


Impact of wavelet on accuracy of estimated models in rainfall-runoff modeling (Case study: Sufi Chay)

Ehsan Mirzania^{*1} , Hossein Malek Ahmadi¹, Yadegar Shahmohammadi¹, Ali Ebrahimzadeh²

¹ M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

² Assistant Professor, Department of Civil Engineering, Islamic Azad University of Marand, Marand, Iran

Abstract

Introduction

In recent decades, accurate modeling of runoff has always been one of the hottest topics for researchers in the field of hydrology, as it plays an important role in water resources management, hydropower development, urban planning, irrigation and other hydrological/meteorological activity programs. Concept-based and physical models require huge amounts of data and environmental calculations. The nonlinear nature of the rainfall-runoff process and the complexity of physical models are some of the reasons why researchers have turned to intelligent models. However, these models may not provide logical results for nonlinear hydrological processes. To overcome this shortcoming, nonlinear artificial neural networks (ANNs) have depicted a real success in predicting hydrological time series.

Materials and Methods

The usefulness of wavelet transforms in noise reduction and multi-resolution analysis along with the ability of ANNs to optimize and predict hydrological processes has recently been introduced as a neural network wavelet hybrid model (WANN) and is widely used by hydrologists not only for rainfall-runoff modeling. It has been used to simulate some other components of the hydrological cycle such as river flow, groundwater, precipitation and sediment. In this study, precipitation and discharge data on a monthly scale have been used. For modeling in this research, ANN and WANN have been used. Data were used for Sufi Chay Basin for period 2001-2019.

Results and Discussion

In this study, for modeling rainfall-runoff by neural network in MATLAB 2018 Software and investigating the effect of using wavelet transform on the accuracy of rainfall-runoff model has been done. First, the existence of autocorrelation and its significance in runoff data were investigated using the partial autocorrelation function (PACF). In the hybrid model, Daubechies mother wavelets 3 and 4 are used. Six scenarios were examined for modeling. Among the selected scenarios, scenarios 4 and 5 had the best results in comparison between the two models. The poor accuracy of the first three scenarios (Scenarios 1-3) indicates that using rainfall data alone are not sufficient to model runoff, thus employing the last monthly runoff data into the model made a significant change in the results. In the ANN model, scenario 4 has more acceptable results with correlation coefficient (r), square root mean square error (RMSE) and Nash Sutcliffe coefficient (NSE) of 0.889, 51.574 and 0.788, respectively for the training section, and 0.779, 70.625, and 0.595, respectively for the test section. In the hybrid model WANN, scenario 5 has the best results with the values of r, RMSE and NSE of 0.997, 23.99 and 0.954, respectively for the training section, and 0.829, 62.334 and 0.684, respectively for the test section.

Conclusion

In the present study, the performance of ANN and WANN models for rainfall-runoff modeling in Sufi Chay Basin using different parameters of rainfall and discharge delays during the statistical period (2001-2019) was evaluated. The highest accuracy of the models was provided in combining runoff input with a time delay and monthly precipitation. The purpose of this study is the effect of wavelet on increasing the accuracy of estimation in rainfall-runoff modeling. The results of the present study showed that the hybrid model will increase the accuracy of a model.

Keywords: Rainfall-Runoff, ANN, WANN, Sufi Chay.

Article Type: Research Article

*Corresponding Author, E-mail: e.mirzania99@ms.tabrizu.ac.ir

Citation: Mirzania, E., Malek Ahmadi, H., Yadegar Shahmohammadi, Y., & Ebrahimzadeh, A. (2021). Impact of wavelet on accuracy of estimated models in rainfall-runoff modeling (Case study: Sufi Chay. *Water and Soil Management and Modeling*, 1(3), 67-79.

DOI: 10.22098/MMWS.2021.9335.1035

DOR: 20.1001.1.27832546.1400.1.3.6.8

Received: 03 August 2021; Accepted: 19 August 2021

Water and Soil Management and Modeling, Year 2021, Vol. 1, No. 3, pp. 67-79

Publisher: University of Mohaghegh Ardabili

© Author(s)





تأثیر موجک بر افزایش دقت مدل‌های تخمینی در مدل‌سازی بارش-رواناب (مطالعه موردی: حوضه صوفی‌چای)

احسان میرزانیان^{۱*}، حسین ملک احمدی^۱، یادگار شاه‌محمدی^۱، علی ابراهیم‌زاده^۲

^۱ دانشجوی کارشناسی ارشد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
^۲ استادیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد مرند، مرند، ایران

چکیده

فرآیند بارش-رواناب از مهم‌ترین و پیچیده‌ترین پدیده‌ها در چرخه هیدرولوژی بوده و در مدل‌سازی آن، دیدگاه‌های متفاوتی برای توسعه و بهبود مدل‌های پیش‌بینی‌کننده ارائه شده است. لذا، بر حسب استفاده از روش‌های گوناگون، انواع مدل‌ها توسعه یافته‌اند. در این تحقیق فرآیند بارش-رواناب در حوضه صوفی‌چای با استفاده از شبکه عصبی مصنوعی (ANN) و هیبرید موجک-شبکه عصبی (WANN) مورد مطالعه قرار گرفته است. داده‌های بارش-رواناب در طول دوره آماری (۹۸-۱۳۸۰) برای آموزش و صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت و شش سناریو برای هر مدل در نظر گرفته شد. نتایج این سناریوها نشان داد که بهترین ورودی‌ها برای مدل‌ها، مربوط به سناریوی پنج است که در آن از دبی با یک تأخیر، بارش ماه مورد نظر و بارش با یک تأخیر استفاده شده است. در حالت کلی نتایج حاکی از دقت قابل قبول هر دو مدل است. از لحاظ اولویت نیز مدل WANN با بیش‌ترین دقت ضریب همبستگی (R)، جذر میانگین مربع خطاها (RMSE) و ضریب نش-ساتکلیف (NSE) به ترتیب برابر ۰/۹۷، ۲۳/۹۹ و ۰/۹۵ برای مرحله آموزش و ۰/۸۲، ۶۲/۳۳ و ۰/۶۸ برای مرحله آزمون کمترین خطا در اولویت اول و مدل ANN در اولویت بعدی با مقادیر ضریب همبستگی (R)، جذر میانگین مربع خطاها (RMSE) و ضریب نش-ساتکلیف (NSE) به ترتیب برابر ۰/۹۳، ۴۰/۴۱ و ۰/۸۷ برای بخش آموزش و ۰/۸۱، ۷۳/۴۰ و ۰/۵۶ برای بخش آزمون قرار گرفتند و نتایج گویای این بود که موجک باعث بهبود نتایج و پیش‌بینی در مدل‌سازی بارش-رواناب شده است.

واژه‌های کلیدی: بارش-رواناب، شبکه عصبی مصنوعی، هیبرید موجک-شبکه عصبی، صوفی‌چای

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: e.mirzania99@ms.tabrizu.ac.ir

استناد: میرزانیان، ا.، ملک احمدی، ح.، شاه‌محمدی، ی.، و ابراهیم‌زاده، ع. (۱۴۰۰). تأثیر موجک بر افزایش دقت مدل‌های تخمینی در مدل‌سازی بارش-رواناب (مطالعه موردی: حوضه صوفی‌چای). *مدل‌سازی و مدیریت آب و خاک*، ۱(۳)، ۶۷-۷۹.

