

## Assessment of the Performance of Various Wavelet Transforms in Combined Wavelet-neural Network Modeling for Monthly River Flow Prediction (Case Study: Kardeh Watershed)

A. Kazemi Choolanak<sup>1</sup>, F. Modaresi<sup>ID</sup><sup>2\*</sup>, A. Mosaedi<sup>ID</sup><sup>3</sup>

1, 2 and 3- Master's Degree Student, Assistant Professor and Professor in Water Science and Engineering Department, Faculty of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran, respectively.

(\*- Corresponding Author Email: [fmodaresi@um.ac.ir](mailto:fmodaresi@um.ac.ir))

Received: 15-01-2024  
Revised: 26-02-2024  
Accepted: 03-03-2024  
Available Online: 03-03-2024

### How to cite this article:

Kazemi Choolanak, A., Modaresi, F., & Mosaedi, A. (2024). Assessment of the performance of various wavelet transforms in combined wavelet-neural network modeling for monthly river flow prediction (Case study: Kardeh watershed). *Journal of Water and Soil*, 38(2), 191-206. (In Persian with English abstract).  
<https://doi.org/10.22067/jsw.2024.86414.1371>

### Introduction

Predicting river flow is one of the most crucial aspects in water resources management. Improving forecasting methods can lead to a reduction in damages caused by hydrological phenomena. Studies indicate that artificial neural network models provide better predictions for river flow compared to physical and conceptual models. However, since these models may not offer reliable performance in estimating unstable data, using preprocessing techniques is necessary to enhance the accuracy and performance of artificial neural networks in estimating hydrological time series with nonlinear relationships. One of these methods is wavelet transformation, which utilizes signal processing techniques.

### Materials and Methods

In this study, to evaluate the efficiency of discrete and continuous wavelet types in the Wavelet-Artificial Neural Network (WANN) hybrid model for monthly flow prediction, a case study was conducted on the Kardeh Dam watershed in the northeast of Iran, serving as a water source for part of Mashhad city and irrigation downstream agricultural lands. Monthly streamflow estimates for the upstream sub-basin of the Kardeh Dam were obtained from the meteorological and hydrometric stations' monthly statistics over a 30-year period (1991-2020). The WANN model is a hybrid time series model where the output of the wavelet transform serves as a data preprocessing method entering an artificial neural network as the predictive model. The combination of wavelet analysis and artificial neural network implies using wavelet capabilities for feature extraction, followed by the neural network to learn patterns and predict data, potentially enhancing the models' performance by leveraging both methods. The 4-fold cross-validation method was employed for the artificial neural network model validation, where the model underwent validation and accuracy assessment four times, each time using 75% of the data for training and the remaining 25% for model validation. The final results were presented by averaging the validation and accuracy results obtained from each of the four model runs. To evaluate and compare the performance of the models used in this study, three evaluation indices, Nash-Sutcliffe Efficiency (NSE), Root Mean Square Error (RMSE), and Pearson correlation coefficient (R), were employed.

### Results and Discussion



©2024 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/), which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source.

<https://doi.org/10.22067/jsw.2024.86414.1371>

The analysis of meteorological and hydrometric data in this study revealed that monthly streamflow in two time steps, T-1 and T-2, were the most effective predictive variables. Each of the two runoff variables of the previous month (Qt-1) and the previous two months (Qt-2) were analyzed by each of the Haar and Fejer-Korovkin2 discrete wavelet transforms and the two continuous Symlet3 and Daubechies2 wavelets at three levels. The results of each level of decomposition was given as input to the ANN model. The presented results at each decomposition level indicated that hybrid models could accurately predict lower flows compared to the single ANN model, and the estimation of maximum values also significantly improved in the hybrid models. Among the wavelets used, Haar wavelets exhibited the weakest performance, and the less commonly employed Kf2 wavelet showed a moderate performance. Since the Haar and Fk2 wavelets, with their discrete structure, did not perform well in decomposing continuous monthly streamflow data, continuous wavelet models outperformed discrete wavelet models. The hybrid models, combining wavelet analysis and artificial neural networks, demonstrated up to an 11% improvement over the performance of the single neural network model.

