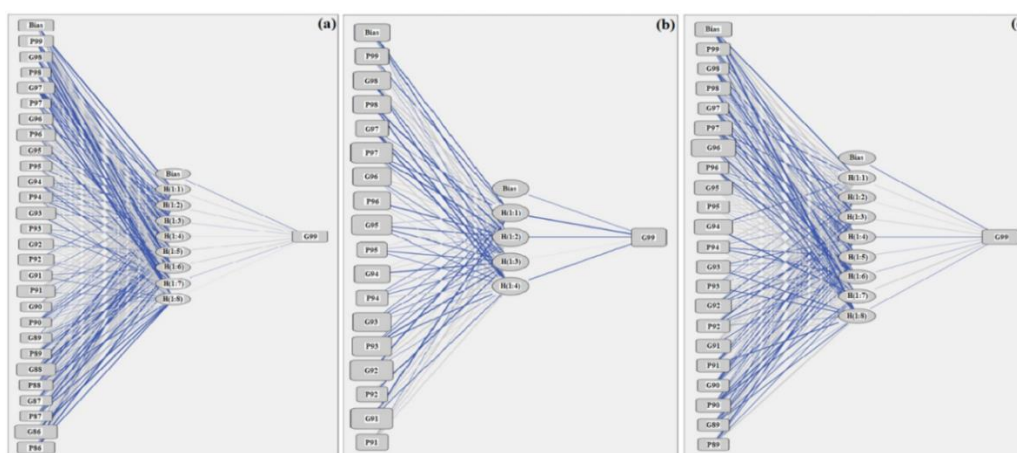
شکل ۳ ساختار شبکه عصبی مصنوعی و نحوه برقراری ارتباط زمان‌های گذشته تراز آب زیرزمینی و زمان‌های گذشته و حال بارش را با زمان حال تراز آب زیرزمینی در سری داده‌ها به تفکیک حوضه نشان می‌دهد. مطابق شکل ۳ قسمت (a)، در حوضه آبخیز گالیکش مقادیر بارش و تراز آب زیرزمینی ماهانه ۱۴ سال گذشته به عنوان متغیرهای پیش‌بینی‌کننده وارد مدل شده و بهترین عملکرد را داشته‌اند که این کار مطابق با الگوریتم فوق انجام شده است. همچنین بررسی ساختار شبکه عصبی مصنوعی در حوضه‌های آبخیز رامیان و محمدآباد نشان داد که به ترتیب مقادیر بارش و تراز آب زیرزمینی ماهانه ۹ و ۱۱ سال گذشته آن‌ها به عنوان متغیرهای پیش‌بینی‌کننده وارد مدل شده و بهترین عملکرد را داشته‌اند.

به دلیل وجود دوره تناوب ۱۲ ماهه در سری‌های زمانی مورد بررسی، مشاهدات ماهانه مقادیر بارش و تراز آب زیرزمینی هر سال به‌عنوان متغیرهای مستقل دسته‌بندی شد. مقادیر تراز آب زیرزمینی سال آخر به‌عنوان متغیر وابسته برای مدل شبکه عصبی در نظر گرفته شد. از آنجا که سال‌های نزدیک‌تر به وضعیت حال اطلاعات دقیق‌تری از وضعیت این زمان دارند، سال‌ها به صورت فرآیند پیش‌رو در شبکه‌های عصبی در نظر گرفته شد. در این پژوهش مراحل زیر برای مدل‌سازی شبکه‌های عصبی بر اساس فرآیند پیش‌رو طی شد.

گام اول: داده‌های بارش دو سال آخر و داده‌های تراز آب زیرزمینی سال قبل چاه‌ها به‌عنوان متغیر پیش‌بینی‌کننده در نظر گرفته شد. سپس مقادیر پیش‌بینی تراز آب زیرزمینی تعیین و شاخص RMSE برای مقادیر پیش‌بینی محاسبه گردید.

گام دوم: علاوه بر داده‌های فوق، مقادیر بارش و تراز آب زیرزمینی 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