DOI: 10.22098/MMWS.2021.9335.1035

DOR: 20.1001.1.27832546.1400.1.3.6.8

تاریخ دریافت: ۱۴۰۰/۰۵/۰۱، تاریخ پذیرش: ۱۴۰۰/۰۵/۲۸

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۰، دوره ۱، شماره ۳، صفحه ۶۷ تا ۷۹

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

هیبرید موجکی شبکه عصبی (WANN) اخیراً معرفی شده و به‌طور گسترده‌ای توسط هیدرولوژیست‌ها نه تنها برای مدل‌سازی بارش-رواناب استفاده شده است، بلکه برای شبیه‌سازی برخی دیگر از اجزای چرخه هیدرولوژیکی مانند جریان رودخانه، آب زیرزمینی، بارش و رسوب (Nourani et al., 2015) مورد استفاده قرار گرفته است. نتایج نشان داد که اگرچه پیش‌پردازش داده‌های مبتنی بر موجک می‌تواند کارایی مدل‌سازی را در مقیاس‌های مختلف زمانی (کوتاه‌مدت و بلندمدت) بهبود بخشد، اما این پیشرفت در مقیاس‌های زمانی بزرگ (مانند فصلی یا ماهانه نسبت به روزانه یا ساعتی) معقول‌تر است؛ زیرا در بیش‌تر فرآیندهای هیدرولوژیکی (به‌عنوان نمونه، بارش-رواناب)، الگوهای فصلی (دوره‌ای) در سری‌های زمانی در مقیاس بزرگ با توجه به سری زمانی با مقیاس کوچک غالب‌ترند (Sharghi et al., 2018).

مطالعات متعددی در زمینه مدل‌سازی فرآیند بارش-رواناب صورت گرفته است. برای نمونه، Ghorbani et al. (2015) فرآیند بارش-رواناب روزانه در حوضه بالیخلوچای با استفاده از ماشین‌بردار پشتیبان، شبکه‌های عصبی مصنوعی، هیبرید موجک - ماشین‌بردار پشتیبان و هیبرید موجک-شبکه عصبی را مورد مطالعه و مقایسه قرار داده‌اند. داده‌های بارش-رواناب روزانه در طول دوره آماری (۱۳۷۹-۱۳۸۷) برای آموزش و صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. در حالت کلی نتایج حاکی از دقت قابل قبول هر چهار روش است. از لحاظ اولویت نیز مدل هیبرید موجک- شبکه عصبی با بیش‌ترین دقت و کمترین خطا در اولویت اول و مدل‌های هیبرید موجک-ماشین‌بردار پشتیبان، شبکه عصبی مصنوعی و ماشین‌بردار پشتیبان به ترتیب در اولویت‌های بعدی قرار گرفتند. هم‌چنین، Alizadeh et al. (2017) رویکرد جدیدی را برای پیش‌بینی بارش و رواناب در حوضه رودخانه تولت طی دو ماه آینده ارائه کردند. برای این منظور، ترکیبی از تبدیل موجک و شبکه عصبی مصنوعی شامل هر دو سری زمانی مشاهده شده و پیش‌بینی شده در ساختار ورودی در نظر گرفته شد. نتایج نشان داد که می‌توان با استفاده از روش جدید، پیش‌بینی قابل اطمینان از روند بارندگی و رواناب برای یک و دو ماه آینده به‌دست آورد.

Sharghi et al. (2019) به بررسی ارتباط بین شبکه عصبی مصنوعی حساس (EANN) و تبدیل موجک برای مدل‌سازی بارش-رواناب پرداختند. نتایج به‌دست آمده برای مدل‌سازی ماهانه نشان داد که هیبرید شبکه عصبی مصنوعی حساس و موجک (WEANN) به ترتیب از نظر اعتبار و معیارهای کارایی آموزش می‌تواند از مدل‌های WANN و EANN تا ۱۷ و ۳۵ درصد بهتر عمل کند. (Shafeizadeh et al., 2019) در تحقیق

در دهه‌های اخیر، مدل‌سازی دقیق بارش رواناب همیشه یکی از جالب توجه‌ترین مباحث محققان در زمینه هیدرولوژی بوده است؛ زیرا نقش مهمی در مدیریت منابع آب، توسعه نیروگاه‌های برق‌آبی، برنامه‌ریزی شهری، آبیاری و سایر برنامه‌های فعالیت‌های هیدرولوژی و هواشناسی دارد (Alizadeh et al., 2017). فرآیند بارش-رواناب، که به دلیل تعامل عوامل مختلف مکانی-زمانی به‌عنوان یک سیستم پیچیده شناخته می‌شود و یک جز قابل توجه از چرخه آب است که نقش مهمی در برنامه‌ریزی مدیریت منابع آب دارد (Nourani et al., 2019). مدل‌های مبتنی بر مفهوم و فیزیکی به حجم عظیمی از داده‌ها و محاسبات محیطی نیاز دارند. خاصیت غیرخطی فرآیند بارش-رواناب و پیچیده بودن مدل‌های فیزیکی از دلایلی است که باعث شده محققان به سوی مدل‌های هوشمند روی آورند.

با این حال، این مدل‌ها ممکن است نتایج منطقی در خصوص فرآیندهای هیدرولوژیکی غیرخطی ارائه ندهند. برای غلبه بر این کمبود، شبکه‌های عصبی مصنوعی غیرخطی (ANNs) یک موفقیت واقعی را در پیش‌بینی سری‌های زمانی هیدرولوژیک به تصویر کشیده‌اند (Sharghi et al., 2018). از معروف‌ترین و پرکاربردترین روش‌های موجود در بحث بارش-رواناب، شبکه‌های عصبی مصنوعی هستند که به‌خصوص در دهه اخیر کاربرد فراوانی در برآورد متغیرها در مسائل مختلف داشته‌اند.

الف) شبکه‌های عصبی مصنوعی ابزار جعبه سیاه هستند؛ بنابراین، نیازی به اطلاعات قبلی در مورد فیزیک پدیده‌ها نیست. ب) شبکه‌های عصبی ملی به‌صورت غیرخطی ذاتی هستند. این غیرخطی بودن از طریق سلول‌های عصبی و فعال‌سازی تأمین می‌شود. ج) شبکه‌های عصبی مصنوعی ممکن است ورودی‌های متغیر و متفاوتی داشته باشند و به همین دلیل می‌توانند تنوع مکانی-زمانی ایجاد کنند. د) شبکه‌های عصبی ملی (ANN) برای تغییر در محیط‌های پیچیده سازگار هستند (Kim and Valdés, 2003).

علی‌رغم توانایی شبکه‌های عصبی مصنوعی برای مدل‌سازی متغیرهای هیدرولوژیکی، هنگامی که مجموعه داده‌های موجود شامل نمونه داده‌های ناکافی باشد یا سری‌های زمانی مشاهده شده شامل نرخ بالای تغییرات غیرثابت و فصلی باشد، کمبودهایی وجود دارد. برای دستیابی به دقت قابل اطمینان پیش‌بینی‌ها و غلبه بر چنین کمبودهایی، برخی از رویکردهای پیش‌پردازش داده‌ها براساس تبدیل موجک پیشنهاد شده و در مباحث مدل‌سازی هیدرولوژیکی استفاده شده است.

سودمندی تبدیل موجک در تحلیل نویززدایی و چند تفکیک‌پذیری همراه با توانایی شبکه‌های عصبی مصنوعی در بهینه‌سازی و پیش‌بینی فرآیندهای هیدرولوژیکی به‌عنوان مدل

عصبی به‌منظور مدل‌سازی بارش-رواناب حوضه صوفی‌چای شهرستان مراغه در شمال غرب کشور ایران است.