## Conclusion

Streamflow is a crucial element in the hydrological cycle, and predicting it is vital for purposes such as flood prediction and providing water for consumption. The objective of this research was to evaluate the performance of different types of discrete and continuous wavelet models at various decomposition levels in enhancing the efficiency of artificial neural network (ANN) models for streamflow prediction. Since climate and watershed characteristics can influence the nature of data fluctuations and, consequently, the results of the wavelet model decomposition, choosing an appropriate wavelet model is essential for obtaining the best results. Considering the existing variations in the results of different studies regarding the selection of the best wavelet type, it is suggested to use both continuous and discrete wavelet types in modeling to achieve the best predictions and select the optimal results. Given that a lower number of input variables in neural network models lead to higher accuracy in modeling results, it is recommended to perform decomposition at a two-level depth to reduce input components to the neural network model, thereby reducing the model execution time.

**Keywords:** Artificial Neural Network, Continuous wavelet, Cross-validation, Discrete wavelet, Hybrid model, Wavelet transform

## مقاله پژوهشی

جلد ۳۸، شماره ۲، خرداد-تیر ۱۴۰۳، ص. ۱۹۱-۲۰۶

## ارزیابی کارایی انواع تبدیل موجک در مدل‌سازی ترکیبی موجک- شبکه عصبی مصنوعی برای پیش‌بینی جریان ماهانه رودخانه (مطالعه موردی: رودخانه کارده)

عاطفه کاظمی چولانک<sup>۱</sup> - فرشته مدرسی<sup>۲\*</sup> - ابوالفضل مساعدی<sup>۳</sup>

تاریخ دریافت: ۱۴۰۲/۱۰/۲۵

تاریخ پذیرش: ۱۴۰۲/۱۲/۱۳

### چکیده

رواناب پدیده‌ای مهم در چرخه هیدرولوژیکی است، از این رو پیش‌بینی میزان رواناب رودخانه برای اهدافی نظیر برنامه‌ریزی فعالیت‌های کشاورزی، پیش‌بینی سیلاب و تأمین آب مصرفی حائز اهمیت است. پیچیده بودن مدل‌های فیزیکی یکی از دلایلی است که باعث شده پژوهشگران به مدل‌های داده‌مبناء و مبتنی بر هوش مصنوعی روی آورند. وجود تغییرات آماری در داده‌ها سبب می‌شود که مدل‌سازی جریان رودخانه با مدل‌های داده‌مبناء با مشکلاتی در فرآیند یادگیری مدل همراه باشد. لذا لازم است با مدل‌سازی تلفیقی، دقت پیش‌بینی جریان ارتقاء یابد. هدف تحقیق حاضر، ارزیابی کارایی انواع موجک‌های گسسته و پیوسته در مدل ترکیبی موجک-شبکه عصبی (WANN) برای پیش‌بینی جریان ماهانه رودخانه کارده در ایستگاه ورودی به سد کارده است. بدین منظور، دو موجک گسسته Haar و Fejer-Korovkin2 و دو موجک پیوسته Symlet3 و Daubechies2 در ترکیب با مدل ANN مورد ارزیابی قرار گرفت. بررسی داده‌های هواشناسی و هیدرومتری در یک دوره ۳۰ ساله (۱۳۷۰-۱۳۹۹) نشان داد که جریان ماهانه در دو گام زمانی T-1 و T-2 بهترین متغیرهای پیش‌بینی‌کننده (در سطح اطمینان ۹۵٪) بودند. آنالیزهای ترکیبی در سه سطح تجزیه انجام و کارایی مدل‌ها با روش صحت‌سنجی متقاطع در ۴ سطح مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل‌های ترکیبی دارای دقت بالاتری نسبت به مدل ANN بودند و مدل ترکیبی پیشنهادی Symlet3-ANN در سطح ۳، نتایج بهتری نسبت به سایر مدل‌ها ارائه داد، بطوری‌که شاخص‌های R، RMSE و NSE در بخش واسنجی به ترتیب ۰/۹۰، ۰/۲۵ و ۰/۸۱ و در بخش صحت‌سنجی به ترتیب ۰/۸۵، ۰/۳۰ و ۰/۶۲ بود. همچنین ملاحظه شد دقت نتایج در سطح دو و سه تفاوت معناداری ندارند و بهتر است جهت کاهش مؤلفه‌های ورودی به مدل ANN و کاهش زمان اجرای مدل، تجزیه در سطح دو انجام شود.