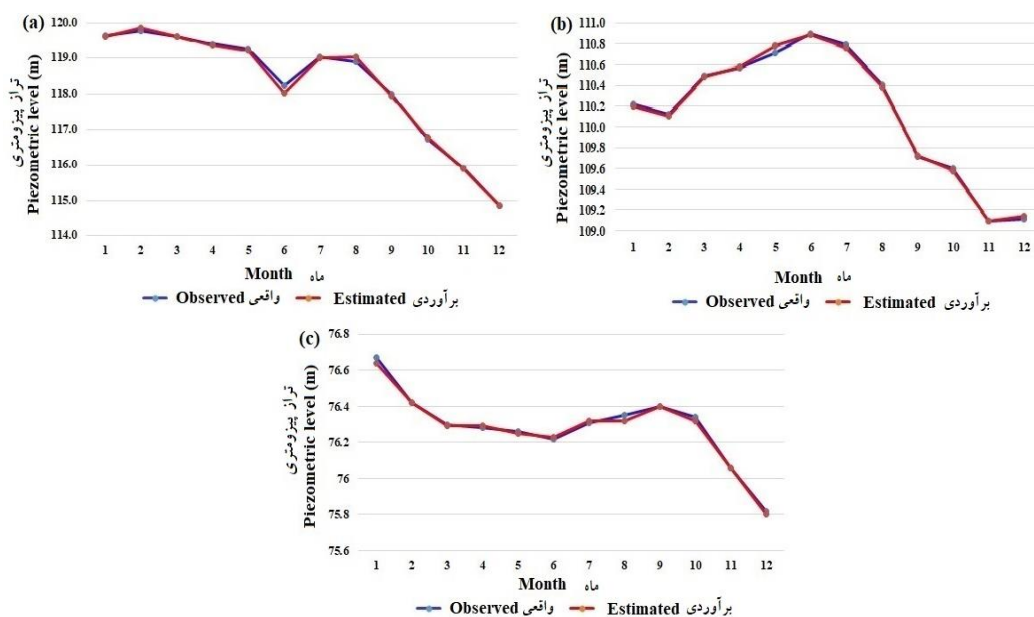


شکل ۳- ساختار مدل شبکه عصبی مصنوعی در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 3. Structures of ANN model in Galikesh (a), Ramian (b) and Mohammadabad (c) watersheds.

آبخیز مورد بررسی عملکرد بسیار مناسبی داشته‌اند. لازم به توضیح است هنگامی که از عملکرد پیش‌رو در مدل‌سازی شبکه عصبی مصنوعی استفاده شود نسبت به حالتی که از سری کامل داده‌ها استفاده می‌شود، به نحو چشمگیری کارایی مدل بهبود می‌یابد.

شکل ۴ نمودار مقایسه مقادیر تراز آب زیرزمینی ماهانه واقعی و پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی را در ۳ حوضه آبخیز مورد بررسی نشان می‌دهد. مطابق شکل ۴ می‌توان بیان نمود که مدل شبکه‌های عصبی در برازش و مدل‌سازی مقادیر بارش- تراز آب زیرزمینی ماهانه در هر ۳ حوضه

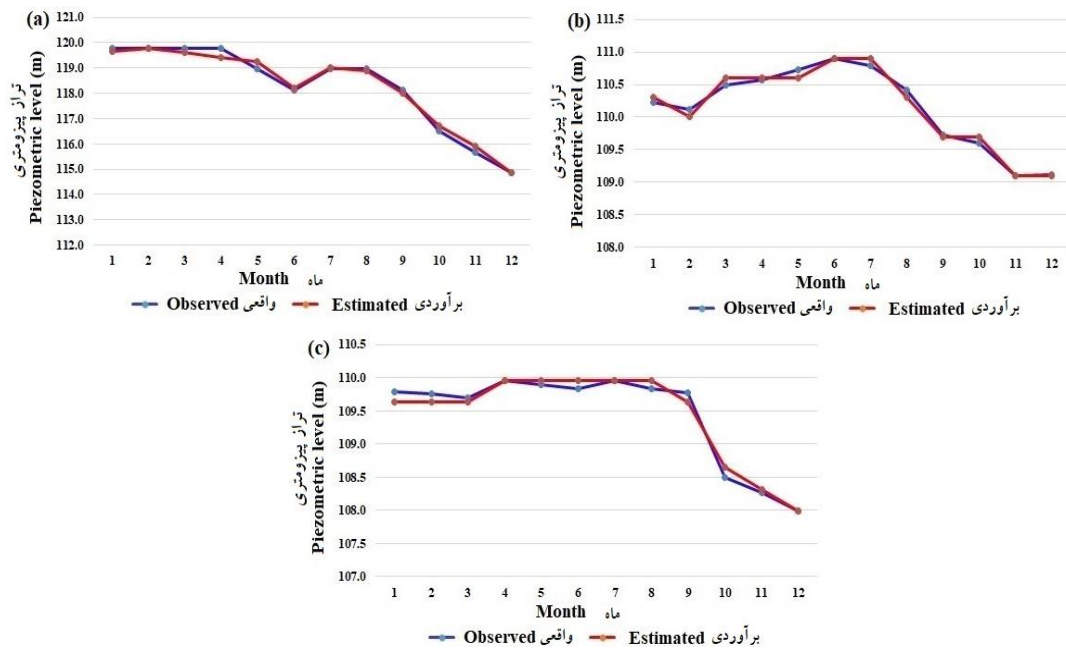


شکل ۴- مقایسه تراز آب زیرزمینی ماهانه واقعی و پیش‌بینی شده توسط مدل ANN در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 4. Comparison of actual and predicted monthly groundwater levels by ANN model in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

در برازش مقادیر تراز آب زیرزمینی ماهانه، برای هر ۳ حوضه آبخیز مورد بررسی عملکردی بسیار مناسبی داشته و به خوبی قابلیت تشخیص روند تغییرات داده‌ها را داشته است. در هر دو مدل شبکه عصبی مصنوعی و شبکه عصبی- فازی بیش‌برآوردی و کم‌برآوردی پیوسته که باعث افزایش خطا و کاهش عملکرد مدل‌ها می‌شود، مشاهده نشد. این موضوع بیانگر آن است که استفاده از دو مدل فوق جهت برآورد و پیش‌بینی مقادیر تراز آب زیرزمینی ماهانه با استفاده از داده‌های بارش ماهانه مؤثر می‌باشد.