۲- مواد و روش‌ها

۲-۱- منطقه مطالعاتی

منطقه مورد مطالعه این تحقیق حوضه صوفی‌چای به‌عنوان یکی از زیر حوضه‌های اصلی سد علویان واقع در شمال غرب ایران و حد فاصل عرض‌های شمالی ۳۷ درجه ۱۴ دقیقه و ۴۳ ثانیه تا ۳۷ درجه ۴۴ دقیقه و ۱۲ ثانیه و طول‌های شرقی ۴۵ درجه ۵۶ دقیقه و ۲۹ ثانیه تا ۴۶ درجه ۲۶ دقیقه و ۵۶ ثانیه است (شکل ۱). ارتفاع حوضه در بالادست روستای علویان بین ۱۴۹۵ تا ۳۳۹۸ متر متغیر است. حوضه صوفی‌چای از دامنه‌های جنوبی کوه سهند سرچشمه می‌گیرد که رودخانه‌های شاخص جنوب شرق دریاچه ارومیه در این حوضه‌ها قرار دارند. نزدیک‌ترین ایستگاه‌های هیدرومتری و سینوپتیک به حوضه صوفی‌چای به‌ترتیب ایستگاه‌های هیدرومتری تازه کند سدعلویان و سینوپتیک مراغه است و پارامترهای هیدرولوژیکی مورد استفاده در این تحقیق شامل مقادیر ماهانه بارش ایستگاه تبخیرسنجی سد علویان در بازه زمانی (۱۳۸۰/۷/۱-۱۳۹۸/۶/۳۱) و نیز مقادیر ماهانه دبی ایستگاه هیدرومتری تازه‌کند در بازه زمانی (۱۳۸۰/۷/۱-۱۳۹۸/۶/۳۱) است. مشخصات آماری پارامترهای مذکور در جدول ۱ ارائه شده است.

۲-۲- شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی روشی است که مدل جعبه سیاه را ارائه می‌دهد و می‌تواند برای حل مشکلات مختلف پیچیده مورد استفاده قرار گیرد. از شبکه‌های عصبی برای گرفتن رابطه بین ورودی و خروجی بدون هیچ جزئیاتی در مورد فرآیند داخلی استفاده می‌شود. شبکه‌های عصبی مصنوعی بر اساس استنباط از سیستم عصبی بیولوژیکی استوار است (Nouri et al., 2008). شبکه‌های عصبی مصنوعی به‌عنوان ابزاری کارآمد برای آشکار کردن رابطه غیرخطی ورودی و خروجی مورد استفاده قرار می‌گیرند (شکل ۲). علی‌رغم مدل‌های مفهومی، هنگام برخورد با مدل‌های روابط ریاضی بین ورودی و خروجی تعریف نشده است. یک مدل معمول شبکه عصبی مصنوعی (forward feed neural network) شامل سه لایه متمایز ورودی، مخفی و خروجی است. هر لایه دارای مجموعه‌ای از گره‌ها (نورون‌ها) است که در آن‌ها به‌طور کامل با گره‌های لایه زیر مرتبط هستند. این مدل دارای یک مرحله تغذیه رو به جلو است که در آن سیگنال‌های ورودی در جهت جلو (لایه به‌لایه) برای رسیدن به لایه خروجی و یک فرآیند انتشار به‌عقب خطا که قدرت اتصال (وزن) را اصلاح می‌کند، پخش می‌شوند. خطا به‌عنوان تفاوت بین

خود به شبیه‌سازی پیوسته بارش-رواناب در حوضه سد مارون با شبکه‌های عصبی مصنوعی پرداختند تا توانایی و دقت این شبکه در برآورد رواناب ارزیابی شود. مقایسه مقادیر معیارهای آماری بین مدل‌های تک‌ضابطه‌ای و دوضابطه‌ای نشان داد که دقت مدل دوضابطه‌ای در برآورد دبی جریان در ایستگاه ایدنک بیش‌تر از دقت مدل تک‌ضابطه‌ای بود. به‌طوری که ضریب نش-ساتکلیف برای مدل تک‌ضابطه‌ای و دوضابطه‌ای به ازای مرحله آزمون شبکه به‌ترتیب برابر با ۰/۸۶ و ۰/۹۴ بود.

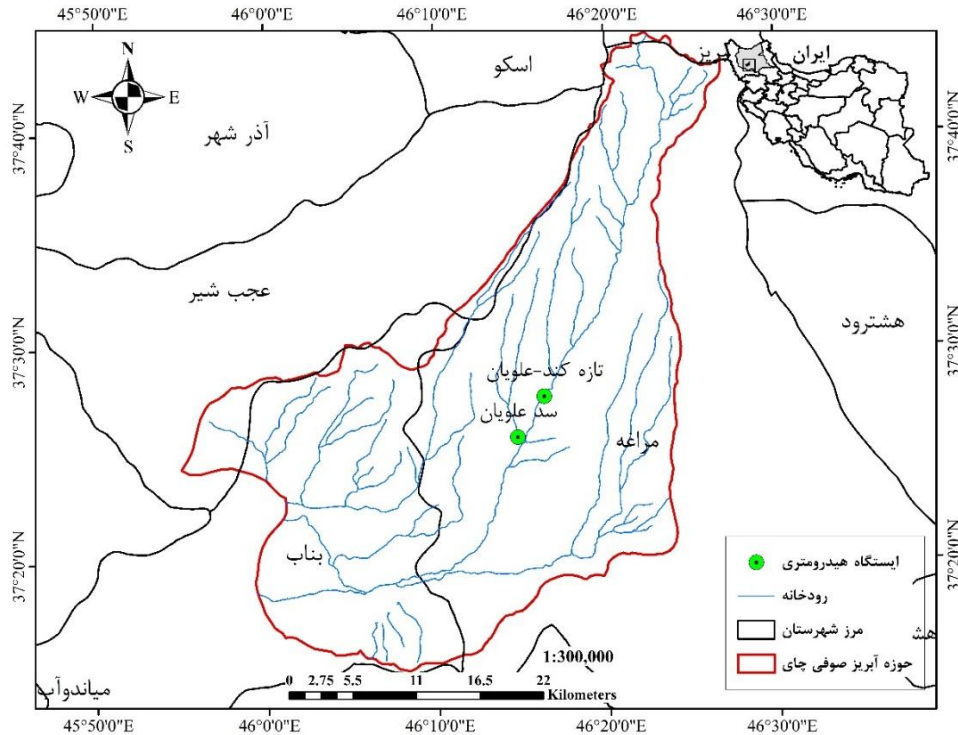
Afifi (2020) شبیه‌سازی بارش-رواناب و پتانسیل سیل‌خیزی با استفاده از مدل HEC-HMS و منطق فازی مطالعه موردی حوضه رود بال در استان فارس پرداخت. نتایج شبیه‌سازی نشان‌دهنده کارایی بالای مدل HEC-HMS در شبیه‌سازی بارش-رواناب حوضه رود بال و برآورد دبی‌های پیک سیلاب است. همچنین، Tikhamarine et al. (2020) در تحقیق خود به مدل‌سازی بارش-رواناب با استفاده از روش‌های پیشرفته یادگیری ماشین شامل بهینه‌ساز هریس هاوکس (HHO) در مقابل بهینه‌سازی ازدحام ذرات (PSO) پرداختند و نتایج نشان داد که تمام مدل‌های افزوده شده با HHO نسبت به سایر مدل‌های یکپارچه با PSO در پیش‌بینی تغییرات رواناب بهتر بودند. در ادامه، Dumka and Kumar (2021) به مدل‌سازی بارش-رواناب با استفاده از شبکه عصبی مصنوعی و شبکه هیبرید عصبی-موجک (WANN) برای سد هاریپورا، اوتاراخند پرداختند. مدل‌های WANN ضریب همبستگی بهتر، میانگین مربعات خطای مربع کمتر و NSE بیش‌تر در مقایسه با مدل‌های شبکه عصبی مصنوعی ارائه دادند. این نتایج می‌تواند برای پیش‌بینی رواناب برای اهداف مختلف مانند هدف آبیاری مفید باشد. اخیراً، Kavusi and Khozayemeh Nejad (2021) در تحقیق خود از چهار مدل مبتنی بر داده PSO، GEP، NN، SVM-LS و ANFIS و همچنین از داده‌های هفت ایستگاه هواشناسی بالادست سد جیرفت در استان کرمان در بازه زمانی ۱۳۷۸ تا ۱۳۹۴ برای شبیه‌سازی فرآیند بارش-رواناب سد جیرفت در استان کرمان استفاده شد. نتایج پژوهش براساس دو معیار ضریب همبستگی (r)، ریشه متوسط مربعات خطا (RMSE) نشان داد که روش PSO-ANFIS با مقدار RMSE برابر ۰/۴۲ مترمکعب بر ثانیه و r برابر ۰/۹۵ در بخش آموزش و RMSE و r به میزان ۰/۹۷ مترمکعب بر ثانیه و ۰/۸۰ در بخش صحت‌سنجی بهترین روش از بین مدل‌های مورد بررسی بود و در هر دو بخش آموزش و صحت‌سنجی دقت بالاتری نسبت به سه مدل دیگر داشت. لذا با توجه به موارد فوق هدف از این تحقیق، بررسی عملکرد مدل شبکه عصبی مصنوعی و الگوریتم هیبریدی موجک-شبکه