**واژه‌های کلیدی:** تبدیل موجک، شبکه عصبی مصنوعی، صحت‌سنجی متقاطع، مدل هیبریدی، موجک پیوسته، موجک گسسته

### مقدمه

پیش‌بینی‌های بهتری را نسبت به مدل‌های فیزیکی و مفهومی نظیر IHACRES، SWAT، MIKE 11 و HEC-HMS برای جریان رودخانه ارائه می‌کنند (Young et al., 2017; Jimeno-Sáez et al., 2018; Ahmadi et al., 2019; Wagena et al., 2020). تارک و آووک (Tareke & Awoke, 2023) در تحقیقی با استفاده از شبکه عصبی مصنوعی به پیش‌بینی بلندمدت جریان رودخانه و خشکسالی هیدرولوژیکی در اتیوپی پرداختند و نشان دادند شبکه عصبی مصنوعی ابزار خوبی برای پیش‌بینی جریان در مناطقی است که همبستگی خوبی بین بارش و جریان وجود دارد اما در مناطق خشک مدل مناسبی نیست.

در چند سال اخیر، پیش‌بینی رواناب رودخانه از مهم‌ترین موضوعات در حوزه مدیریت منابع آب بوده است. بهبود بخشیدن به روش‌های پیش‌بینی جریان منجر به کاهش خسارات ناشی از پدیده‌های هیدرولوژیکی از جمله خشکسالی و سیلاب خواهد شد. برای مدل‌سازی رواناب دو رویکرد اصلی شامل رویکردهای فیزیکی و مفهومی فرآیند محور و رویکردهای تجربی داده محور وجود دارد (Ahooghalandari et al., 2016). مطالعات صورت گرفته برای مقایسه این دو رویکرد اغلب نشان می‌دهند که مدل‌های شبکه عصبی مصنوعی (ANN)

۱، ۲ و ۳- به ترتیب دانشجوی کارشناسی ارشد، استادیار و استاد گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران  
(\*) نویسنده مسئول: (Email: Fmodaresi@um.ac.ir)

مدل‌های خودهمبسته (AR)، میانگین متحرک خودهمبسته (ARMA)، رگرسیون خطی (LR) و ANN را برای پیش‌بینی جریان در چین بررسی کردند؛ نتایج مطالعات آنها نشان می‌دهد که مدل‌های ترکیبی مبتنی بر موجک، عملکرد بهتری نسبت به مدل‌های منفرد دارد. طیب و همکاران (Tayyab et al., 2019) از ترکیب مدل‌های Feed-Forward Back-Propagation Neural Network (FFBPNN) و radial basis function neural network (RBFNN) با یک مدل آنالیز موجک گسسته برای مدل‌سازی رابطه بارش- رواناب ماهانه در حوضه رودخانه جینشا در رودخانه یانگ تسه در چین استفاده کردند و نشان دادند که تبدیل موجک گسسته عملکرد مدل‌ها را بهبود می‌بخشد. با توجه به مطالعات صورت گرفته مشاهده می‌شود که استفاده از مدل‌های آنالیز موجک به طرز چشمگیری دقت مدل‌های مبتنی بر هوش مصنوعی را در مدل‌سازی جریان را افزایش داده است. تاکنون، اکثر تحقیقات مبتنی بر مدل ترکیبی (موجک- شبکه عصبی) Wave-ANN از یک موجک مشخص در یک سطح تجزیه خاص استفاده کرده‌اند (Dalkiliç & Hashemi, 2020; Tayyab et al., 2019). با توجه به اهمیت نوع موجک و سطح تجزیه آن در پیش‌پردازش داده‌های ورودی مدل‌ها و کارایی بالای مدل Wave-ANN در پیش‌بینی جریان رودخانه، در این مطالعه کارایی دو مدل گسسته Haar و Fejer-Korovkin و دو مدل پیوسته Symlet3 و Daubechies در سه سطح تجزیه یک، دو و سه در ترکیب با شبکه عصبی مصنوعی مورد ارزیابی قرار گرفته و عملکرد آنها در مقایسه با هم و نیز در شرایط عدم بکارگیری تبدیل موجک بررسی شده است.