با توجه به نتایج شبکه‌های عصبی و تعیین تعداد سال‌های مؤثر در ۳ حوضه آبخیز مورد بررسی، مدل شبکه عصبی- فازی به تفکیک حوضه برازش داده شد. برای محاسبات مربوط به مدل شبکه عصبی- فازی از بسته frbs در محیط نرم‌افزار R و بر اساس روش وانگ و مندل استفاده گردید. شکل ۵ نمودار مقایسه مقادیر تراز آب زیرزمینی ماهانه واقعی و پیش‌بینی شده توسط مدل شبکه عصبی- فازی را در ۳ حوضه آبخیز مورد بررسی نشان می‌دهد. مطابق شکل ۵ می‌توان قضاوت کرد که مدل شبکه‌های عصبی- فازی مشابه با روش شبکه عصبی مصنوعی



شکل ۵- مقایسه تراز آب زیرزمینی ماهانه واقعی و پیش‌بینی شده توسط مدل ANFIS در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 5. Comparison of actual and predicted monthly groundwater level by ANFIS model in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

گالیکش، رامیان و محمدآباد برازش داده شد (۳۲). بهترین مدل برازش شده به داده‌های بارش ماهانه در ایستگاه‌های هواشناسی منتخب در جدول ۱ ارایه شده است. با توجه به سطح مقادیر معنی‌داری که بسیار بالاتر از ۰/۰۵ می‌باشد، مشخص شد که در سری‌های زمانی باقی‌مانده مدل‌ها، همبستگی وجود ندارد در نتیجه مدل‌ها به خوبی برازش داده شده‌اند.

سپس مدل‌سازی مقادیر بارش-تراز آب زیرزمینی به روش تابع انتقال در ۳ مرحله پیش‌صافی، همبستگی متقابل و برازش مدل انجام شد.

مرحله پیش‌صافی: برای پیش‌صافی کردن رابطه بین سری‌های زمانی ورودی (بارش) و خروجی (تراز آب زیرزمینی) یک مدل باکس و جنکینز به بارش در هر سه ایستگاه هواشناسی واقع در حوضه‌های آبخیز

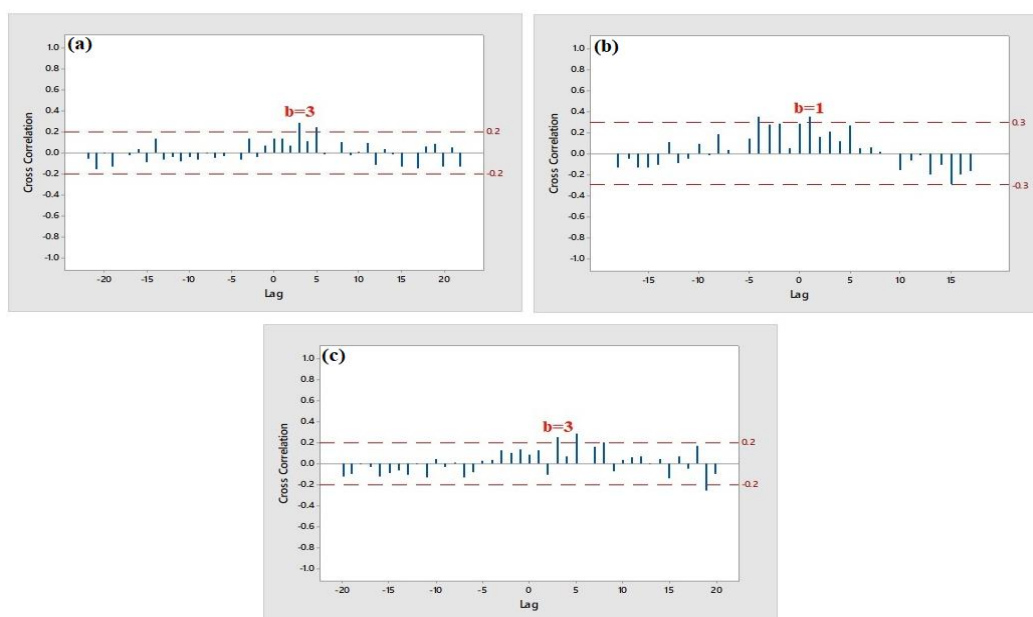
جدول ۱- نتایج مدل‌سازی باکس و جنکینز برای سری‌های زمانی بارش ماهانه.

Table 1. The results of Box and Jenkins modeling for the monthly rainfall time series.

مقدار معنی‌داری Significant values	مدل باکس و جنکینز Box and Jenkins Model	ایستگاه هواشناسی Meteorological station
0.338	$(0, 0, 1) \times (0, 1, 1)_{12}$	گالیکش Galikesh
0.904	$(0, 0, 2) \times (0, 1, 1)_{12}$	رامیان Ramian
0.857	$(0, 0, 4) \times (0, 1, 1)_{12}$	سرمو Mohamadabad

است که نشان می‌دهد بارش با سه ماه تاخیر بر تراز آب زیرزمینی تأثیر مستقیم گذاشته است اما در حوضه آبخیز رامیان این تاخیر یک ماه بعد از وقوع بارش اتفاق افتاده است. با توجه به نوع تشکیلات و سازندهای زمین‌شناسی متفاوت در هر یک از حوضه‌های آبخیز مورد مطالعه که از لحاظ میزان نفوذ و توان آبگذری شرایط متفاوتی دارند، مقدار تاخیرها منطقی به نظر می‌رسد. نتایج این بررسی با مطالعات اسلامیان و همکاران (۲۰۰۹) که بیان نموده‌اند اثر ریزش‌های جوی با تاخیر ۳ ماهه بر تراز آب زیرزمینی اثر گذاشته‌اند (۱۷)، همسویی دارد.