فعال‌سازی (خطی) برای لایه خروجی. N و M تعداد نورون‌ها را به ترتیب در لایه‌های ورودی و پنهان نشان می‌دهد. w_{ko} و w_{jo} وزن نورون j در لایه پنهان و نورون k در لایه خروجی هستند. w_i وزن بین گره ورودی i و گره پنهان k است، و w_{kj} وزن بین گره پنهان j و گره خروجی k هستند.

مقادیر محاسبه شده و مشاهده شده متغیر هدف تعریف می‌شود. به طور کلی، مدل شبکه عصبی مصنوعی می‌تواند به شکل ریاضی به صورت زیر تنظیم شود (Jeong and Kim, 2005):

$$O_k = g_2 \left[\sum_{j=1}^M w_{kj} g_1 \left(\sum_{i=1}^N w_{ji} x_i + w_{jo} \right) + w_{ko} \right] \quad (1)$$

که در آن، x_i برابر مقدار ورودی به گره i ، O_k خروجی در گره k ، g_1 تابع فعال‌سازی (غیرخطی) برای لایه مخفی و g_2 تابع



شکل ۱- موقعیت منطقه مطالعاتی
Figure 1- Location of study area

الگوریتم‌ها را می‌توان برای آموزش شبکه‌های عصبی مصنوعی از جمله شیب نزولی و الگوریتم‌های سریع‌تر با استفاده از تکنیک‌های ابتکاری یا بهینه‌سازی استفاده کرد (Beale and Demuth, 1998; Chen et al., 2015). پارامترهای استفاده شده برای مدل‌سازی شبکه عصبی مصنوعی در جدول ۲ ذکر شده است.

جدول ۲- مقادیر متغیرهای مورد استفاده در مدل شبکه عصبی
Table 2- The values of the variables used in the neural network model

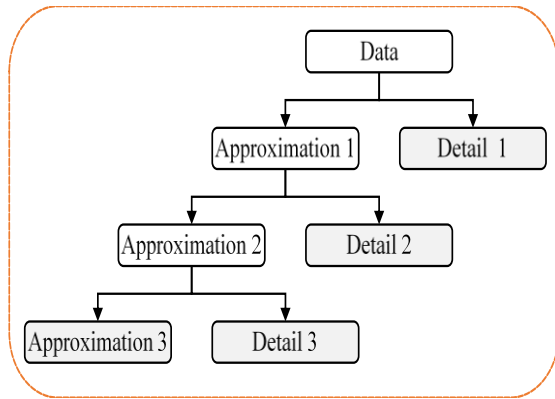
متغیر	بهترین مقدار
نوع شبکه عصبی	Feed-Forward back propagation
تعداد لایه پنهان	1
الگوریتم آموزشی	Levenberg-Marquardt
تعداد نورون	3 - 10
تابع انتقالی لایه اول	tansig
تابع انتقالی لایه دوم	purelin
تعداد تکرار	1000

جدول ۱- مشخصات آماری بارش و رواناب


Table 1- Statistical information of rainfall and runoff

مشخصات آماری	بارش (mm)	دبی (m ³ /s)
حداقل	0	1.16
حداکثر	142.50	624.07
چارک اول	3.50	22.46
میانه	19.00	36.34
چارک سوم	45.50	117.25
میانگین	29.61	91.27
واریانس	1098.18	12504.16
انحراف معیار	33.14	111.82
چولگی	1.49	1.96
کشیدگی	1.79	3.64

به منظور دستیابی به عملکرد مناسب مدل‌های شبکه عصبی، تعدادی از پارامترها مانند تعداد تکرار، تعداد نورون‌های موجود در لایه پنهان، وزن‌ها و بایاس‌ها باید بر این اساس تنظیم شوند. این معمولاً از طریق مرحله آموزش اتفاق می‌افتد. انواع مختلف



شکل ۳- نمای شماتیک تبدیل موجک
Figure 3- Schematic view of wavelet transform



شکل ۲- نمای شماتیک مدل شبکه عصبی
Figure 2- Schematic view of neural network model

جدول ۳- مقادیر متغیرهای مورد استفاده در تبدیل موجک
Table 3- The values of the variables used in the Wavelet transform

متغیر	بهترین مقدار
موجک مادر	Daubechies 3-4
سطح تجزیه	3
تعداد سری تخمین	1
تعداد سری جزئیات	3

۲-۴- شاخص‌های عملکرد آماری

به منظور بررسی عملکرد مدل‌های استفاده شده در این مقاله لازم است شاخص‌های عملکرد را در مدل محاسبه کرد و مورد بررسی قرار داد در این مقاله از شاخص‌های عملکرد زیر برای سنجش دقت و عملکرد مدل‌های شبکه عصبی و هیبرید شبکه عصبی و موجکی استفاده شده است.

ضریب همبستگی (R):

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

جزر میانگین مربع خطاها (RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{pred,i} - Q_{obs,i})^2} \quad -\infty < RMSE < \infty \quad (5)$$

ضریب نش - ساتکلیف (NSE):

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (Q_{obs,i} - Q_{pred,i})^2}{\sum_{i=1}^N (Q_{obs,i} - \bar{Q}_{obs})^2} \right] \quad -\infty < NSE < 1 \quad (6)$$

که در معادلات ۴، ۵ و ۶ $Q_{obs,i}$ مقدار رواناب مشاهداتی، $Q_{pred,i}$ مقدار رواناب محاسباتی، N تعداد داده‌ها و \bar{Q}_{obs} و \bar{Q}_{pred} به ترتیب مقدار میانگین رواناب مشاهداتی و محاسباتی است (Tikhmarine et al., 2020). شکل ۴ روند انجام مطالعه حاضر را نمایش می‌دهد.