## مواد و روش‌ها

### محدوده مطالعاتی و داده‌ها

حوضه آبریز کارده با مساحتی در حدود ۶۸۰/۵ کیلومتر مربع در شمال شرق ایران و شمال شهر مشهد قرار دارد که جزء نواحی کوهستانی و مرتفع شمال این شهر محسوب می‌شود و بخشی از حوضه رودخانه کشف رود از زیرحوضه‌های قره قوم است. این حوضه از نظر موقعیت جغرافیایی، در محدوده ۲۶ درجه و ۵۹ دقیقه تا ۴۴ درجه و ۵۹ دقیقه طول شرقی و ۳۷ درجه و ۳۶ دقیقه تا ۵۸ درجه و ۳۶ دقیقه عرض جغرافیایی قرار دارد. رودخانه کارده از تلاقی دو شاخه کوشک آباد و آل سرچشمه می‌گیرد. سد مخزنی کارده به ظرفیت حدود ۳۸ میلیون متر مکعب در بخش انتهایی این حوضه و بر روی رودخانه (شکل ۱) قرار دارد و تأمین کننده بخشی از آب شرب شهر مشهد و همچنین آبیاری اراضی کشاورزی پایین دست حوضه است (Dastorani et al., 2022). از این رو، در مطالعه حاضر، پیش‌بینی جریان ورودی به این سد مورد ارزیابی قرار گرفته است. به‌منظور برآورد رواناب ماهانه

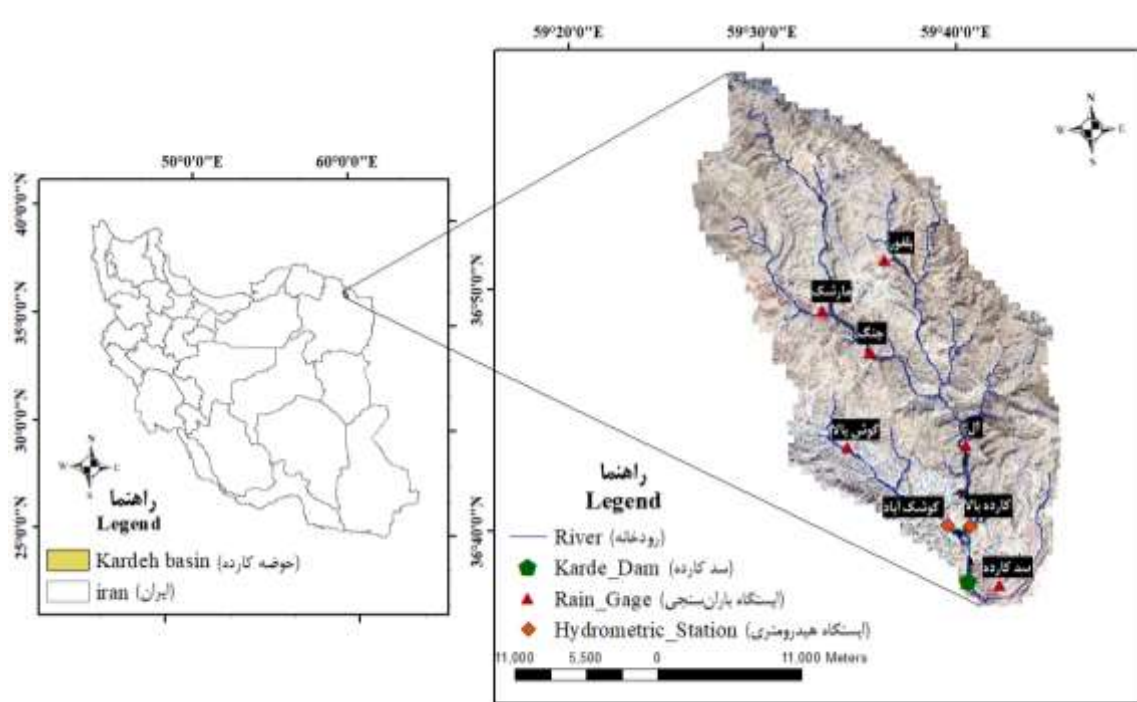
اگر چه از شبکه‌های عصبی مصنوعی به‌عنوان یک ابزار پرکاربرد برای پیش‌بینی متغیرهای هیدرولوژیکی استفاده می‌شود، اما این مدل ممکن است در تخمین داده‌های ناپایدار عملکرد قابل اعتمادی ارائه ندهد (Okkan, 2013). بنابراین، برای بهبود دقت و عملکرد شبکه‌های عصبی مصنوعی در تخمین سری‌های زمانی هیدرولوژیکی با روابط غیرخطی، نیاز به استفاده از تکنیک‌های پیش‌پردازش داده‌ها می‌باشد (Dalkiliç & Hashemi, 2020). یکی از این روش‌ها، تبدیل موجک است که از تکنیک پردازش سیگنال بهره می‌برد. مطالعات صورت گرفته نشان می‌دهد که اطلاعات حاصل از تحلیل موجک درباره رفتار و ساختار سری‌های مشاهده شده، پیش‌بینی‌های موفق را در پیش‌بینی سری‌های هیدرولوژیکی ارائه داده است (Danandeh Mehr et al., 2020; Sithara et al., 2020; Abda et al., 2021). بسیاری از مطالعات با مدل ترکیبی تحلیل موجک و شبکه عصبی مصنوعی (WNN) شکل می‌گیرد، به پیش‌بینی‌های موفق دست یافته‌اند؛ بعنوان مثال صدیقی (Siddiqi et al., 2021) از پیش‌پردازش موجک برای بهبود دقت مدل ANN برای پیش‌بینی میانگین ماهانه جریان در حوضه رودخانه ایندوس، پاکستان استفاده کردند و نشان دادند که مدل ترکیبی در پیش‌بینی جریان ماهانه در مقایسه با مدل منفرد بهتر عمل می‌کند. برای پیش‌بینی جریان‌های روزانه در شمال شرقی برزیل، فریره و همکاران (Freire et al., 2019) انواع موجک پیوسته Coifet, Symlet, Daubechies و مدل موجک گسسته Meyer را با مدل ANN ترکیب کردند. نتایج آنها نشان داد که ANN مبتنی بر موجک به طرز چشمگیری عملکرد مدل ANN را بهبود بخشیده و موجک گسسته Meyer بالاترین موفقیت را در پیش‌بینی نشان داد. دالکلیک و هاشمی (Dalkiliç & Hashemi, 2020) دریافتند که مدل ترکیبی شبکه عصبی با مدل موجک هار (WNN) در تخمین جریان ماهانه نسبت به مدل ANN و مدل سیستم استنتاج عصبی فازی تطبیقی (ANFIS) عملکرد موفق‌تری دارد. گونس و همکاران (Güneş et al., 2021) در یک مدل ترکیبی از تبدیل‌های موجک پیوسته Daubechies و شبکه‌های عصبی مصنوعی (ANNs) برای تخمین جریان ماهانه استفاده کردند و نشان دادند که مدل ترکیبی عملکرد بهتری نسبت به مدل ANN دارد. همچنین در پژوهشی بیلماز و همکاران (Yilmaz et al., 2022) برای بهبود مدل ANN، از مدل پیوسته Daubechies استفاده کردند و نشان دادند مدل ترکیبی پیشنهادی دقت پیش‌بینی جریان ماهانه رودخانه را بطور قابل توجهی در مقایسه با ANN افزایش می‌دهد. بیسواس و چاکرابورتی (Chakraborty & Biswas, 2023) نیز نشان دادند که ترکیب مدل آنالیز موجک پیوسته Daubechies با مدل ANN و مدل Long-Short Term Memory (LSTM) دقت پیش‌بینی رواناب توسط این دو مدل را افزایش می‌دهد. سان و همکاران (Sun et al., 2019) کاربرد تبدیل موجک با