مرحله همبستگی متقابل: پس از برازش مدل پیش‌صافی، دقیقاً همان مدل به داده‌های تراز آب زیرزمینی ماهانه برازش داده شد. نمودار خودهمبستگی متقابل بین سری زمانی تراز آب زیرزمینی و بارش پس از پیش‌صافی کردن در حوضه‌های آبخیز منتخب در شکل ۶ نمایش داده شده است. وجود یک پیک معنی‌دار در هر سه نمودار بیانگر ارتباط بین بارش و تراز آب زیرزمینی در هر ۳ حوضه آبخیز مورد بررسی می‌باشد که پیش‌شرط استفاده از تابع انتقال است. با توجه به شکل ۶ همبستگی متقابل بین بارش و تراز آب زیرزمینی در دو حوضه آبخیز گالیکش و محمدآباد با تاخیر ۳ ماهه دارای یک پیک معنی‌دار



شکل ۶- نمودار خودهمبستگی متقابل بین سری‌های زمانی بارش و تراز آب زیرزمینی در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 6. Cross correlation diagram between rainfall and groundwater level time series in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

به سطح مقادیر معنی‌داری که بسیار بالاتر از ۰/۰۵ می‌باشد، هم تابع انتقال و هم مدل سری زمانی مقادیر باقی‌مانده در هر ۳ حوضه آبخیز مورد مطالعه به خوبی برازش داده شده‌اند.

برازش تابع انتقال: جدول ۲ نتایج برازش مدل تابع انتقال را در ایستگاه‌های منتخب نشان می‌دهد. با توجه به نمودار خودهمبستگی متقابل، مقادیر پارامترهای تابع انتقال تعیین گردید. هم‌چنین به سری زمانی باقی‌مانده، مدل‌های مناسب برازش داده شد. با توجه

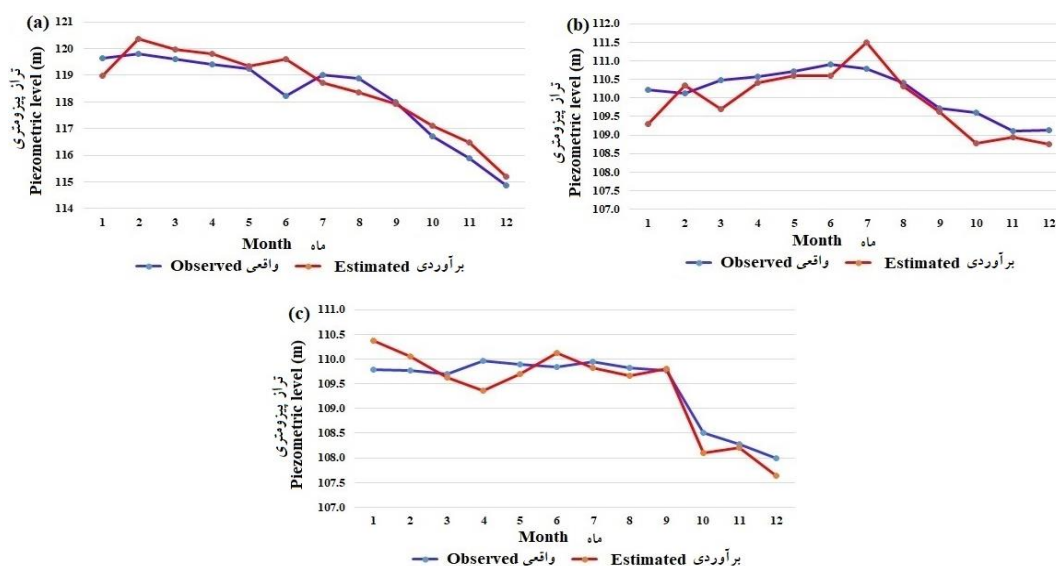
جدول ۲- نتایج برازش مدل TF بارش- تراز آب زیرزمینی در حوضه‌های آبخیز منتخب.

Table 2. The results of fitting the TF model for rainfall-groundwater level in selected watersheds.

مقادیر معنی داری Significant values		مدل برازش شده به سری زمانی باقی مانده The model fitted to the residual time series	پارامترهای مدل تابع انتقال Parameters of the TF model			حوضه آبخیز Watershed
همبستگی در سری زمانی باقی مانده	همبستگی بین سری زمانی بارش و باقی مانده		b	r	s	
0.450	0.580	$(0, 0, 2) \times (0, 0, 1)_{12}$	3	2	2	گالیکش Galikesh
0.650	0.925	$(0, 0, 1) \times (0, 0, 1)_{12}$	1	2	12	رامیان Ramian
0.650	0.530	$(0, 0, 1) \times (0, 0, 2)_{12}$	3	2	2	محمدآباد Mohamadabad

و قادر به تشخیص روند و تغییرات داده‌ها بوده است. در مدل تابع انتقال نیز همانند دو روش دیگر، بیش‌برآوردی و کم‌برآوردی پیوسته که باعث افزایش خطا و کاهش عملکرد مدل‌ها می‌شود، مشاهده نشد. هم‌چنین با توجه به مقایسه نتایج مدل‌سازی روش تابع انتقال با دو روش شبکه عصبی مصنوعی و شبکه‌های عصبی- فازی می‌توان بیان نمود که دو روش دیگر نسبت به روش تابع انتقال از عملکرد بهتری جهت پیش‌بینی تراز آب زیرزمینی برخوردار بوده‌اند.