۲-۳- موجک

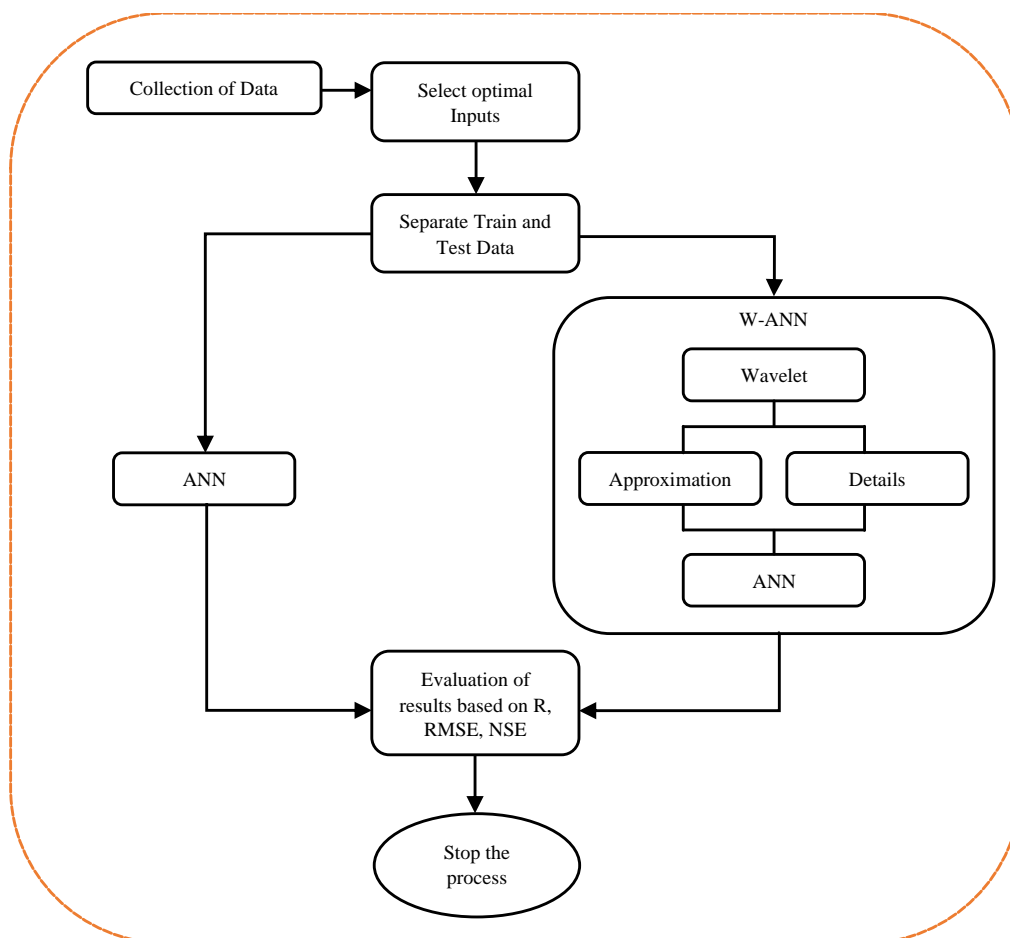
تبدیل موجک یک تبدیل ریاضی است که از توابع پایه‌ای به نام موجک استفاده می‌کند (شکل ۳). تبدیل موجک این قابلیت را دارد که یک سیگنال را به صورت زمان-مقیاس بررسی نماید. با استفاده از تبدیل یا تحلیل موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد (Nouri et al., 2008). تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه ارائه شده است و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه زمان کوتاه، سیگنال موردنظر به پنجره‌هایی تقسیم شده و تبدیل موجک روی هر کدام از این پنجره‌ها به صورت جداگانه انجام می‌گیرد (Vapnik, 1988). توانایی‌های این روش برای تجزیه سری‌های زمانی باعث شده است امروزه از این روش برای تولید ورودی مدل‌های هوشمند مثل شبکه عصبی استفاده شود، که افزایش دقت را در این مدل‌ها نشان داده است.

روش موجک از تابع موجک مادر برای تجزیه داده‌ها به تخمین و جزئیات استفاده می‌کند. تبدیل موجک به صورت رابطه‌های ۲ و ۳ صورت می‌پذیرد (Vapnik, 1988):

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \Psi\left(\frac{t-\tau}{s}\right) \quad (2)$$

$$CWT_f^\Psi(s,\tau) = \Psi_f^\Psi(s,\tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \Psi\left(\frac{t-\tau}{s}\right) dt = \langle f(t), \Psi_{s,\tau}(t) \rangle \quad (3)$$

رابطه ۲ یک رابطه با دو متغیر s و τ است که s پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال هستند. علامت * نیز نشان‌دهنده مزدوج مختلط است و Ψ نماد موجک مادر است. در جدول (۳) پارامترهای استفاده شده برای تبدیل موجک ارائه شده است.



شکل ۴- شمای کلی روند انجام کار

Figure 4- Flowchart of study steps


۳ و ۴ استفاده شد که نمودار سری تجزیه شده با استفاده از این موجک مادر در شکل ۶ برای داده‌های بارش و در شکل ۷ برای داده‌های رواناب مشاهده می‌شود. داده‌ها تا سه سطح تجزیه شدند و سپس یک تخمین اصلی و سه جزئیات به شبکه عصبی داده شد (در واقع سری زمانی داده‌های ورودی به چهار قسمت تجزیه شد). نتایج مدل‌های شبکه عصبی (ANN) و هیبرید شبکه عصبی و موجکی (W-ANN) در جدول ۴ نشان داده شده است. در بین سناریوهای انتخاب شده، دو سناریوی ۴ و ۵ بهترین نتیجه را در دو مدل داشته‌اند، که نمودار پراکندگی و سری زمانی در شکل‌های ۸ و ۹ به ترتیب برای شبکه عصبی و هیبرید موجکی عصبی مشاهده می‌شود. عدم دقت سه سناریوی اول (سناریوهای ۱، ۲ و ۳) نشان‌دهنده کافی نبودن داده‌های بارش به‌تنهایی برای مدل‌سازی رواناب است و استفاده از داده‌های رواناب ماه گذشته تغییر بسیار چشم‌گیری را در نتایج نشان داده است. در مدل شبکه عصبی سناریوی ۴ نتایج قابل قبول‌تری داشته که مقادیر ضریب همبستگی (R)، جذر میانگین مربع خطاها (RMSE) و ضریب نش-ساتکلیف (NSE) به ترتیب برای بخش آموزش برابر با ۰/۸۸۹، ۵۱/۵۷۴ و ۰/۷۸۸ و برای بخش

۳- نتایج و بحث

در این مطالعه تلاش برای مدل‌سازی بارش-رواناب به‌وسیله شبکه عصبی در نرم‌افزار MATLAB 2018 و بررسی تأثیر استفاده از تبدیل موجک بر دقت مدل بارش-رواناب انجام شده است. در این تحقیق از داده‌های بارش و رواناب ایستگاه هیدرومتری تازه‌کند و ایستگاه سینوپتیک مراغه در حوضه صوفی‌چای برای این مدل‌ها استفاده شده است. داده‌های بارش و رواناب با شش سناریوی مختلف به مدل‌ها داده شدند تا حالت‌های مختلف بررسی و بهترین سناریو انتخاب شود. در ابتدا به بررسی وجود خودهمبستگی و میزان معنادار بودن آن در داده‌های رواناب با استفاده از تابع خودهمبستگی جزئی (PACF) پرداخته شد. با توجه به شکل ۵ معنادار بودن خودهمبستگی تا یک ماه برای رواناب مشاهده می‌شود، اما بعد از یک ماه تأثیر معناداری دیده نمی‌شود؛ چراکه نمودار زیر باند اطمینان قرار گرفته است. در مدل عصبی d، لایه مخفی و تعداد نرون‌های بین ۳ تا ۱۰ با آزمون خطا انتخاب شد. تابع لایه اول تانژانت سیگموئید (tansig) و برای لایه دوم از تابع انتقال خطی (purelin) استفاده شد. در مدل هیبریدی از موجک مادر دایچیز


به‌صورت مستقیم باعث افزایش دقت مدل شده است، در این حالت شبکه عصبی به‌صورت جداگانه با فرکانس‌های مختلف سری زمانی ورودی‌ها آموزش می‌بیند. این نتایج تأثیر مثبت تبدیل موجکی را بر روی شبکه عصبی به‌خوبی نشان می‌دهد. اما با توجه به نتایج ضرایب عملکرد مانند ضریب نش-ساتکلیف مدل شبکه عصبی، می‌توان فهمید این مدل هم قابل قبول بوده و عملکرد نسبتاً خوبی داشته است.