زیرحوضه بالادست سد کارده از آمار ماهانه ایستگاه‌های هواشناسی و هیدرومتری حوضه (جدول ۱ و شکل ۱) در بازه زمانی ۳۰ ساله (۱۳۹۹-۱۳۷۰) استفاده گردید. تغییرات متوسط بارش و جریان ماهانه محدوده مطالعاتی در شکل ۲ نشان داده شده است.

جدول ۱- مشخصات مکانی و آماری ایستگاه‌های هواشناسی و هیدرومتری مورد استفاده در منطقه مطالعاتی در بازه زمانی (۱۳۹۹-۱۳۷۰)


Table 1- Geographical and statistical properties of the meteorological and hydrometric stations in the study area in the period 1991-2021

Station type	Station	XUTM	YUTM	Mean	Stdev	
نوع ایستگاه	نام ایستگاه	طول	عرض	میانگین	انحراف معیار	
Metheteorological هواشناسی	Al	آل	738112	4066830	25.14	26.44
	Jong	جنگ	730763	4073907	27.20	28.85
	Goosh Bala	گوش بالا	729015	4066640	24.25	25.86
	Bolghoor	بلغور	731891	4081022	31.74	31.48
	Kardeh Dam	سد کارده	740690	4056097	23.49	32.79
	Mareshk	مارشک	727063	4077158	25.89	26.22
Hydrometric هیدرومتری	Kardeh	کارده	738303	4060437	0.54	0.64
	Kooshk Abad	کوشک آباد	736998	4060587	0.02	0.06