بعد از برازش مدل تابع انتقال در محیط نرم‌افزار SAS، اقدام به پیش‌بینی مقادیر تراز آب زیرزمینی با استفاده از داده‌های بارش برای ۱۲ ماه آینده شد. شکل ۷ نمودار مقایسه مقادیر تراز آب زیرزمینی واقعی و پیش‌بینی شده به صورت ماهانه توسط مدل تابع انتقال را در سه حوضه آبخیز مورد بررسی نشان می‌دهد. با توجه به شکل ۷ می‌توان قضاوت کرد که مدل تابع انتقال در برازش مقادیر تراز آب زیرزمینی ماهانه در سه حوضه آبخیز مورد بررسی عملکرد مناسبی داشته



شکل ۷- مقایسه تراز آب زیرزمینی ماهانه واقعی و پیش‌بینی شده توسط مدل TF در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 7. Comparison of actual and predicted monthly groundwater level by TF model in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

نتایج مقایسه مدل‌های مورد استفاده جهت پیش‌بینی تراز آب زیرزمینی ماهانه را در ۳ حوضه آبخیز مورد مطالعه نشان می‌دهد.

برای مقایسه کارایی روش‌های مورد بحث در برازش مقادیر تراز آب زیرزمینی ماهانه در ۳ چاه واقع در خروجی ۳ حوضه آبخیز مورد مطالعه از ۳ معیار MAD ، $RMSE$ و $MAPE$ استفاده شد. جدول ۳

جدول ۳- نتایج اعتبارسنجی مدل‌ها جهت پیش‌بینی تراز آب زیرزمینی ماهانه.

Table 3. Validation results of models to predict the monthly groundwater level.

نام مدل Model name			شاخص‌های استاندارد Standard indicators	حوضه آبخیز Watershed
تابع انتقال TF	شبکه عصبی - فازی ANFIS	شبکه عصبی مصنوعی ANN		
0.4717	0.1464	0.0575	MAD	گالیکش Galikesh
0.5711	0.1841	0.0778	RSME	
0.0040	0.0012	0.0005	MAPE	
0.3993	0.0683	0.0192	MAD	رامیان Ramian
0.5023	0.0832	0.0243	RSME	
0.0036	0.0006	0.0002	MAPE	
0.2658	0.0832	0.0400	MAD	محمدآباد Mohamadabad
0.3234	0.1012	0.0532	RSME	
0.0024	0.0008	0.0004	MAPE	

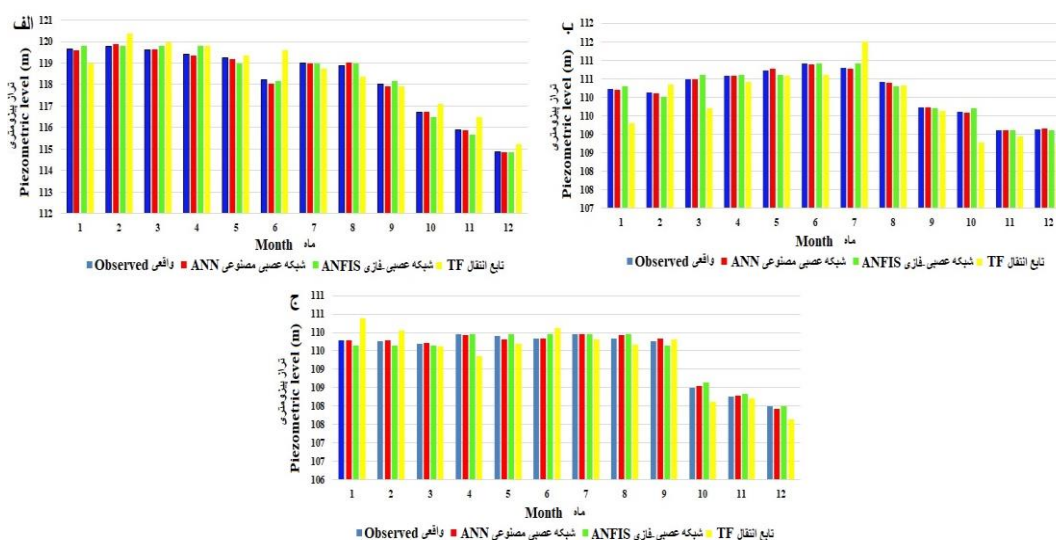
مدل‌سازی مقادیر بارش- تراز آب زیرزمینی می‌باشد. هیستوگرام مقایسه مقادیر واقعی و برآورد شده تراز آب زیرزمینی ماهانه که در شکل ۸ ارایه شده است، به روشنی بیانگر این ادعاست. لازم به توضیح است که در استفاده از مدل شبکه عصبی از عملکرد پیش‌رو استفاده شده است که با تعیین تعداد سال‌های مؤثر، باعث بهبود قابل‌ملاحظه در عملکرد این روش شده است.