آزمون برابر با ۰/۷۷۹، ۰/۶۲۵ و ۰/۵۹۵ است و در مدل هیبرید شبکه عصبی و موجکی سناریوی ۵ بهترین نتایج را داشته است که مقادیر ضریب همبستگی، جذر میانگین مربع خطاها و ضریب نش-ساتکلیف به‌ترتیب برای بخش آموزش برابر با ۰/۹۹۷، ۰/۲۳/۹۹ و ۰/۹۵۴ و برای بخش آزمون برابر با ۰/۸۲۹، ۰/۶۲/۳۳۴ و ۰/۶۸۴ به‌دست آمده است. مشاهده می‌شود با تجزیه کردن داده‌ها به فرکانس‌های کوچک‌تر و استفاده از آن‌ها برای آموزش مدل شبکه عصبی به‌جای آموزش شبکه عصبی با داده‌ها




شکل ۵- تابع خودهمبستگی جزئی برای داده‌های رواناب

Figure 5- Partial Auto Correlation Function (PACF) for runoff data



شکل ۶- داده تجزیه شده بارش به تخمین و جزئیات توسط تبدیل موجک

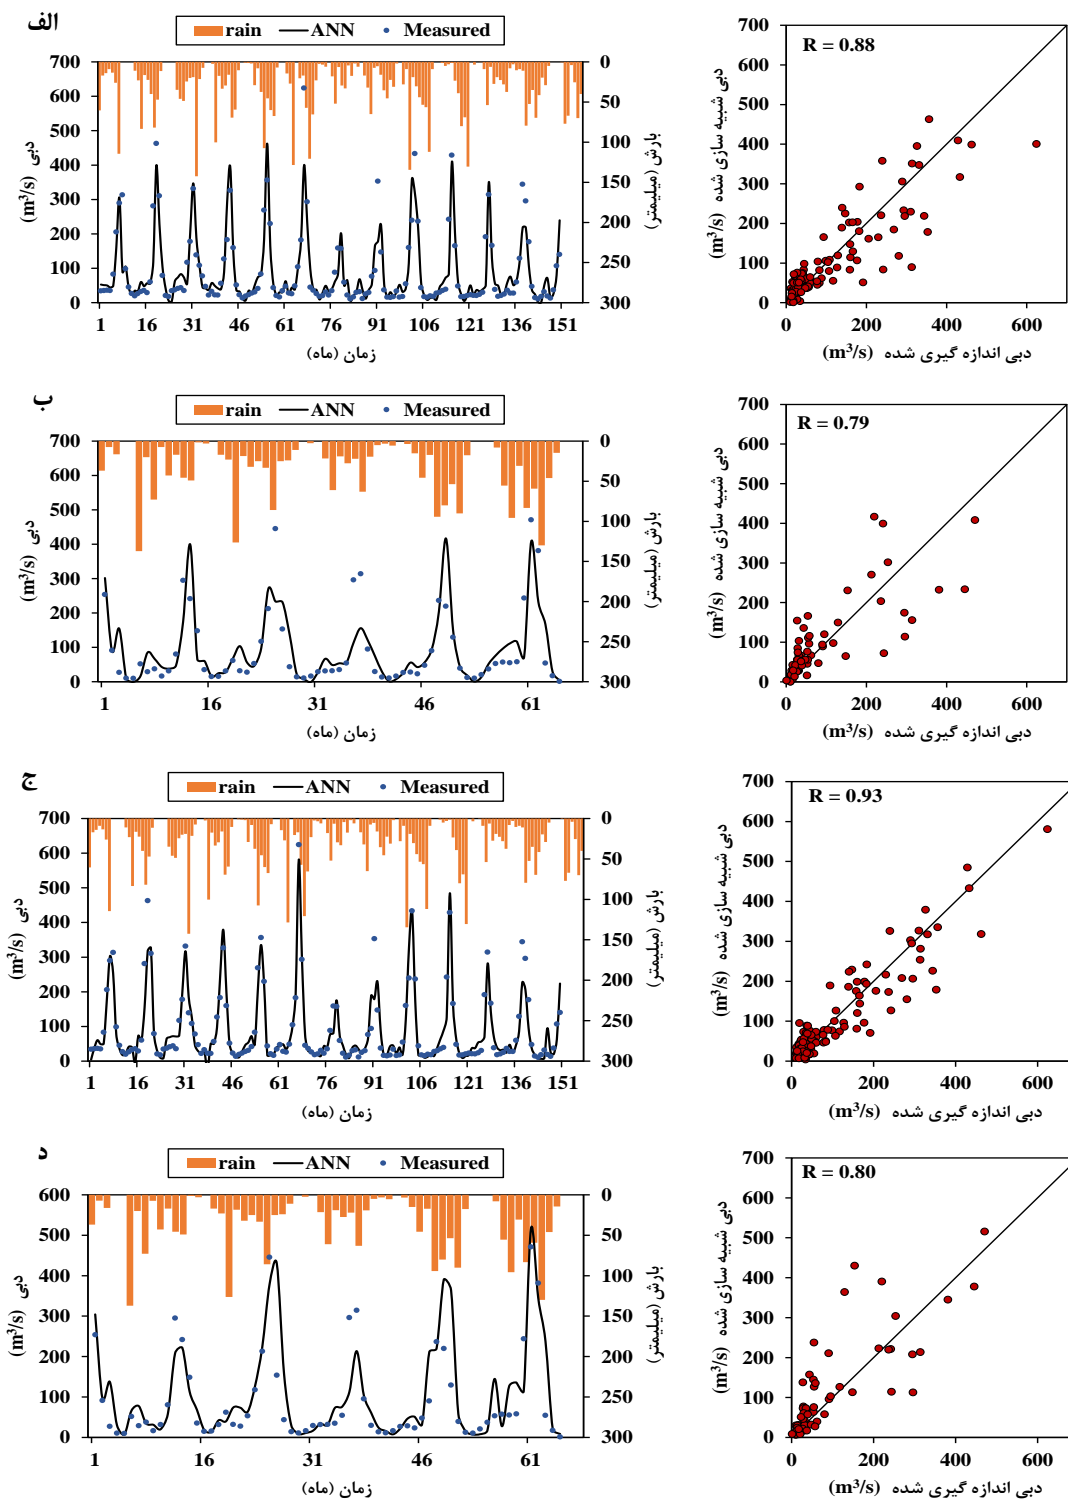
Figure 6- Decomposed rainfall data into prediction and details by wavelet transform



شکل ۷- داده تجزیه شده رواناب به تخمین و جزئیات توسط تبدیل موجک
 Figure 7- Decomposed runoff data into prediction and details by wavelet transformation