به‌طور کلی با توجه به نتایج حاصل از برازش مدل‌ها، پیش‌بینی و هم‌چنین اعتبارسنجی هر یک از ۳ مدل مورد بررسی با استفاده از معیارهای استاندارد MAD ، $RMSE$ و $MAPE$ می‌توان چنین بیان نمود که مدل شبکه عصبی مصنوعی در ۳ حوضه آبخیز گالیکش، رامیان و محمدآباد جهت پیش‌بینی تراز آب

بر اساس نتایج اعتبارسنجی جدول ۳ مشخص شد که جهت پیش‌بینی مقادیر تراز آب زیرزمینی ماهانه با استفاده از داده‌های بارش در هر سه حوضه آبخیز که در سرشاخه‌های شرقی، غربی و مرکزی حوضه آبریز گرگانرود واقع شده‌اند، مدل شبکه عصبی مصنوعی به دلیل کم‌تر بودن مقادیر محاسبه شده برای هر ۳ معیار MAD ، $RMSE$ و $MAPE$ نسبت به دو مدل دیگر دارای بهترین عملکرد بوده است. بعد از شبکه عصبی مصنوعی، شبکه عصبی - فازی دارای مناسب‌ترین عملکرد بوده و نتایج هر دو مدل بسیار نزدیک به هم می‌باشد. روش تابع انتقال در بین سه مدل مورد استفاده عملکرد ضعیف‌تری داشته است ولی با توجه به این‌که در تشخیص روند تغییرات مناسب عمل کرده بود، مدل مناسبی جهت پیش‌بینی و

(۲۰۲۲) و لوهانی و کریشان (۲۰۱۵) در کشور هند که بیان نموده‌اند که روش شبکه عصبی مصنوعی جهت مدل‌سازی بارش-تراز آب زیرزمینی دارای عملکرد مناسبی می‌باشد، انطباق دارد (۱۴، ۲۰، ۱۰ و ۹).

زیرزمینی با استفاده از داده‌های بارش ماهانه دارای بهترین عملکرد بوده است. نتایج این بررسی با مطالعات انجام شده توسط محتشم و همکاران (۲۰۱۷)، مختاری و همکاران (۲۰۱۳)، جندقی



شکل ۸- هیستوگرام مقایسه مقادیر واقعی و برآورد شده تراز آب زیرزمینی با استفاده از ۳ مدل در حوضه‌های آبخیز گالیکش (a)، رامیان (b) و محمدآباد (c).

Figure 8. Histogram of comparing the actual and estimated groundwater level by 3 models in Galikesh (a), Ramian (b) and Mohamadabad (c) watersheds.

مصنوعی است (۱۸، ۱۹ و ۱۲)، هم‌خوانی ندارد. در این خصوص لازم به ذکر است که دقت این روش بر اساس معیارهای استاندارد، در مدل‌سازی و پیش‌بینی بسیار شبیه به مدل شبکه عصبی مصنوعی می‌باشد که این نتیجه با مطالعات امامقلی‌زاده و همکاران (۲۰۱۴) و ابارشی و همکاران (۲۰۱۴) که بیان نموده‌اند که هر دو مدل شبکه عصبی- فازی و شبکه عصبی مصنوعی جهت مدل‌سازی بارش-تراز آب زیرزمینی عملکرد مناسب و یکسانی داشته‌اند (۱۱ و ۱۹)، هم‌خوانی دارد.

در این پژوهش، با توجه به این‌که سال‌های نزدیک‌تر به زمان حال اطلاعات دقیق‌تری از وضعیت این زمان دارند، سال‌ها به صورت فرآیند پیش‌رو در

در این بررسی هم‌چنین مشخص شد که مدل شبکه عصبی- فازی بعد از مدل شبکه عصبی مصنوعی دارای مناسب‌ترین عملکرد برای مدل‌سازی و پیش‌بینی تراز آب زیرزمینی با استفاده از داده‌های بارش ماهانه بوده است. نتایج این بررسی با مطالعه رشیدی و همکاران (۲۰۱۶) که بیان نموده‌اند جهت مدل‌سازی بارش-تراز آب زیرزمینی روش شبکه عصبی مصنوعی مناسب‌تر از روش شبکه عصبی- فازی است (۲۱)، انطباق دارد اما با مطالعات سعیدی رضوی و عرب (۲۰۱۹)، آموتها و پورچلوان (۲۰۱۱) و امامقلی‌زاده و همکاران (۲۰۱۴) که بیان نموده‌اند جهت مدل‌سازی بارش-تراز آب زیرزمینی، روش شبکه عصبی- فازی مناسب‌تر از روش شبکه عصبی

برازش مدل و پیش‌بینی مقادیر تراز آب زیرزمینی با استفاده از داده‌های بارش به کمک سه مدل شبکه عصبی مصنوعی، شبکه عصبی - فازی (انفیس) و تابع انتقال انجام و سپس اعتبارسنجی مدل‌ها انجام شد. با توجه به نمودار خودهمبستگی نگار تراز آب زیرزمینی مشخص گردید که در هر سه چاه روند فصلی با دوره تناوب ۱۲ ماه وجود دارد. در این پژوهش، با توجه به این که سال‌های نزدیک‌تر به زمان حال اطلاعات دقیق‌تری از وضعیت این زمان دارند، سال‌ها به صورت فرآیند پیش‌رو در شبکه‌های عصبی در نظر گرفته شد. نتایج نشان داد در هر سه حوضه آبخیز مورد بررسی مدل شبکه عصبی مصنوعی جهت پیش‌بینی تراز آب زیرزمینی ماهانه با استفاده از داده‌های بارش دارای بهترین عملکرد بوده است. در این بررسی هم‌چنین مشخص شد که مدل شبکه عصبی - فازی بعد از مدل شبکه عصبی مصنوعی دارای مناسب‌ترین عملکرد بوده و نتایج آن بسیار مشابه با نتایج شبکه عصبی مصنوعی بوده است. هم‌چنین دقت مدل تابع انتقال نسبت به دو مدل دیگر در هر ۳ حوضه کم‌تر تعیین شد. هر چند که مدل تابع انتقال دارای دقت کم‌تری نسبت به شبکه عصبی - فازی و شبکه عصبی مصنوعی می‌باشد، اما دارای مزایایی است که نمی‌توان از آن چشم‌پوشی کرد. مدل تابع انتقال در شناسایی تاخیر در تأثیرگذاری بین متغیرهای ورودی و خروجی و هم‌چنین بیان مدلی که می‌توان بر اساس آن نحوه اثرگذاری بارش را به صورت یک مدل بیان کرد، بسیار مؤثر است.

تقدیر و تشکر

- نویسندگان از داوران محترم این مقاله که با نظرات خود موجب بهبود متن حاضر شده‌اند، تشکر می‌نمایند.
- نویسندگان از دانشگاه گنبد کاووس که موجبات تسهیل انجام این پژوهش را فراهم نموده‌اند، تشکر می‌نمایند.

شبکه‌های عصبی در نظر گرفته شد. لازم به توضیح است که در هنگام استفاده از این مدل چنانچه از فرآیند پیش‌رو با تعیین تعداد سال‌های مؤثر استفاده شود نسبت به زمانی که کل داده‌ها در مدل‌سازی مشارکت داشته باشد، کارایی مدل بهبود قابل ملاحظه‌ای خواهد یافت. نتایج این بررسی با مطالعات قزل‌سفلی و همکاران (۲۰۲۲) و جندقی (۲۰۲۳) که از این روش به ترتیب در مدل‌سازی مقادیر رواناب متوسط ماهانه و بارش ماهانه استفاده نموده‌اند (۱۵ و ۱۶)، همسویی دارد.

در این بررسی هم‌چنین از مدل تابع انتقال جهت مدل‌سازی بارش - تراز آب زیرزمینی استفاده شد. با توجه به اعتبارسنجی این مدل با شاخص‌های استاندارد مشخص گردید که دقت این مدل در پیش‌بینی نسبت به دو مدل شبکه عصبی - فازی و شبکه عصبی مصنوعی کم‌تر است با این وجود مدل تابع انتقال در برازش مقادیر تراز آب زیرزمینی ماهانه عملکرد مناسبی داشته و قادر به تشخیص روند و تغییرات داده‌ها بوده است. در مدل تابع انتقال نیز همانند دو روش دیگر، بیش‌برآوردی و کم‌برآوردی پیوسته که باعث افزایش خطا و کاهش عملکرد مدل‌ها می‌شود، مشاهده نشد. نتایج این بررسی با مطالعات موهاناساندرام و همکاران (۲۰۱۷) در کشور هند، ویلیام و همکاران (۲۰۱۹) در کشور هلند، سالم (۲۰۲۱) در عربستان سعودی و جندقی و همکاران (۲۰۲۱) در ایران که بیان نموده‌اند مدل تابع انتقال دارای عملکرد مناسب می‌باشد (۱۳، ۲۲، ۲۴ و ۲۳)، همسویی دارد.

نتیجه‌گیری

در پژوهش حاضر با استفاده از آمار ۳۰ ساله در سه حوضه آبخیز گالیکش، رامیان و محمدآباد جهت مدل‌سازی بارش - تراز آب زیرزمینی انجام شد.

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.

داده‌ها، اطلاعات و دسترسی

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

- داده‌های این متن مرتبط با پروژه تحقیقاتی با عنوان ارتباط بین بارش و تراز آب زیرزمینی با استفاده از رگرسیون تاخیر زمانی در دانشگاه گنبد کاووس می‌باشد. دسترسی به داده‌ها و اطلاعات صرفاً برای داوران/ دبیر تخصصی/ سردبیر نشریه و بنابر درخواست ایشان میسر خواهد بود.

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.

منابع

- Gunduz, O., & Simsek, C. (2011). Influence of climate change on shallow ground water resources: the link between precipitation and ground water levels in alluvial system. In proceedings of the NATO advanced research workshop (ARW) on climate change and its effects on water resources, edited by A. Baba, G. Tayffur, O. Gunduz, K.W.F. Howard, M.J. Fridel. *Journal of Hydrology*, 23 (51), 225-234.
- Fistikoglu, O., Gunduz, O., & Simsek, C. (2016). The correlation between statistically downscaled precipitation data and groundwater level Records in North-Western Turkey. *Water Resources Management*, 15 (7), 122-129.
- Jyrkama, M. I., & Sykes, J. F. (2007). The impact of climate change on spatially varying ground water recharge in the Grand river watershed Ontario. *Journal of hydrology*, 5 (338), 237-250.
- Bai, M. D., & Jha, M. K. (2012). Hydrologic time series analysis: theory and practice. Springer Science & Business Media.
- Bai, C., Hong, M., Wang, D., Zhang, R., & Qian, L. (2014). Evolving an information diffusion model using a genetic algorithm for monthly river discharge time series interpolation and forecasting. *Journal of Hydrometeorology*, 15 (6), 2236-2249.
- Bisht, D., & Jangid, A. (2011). Discharge modelling using adaptive neuro-fuzzy inference system. *International Journal of Advanced Science and Technology*, 31 (1), 99-114.
- Rashmi, N., & Sudhir, N. (2017). Multivariate rainfall-runoff modeling of Kulfo River. *Journal of Current Environmental Engineering Continued as Current Environmental Management*, 4 (3), 177-188.