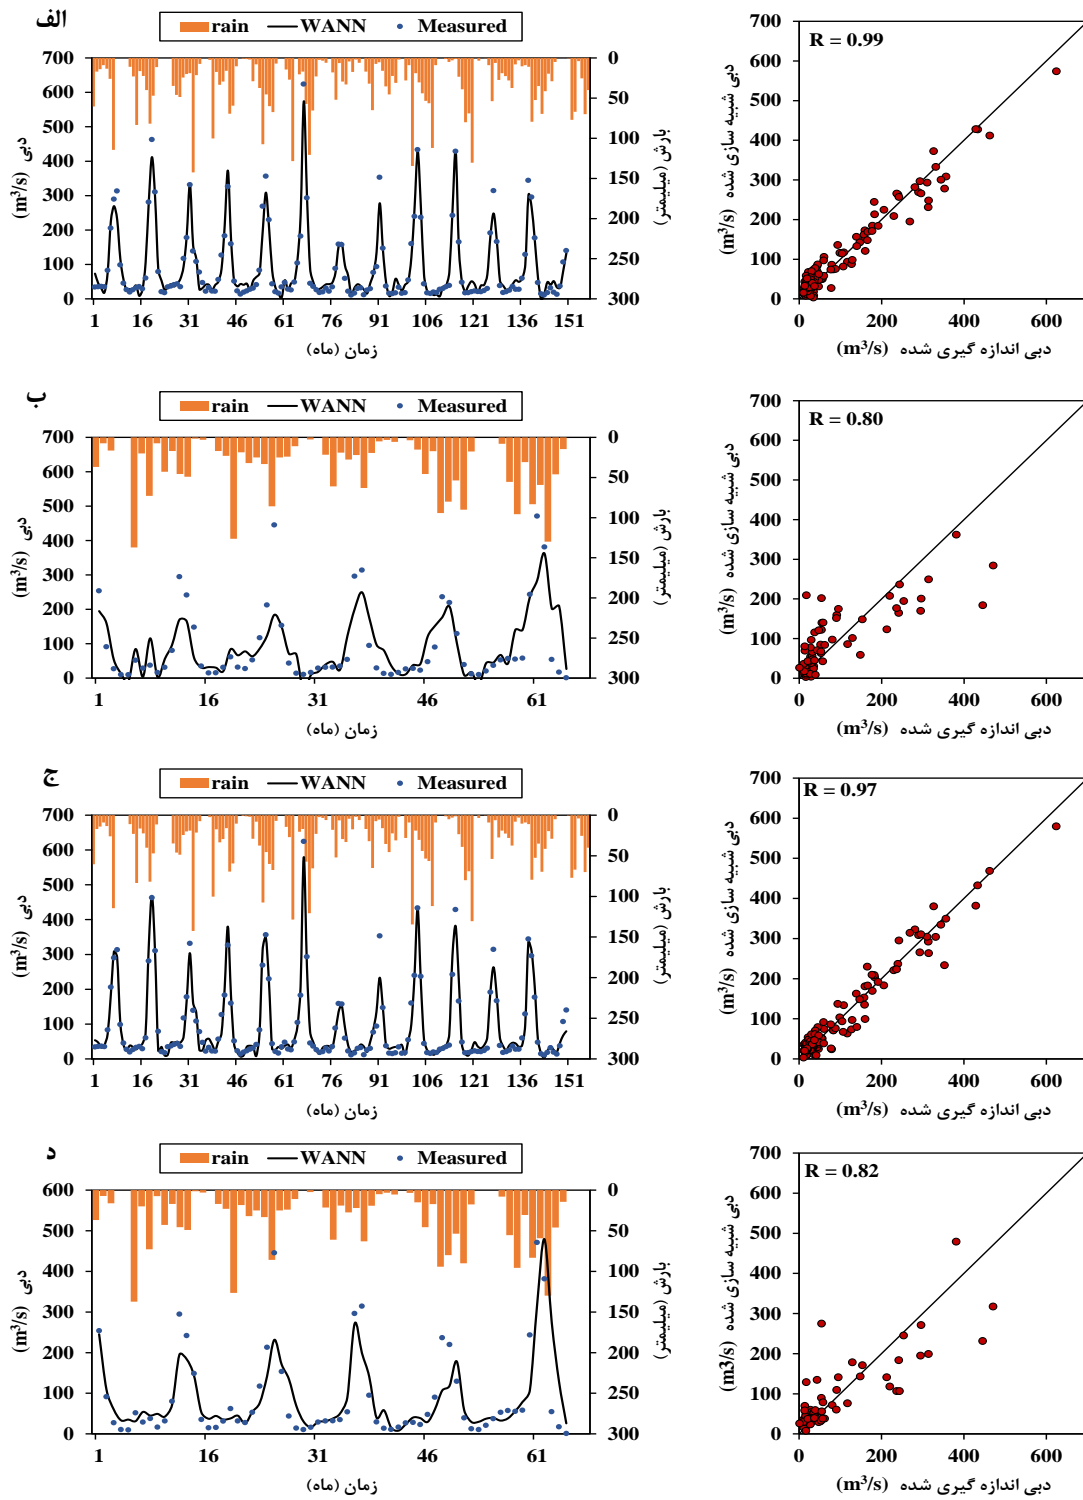
جدول ۴- الگوهای مختلف ورودی مدل و شاخص‌های عملکرد برای مراحل آموزش و آزمون
 Table 4- Different model input patterns and performance indicators in training and testing stages

سناریو	مدل	ساختار ورودی	خروجی	آموزش		آزمون	
				ضریب همبستگی	جذر میانگین مربع خطاها	ضریب همبستگی	جذر میانگین مربع خطاها
ANN	1	R_t	Q_t	0.440	100.982	0.185	106.570
	2	R_t, R_{t-1}	Q_t	0.676	84.034	0.438	102.385
	3	R_t, R_{t-1}, R_{t-2}	Q_t	0.754	74.492	0.563	90.748
	4	R_t, Q_{t-1}	Q_t	0.889	51.574	0.788	70.625
	5	R_t, R_{t-1}, Q_{t-1}	Q_t	0.933	40.411	0.870	73.398
	6	$R_t, R_{t-1}, R_{t-2}, Q_{t-1}$	Q_t	0.935	40.235	0.873	79.014
WANN	1	R_t	Q_t	0.432	109.311	0.045	137.729
	2	R_t, R_{t-1}	Q_t	0.734	77.284	0.524	89.815
	3	R_t, R_{t-1}, R_{t-2}	Q_t	0.859	58.235	0.733	94.184
	4	R_t, Q_{t-1}	Q_t	0.979	24.372	0.953	67.573
	5	R_t, R_{t-1}, Q_{t-1}	Q_t	0.977	23.999	0.954	62.334
	6	$R_t, R_{t-1}, R_{t-2}, Q_{t-1}$	Q_t	0.955	35.717	0.900	76.793



شکل ۸- نمودار پراکندگی‌ها و سری‌های زمانی آموزش و آزمون نتایج تولید شده توسط مدل شبکه عصبی بهینه برای بهترین سناریوها

(الف) سناریوی ۴ مرحله آموزش، (ب) سناریوی ۴ مرحله آزمون، (ج) سناریوی ۵ مرحله آموزش و (د) سناریوی ۵ مرحله آزمون
 Figure 8- The scatterplots and time series of the train and test results produced by the optimal ANN model for the best scenarios (a) scenario 4- training, (b) scenario 4- testing, (c) scenario 5- training, and (d) scenario 5 testing



شکل ۹- نمودار پراکندگی‌ها و سری‌های زمانی آموزش و آزمون نتایج تولید شده توسط مدل هیبرید عصبی موجکی بهینه برای بهترین سناریوها (الف) سناریو ۴ بخش مرحله (ب) سناریو ۴ مرحله آزمون (ج) سناریو ۵ مرحله آموزش (د) سناریو ۵ مرحله آزمون
 Figure 9- The scatterplots and time series of the train and test results produced by the optimal W-ANN model for the best scenarios (a) scenario 4- training, (b) scenario 4- testing, (c) scenario 5- training, and (d) scenario 5 testing

۴- نتیجه‌گیری

در پژوهش حاضر عملکرد مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی را برای مدل‌سازی بارش-رواناب ایستگاه هیدرومتری تازه‌کند و ایستگاه سینوپتیک مراغه در حوضه صوفی‌چای با استفاده از پارامترهای بارش و دبی تأخیرهای متفاوت، در طی دوره آماری (۹۸-۱۳۸۰) مورد ارزیابی قرار گرفت. به‌منظور شبیه‌سازی جریان رودخانه شش‌الگوی متفاوت تعریف شد. در کلیه مدل‌ها با ترکیب بارش و دبی دقت تخمین جریان روزانه بهبود یافت. چنانچه بیش‌ترین دقت مدل‌ها در ترکیب ورودی رواناب با یک تأخیر زمانی و بارش ماهانه فراهم شد. این نشان‌دهنده تأثیرپذیری زیاد جریان حوضه صوفی‌چای از دبی ماه قبل و بارندگی همان ماه در مدل شبکه عصبی مصنوعی ANN و دبی ماه قبل و بارندگی همان ماه و بارندگی ماه قبل در مدل WANN است. به‌همین منظور میزان تأثیرپذیر بودن دبی جریان از دبی ماه قبل به‌مراتب بیش‌تر از میزان بارندگی است و لزوماً افزایش مقدار بارندگی موجب افزایش دبی نمی‌شود. هدف

منابع

شافی‌زاده، م.، فتحیان، ح.، نیکبخت‌شهبازی، ع.ر. (۱۳۹۸). شبیه‌سازی پیوسته بارش-رواناب با استفاده از شبکه‌های عصبی مصنوعی بر مبنای انتخاب متغیرهای موثر ورودی با الگوریتم اطلاعات متقابل جزئی (PMI). *تحقیقات منابع آب ایران*، ۱۵(۲)، ۱۴۴-۱۶۱.