8. Tsakiri, K. G., Marsellos, A., & Kapetanakis, S. (2018). Artificial neural network and multiple linear regression for flood prediction in Mohawk River, New York. *Water*, 10 (9), 1158.
9. Mohtasham, M., Dehghani, A.A., Akbarpour, A., & Meftah Halghi, M. (2017). Evaluation of Artificial Neural Networks and MODFLOW Numerical Model in Forecasting Groundwater Table (Case Study: Birjand Aquifer, Southern Khorasan). *Iranian Journal of Irrigation and Drainage*, 1 (4), 1-10. [In Persian]
10. Mokhtari, Z., Nazemi, A. H., & Nadiri, A. (2013). Forecasting the underground water level with artificial neural networks model (Case study: Shabestar plain). *Journal of Geotechnical Geology*, 8 (4), 345-353. [In Persian]
11. 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. [In Persian]
12. Saeedi Razavi, B., & Arab, A. (2019). Groundwater Level Prediction of Ajabshir Plain using Fuzzy Logic, Neural Network Models and Time Series. *Hydrogeology*, 3 (2), 69-81. [In Persian]
13. 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. [In Persian]
14. Jandaghi, N. (2022). Modeling of Monthly Groundwater Level Using Artificial Neural Network Model. 40th National Geosciences of Earth Sciences, Tehran, Iran. [In Persian]
15. Ghezelsoufi, 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 Journal*, 12 (3), 165-188. [In Persian]
16. Jandaghi, N. (2023). Study on the forward process in monthly rainfall modeling using Artificial Neural Network. 17th National Conference on Watershed Management Sciences and Engineering of Iran (Watershed Management & Sustainable Food Security), University of Jiroft, Iran. [In Persian]
17. Eslamiyan, S. S., Nasri, M., & Rahimi, N. (2009). Wet and dry periods and its effects on water resources changes in Buin plain watershed. *Geography and Environmental Planning Journal*, 20 (33), 75-90.
18. Amutha, R., & Porchelvan, P. (2011). Seasonal prediction of groundwater levels using ANFIS and Radial Basis Neural Network. *International Journal of Geology. Earth and Environmental Sciences*, 1 (1), 98-108.
19. Emamgholizadeh, S., Moslemi, Kh., & Karami, Gh. (2014). Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS). *Water Resources Management*, 28 (15), 5433-5446.
20. Lohani, A. K., & Krishan, G. (2015). Application of Artificial Neural Network for Groundwater Level Simulation in Amritsar and Gurdaspur Districts of Punjab, India. *Journal of Earth Science and Climatic Change*, 6 (4), 1-5.
21. Rashidi, S., Mohammadian, M., & Vagharfard, H. (2016). Predicting of Groundwater Level Fluctuation Using ANN and ANFIS in Lailakh plain. *International Journal of Advanced Biotechnology and Research*, 7 (3), 1078-1084.
22. Mohanasundaram, S., Balaji, N., & Suresh Kumar, G. (2017). Transfer function noise modelling of groundwater level fluctuation using threshold rainfall-based binary-weighted parameter estimation approach. *Hydrological Sciences Journal*, 62 (1), 36-49.
23. 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.
24. Salem, A. (2021). Forecasting rainfall in Saudi Arabia via transfer function models. *Journal of Research in Environmental and Earth Sciences*, 7 (1), 6-11.
25. Heshmatpour, A., Jandaghi, N., Pasand, S., & Ghareh Mahmoodlu, M. (2020). Drought effects on surface water quality in Golestan province for Irrigation Purposes, Case study: Gorganroud River, *Physical Geography Quarterly*. 13 (48), 75-88. [In Persian]
26. Wunsch, A., Liesch, T., & Broda, S. (2020). Groundwater level forecasting with Artificial Neural Networks: A comparison of LSTM, CNN and NARX. *Hydrology and Earth System Sciences*. 552, 1-11.
27. 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.
28. Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European journal of operational research*, 160 (2), 501-514.
29. Lohani, A.K., Kumar, R., & Singh, R. D. (2012). Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques. *Journal of Hydrology*, 1-13.
30. Wang, L. X., & Mendel, J. M. (1992). Generating fuzzy rules by learning from examples. *IEEE Transactions on systems, man, and cybernetics*, 22 (6), 1414-1427.
31. Crayer, J. (1986). Time series analysis. PWP Publication, Boston. 286 p.
32. Bowerman, B. L., & O'Connel, R. (1993). Forecasting and time series: An applied approach, Third edition, mazon Publication, 722 p.