عقیقی، م.ا. (۱۳۹۸). شبیه‌سازی بارش-رواناب و پتانسیل سیل‌خیزی با استفاده از مدل HEC-HMS و منطق فازی مطالعه موردی حوضه آبریز رودبال در استان فارس. *جغرافیای طبیعی*، ۱۲(۴۶)، ۱۱۱-۱۲۷.

این تحقیق تأثیر موجک بر افزایش دقت تخمین در مدل‌سازی بارش-رواناب است. نتایج تحقیق حاضر نشان داد که مدل هیبریدی افزایش دقت یک مدل را به‌همراه خواهد داشت. بررسی شاخص‌های آماری نشان داد که مدل‌های مورد استفاده در تحقیق حاضر از عملکرد قابل قبول در برآورد ماهانه حوضه صوفی‌چای برخوردار هستند. هم‌چنین از لحاظ دقت مدل WANN می‌توان از مدل مذکور به‌عنوان ابزاری کارآمد و قابل اعتماد در تخمین جریان رودخانه مذکور استفاده نمود. در مجموع باتوجه به‌نتایج قابل قبول مدل‌های مورد استفاده در تحقیق حاضر، ضرایب و توابع به‌کار رفته برای واسنجی آن‌ها می‌تواند برای تخمین جریان حوضه صوفی‌چای بسیار مفید باشد. هم‌چنین یکی از ویژگی‌های مثبت شبکه عصبی قابلیت به‌روز کردن آن است؛ یعنی با معرفی کردن داده‌های جدید به شبکه عصبی می‌توان مدل را به‌روز کرد و شبکه را با داده‌های جدید آشنا نمود و دقت آن را افزایش داد.

قربانی، م.ع.، ازانی، ع.، و محمودی وان‌علیا، س. مدل‌سازی بارش-رواناب با استفاده از مدل‌های هوشمند هیبریدی. *تحقیقات منابع آب ایران*، ۱۱(۲)، ۱۴۶-۱۵۰.

کاووسی، م.، و خزیمه‌نژاد، ح. (۱۴۰۰). بررسی و مقایسه عملکرد روش مدل‌سازی NN، LS-SVM، ANFIS-PSO و GEP در شبیه‌سازی بارش-رواناب (منطقه مورد مطالعه: هلیل رود - سد جیرفت). *ایران مهندسی آبیاری و آب*، ۱۱(۴۳)، ۹۶-۱۱۰.

نوری، م.، میرحسینی، س.م.، زینال‌زاده، ک.، و رهنما، م.ب. (۱۳۸۶). الگوی جدید بارش-رواناب حوضه آبریز هلیل‌رود با استفاده از مدل هیبرید شبکه عصبی-موجک. *زمین‌شناسی مهندسی*، ۲(۲)، ۴۵۱-۴۷۲.

References

- Afifi, M.E. (2020). Simulation of rainfall-runoff and flood potential using model HEC-HMS and fuzzy logic (Case study of Rudbal Watershed in Fars Province). *Physical Geography Quarterly*, 12(46), 111-127 (in Persian).
- Alizadeh, M.J., Kavianpour, M.R., Kisi, O., & Nourani, V. (2017). A new approach for simulating and forecasting the rainfall-runoff process within the next two months. *Journal of Hydrology*, 548, 588-597.
- Beale, M., & Demuth, H. (1998). Neural network toolbox for use with MATLAB, User's Guide, The Math Works, Natick, 1-6.
- Chen, X., Chau, K., Busari, A. (2015). A comparative study of population-based optimization algorithms for downstream river flow forecasting by a hybrid neural network model. *Engineering Applications of Artificial Intelligence*, 46, 258-268.
- Dumka, B.B., & Kumar, P. (2021). Modeling rainfall-runoff using Artificial Neural Network (ANNs) and Wavelet based ANNs (WANNs) for Haripura am, Uttarakhand. *Indian Journal of Ecology*, 48(1), 271-274.
- Ghorbani, M.A., Azani, A., & Mahmoudi Vanolya, S. (2015). Rainfall-Runoff Modeling Using Hybrid Intelligent Models. *Iran-Water Resources Research*, 11(2), 146-150 (in Persian).
- Jeong, D.I., & Kim, Y.O. (2005). Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction Hydrological processes. *Hydrological Processes*, 19(19), 3819-3835.

- Kavusi, M., & Khozaymeh Nejad, H. (2021). Review and compare performance of 4 modeling methods LS-SVM, NN, GEP and ANFIS-PSO in Simulation of Rainfall - Runoff (Study Area: Halil River - Jiroft Dam). *Irrigation & Water Engineering*, 11(43), 96-110 (in Persian).
- Kim, T.W., & Valdés, J.B. (2003). Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks. *Journal of Hydrologic Engineering*, 8(6), 319-328.
- Nourani, V., Khanghah, T.R., & Baghanam, A.H. (2015). Application of entropy concept for input selection of wavelet-ANN based rainfall-runoff modeling. *Journal of Environmental Informatics*, 26, 52-70.
- Nourani, V., Tajbakhsh, A.D., Molajou, A., & Gokcekus, H. (2019). Hybrid Wavelet-M5 Model Tree for Rainfall-Runoff Modeling. *Journal of Hydrologic Engineering*, 24(5).
- Nouri, M., Mirhosseini, S.M., Zeynalzadeh, K., & Rahnama, M.B. (2008). New pattern of Halil River Basin's rainfall-runoff by using of hybrid neural wavelet network model. *Journal of Engineering Geology*, 2(2), 451-472 (in Persian).
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2019). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8), 839-846.
- Shafeizadeh, M., Fathian, H., & Nikbakht Shahbazi, A. (2019). Continuous Rainfall-Runoff Simulation by Artificial Neural Networks Based on Selection of Effective Input Variables Using Partial Mutual Information (PMI) Algorithm. *Iran-Water Resources Research*, 15(2), 144-161 (in Persian).
- Sharghi, E., Nourani, V., Molajou, A., & Najafi, H. (2019). Conjunction of emotional ANN (EANN) and wavelet transform for rainfall-runoff modeling. *Journal of Hydroinformatics*, 21(1), 136-152.
- Sharghi, E., Nourani, V., Najafi, H., & Molajou, A. (2018). Emotional ANN (EANN) and Wavelet-ANN (WANN) approaches for markovian and seasonal based modeling of rainfall-runoff process. *Water Resources Management*, 32, 3441-3456.
- Tikhmarine, Y., Souag-Gamane, D., Ahmed, A.N., Sammen, S.S.H., Kisi, O., Huang, Y.F., & El-Shafie, A. (2020). Rainfall-runoff modelling using improved machine learning methods: Harris hawks optimizer vs. particle swarm optimization. *Journal of Hydrology*, 589 (11-12), 125133
- Vapnik, V.N. (1988). *Statistical Learning Theory*. John Wiley, New York.