شکل ۱- موقعیت جغرافیایی منطقه مطالعاتی و ایستگاه‌های هواشناسی و هیدرومتری آن

Figure 1- The geographical location of the study area and its hydro-meteorological and hydrometric stations



شکل ۲- تغییرات ماهانه جریان و بارش محدوده مطالعاتی (۱۳۹۹-۱۳۷۰)

Figure 2- Monthly variations of streamflow and precipitation within the study area over a 30-year period (1991-2020)

### مدل آنالیز موجک

تبدیل موجک (WT) یک روش پردازش سیگنال است که به عنوان جایگزینی برای تبدیل فوریه پیشنهاد شده است. این روش سری‌های زمانی را تجزیه می‌کند، نویز را کاهش داده و تخمین‌ها را بهبود می‌بخشد (Nayak et al., 2013; Grossmann & Morlet, 1984). تحلیل فوریه دارای یک نقطه ضعف اولیه است که اطلاعات زمانی را در تبدیل به حوزه فرکانسی از دست می‌دهد، در حالی که WT شامل چند تفکیک‌پذیری در حوزه زمان و فرکانس است (Tiwari & Chatterjee, 2011). تبدیل موجک یک تبدیل ریاضی قدرتمند است که کمک می‌کند تا جنبه‌های روندها، نقاط شکست و ناپیوستگی‌هایی را که تکنیک‌های سنتی تحلیل داده‌ها نمی‌توانند تشخیص دهند، با جزئیات بیشتری بررسی شوند (Adamowski & Sun, 2010). این روش از فواصل طولانی برای نشان دادن اطلاعات فرکانس پایین در سری‌های زمانی و فواصل کوتاه برای نمایش جزئیات فرکانس بالا استفاده می‌کند (Momeneh & Nourani, 2022).

برخلاف تبدیل فوریه، عرض تابع موجک با هر جزء طیفی در تبدیل موجک تغییر می‌کند. تبدیل موجک، در فرکانس‌های بالا، وضوح زمانی خوب و وضوح فرکانس ضعیف را ارائه می‌دهد در حالی که در فرکانس‌های پایین، وضوح فرکانس خوب و وضوح زمانی ضعیف را ارائه می‌دهد. تبدیل موجک پیوسته (CWT) یک سیگنال  $x(t)$  به صورت زیر تعریف می‌شود (Kim & Valdes, 2003)

$$CWT_x^\varphi(\tau, s) = |S| \frac{1}{2} \varphi * \int_{-\infty}^{+\infty} \left( \frac{t-\tau}{s} \right) dt \quad (1)$$

که در آن  $s$  پارامتر مقیاس (عکس فرکانس)،  $\tau$  پارامتر انتقال و  $*$  نشان‌دهنده مزدوج مختلط است (Cannas et al., 2006). پارامتر انتقال مربوط به مکان تابع موجک در هنگام جابجایی آن از طریق سیگنال است که با اطلاعات زمانی در تبدیل موجک مطابقت دارد. پارامتر مقیاس  $s$  به صورت  $1/\text{frequency}$  تعریف می‌شود و با اطلاعات فرکانس مطابقت دارد. موجک مادر  $\varphi(t)$  تابع تبدیل است. مقیاس‌های بزرگ (فرکانس‌های پایین) سیگنال را بسط می‌دهد و اطلاعات دقیق پنهان در سیگنال را ارائه می‌دهند، در حالی که مقیاس‌های کوچک (فرکانس‌های بالا) سیگنال را فشرده می‌کند و اطلاعات کلی درباره سیگنال ارائه می‌دهند (Cannas et al., 2006).

تبدیل موجک گسسته (DWT) به زمان محاسبات کمتری در مقایسه با CWT نیاز دارد و پیاده‌سازی آن ساده‌تر از CWT است. مقیاس‌ها و موقعیت‌های DWT معمولاً براساس توان‌های دو عامل (مقیاس‌ها و موقعیت‌های دوتایی) هستند (Partal & Kisi, 2007). این امر با تغییر نمایش موجک به صورت زیر به دست می‌آید (Malat, 1999).

$$\varphi_{j,k}(t) = S_0^{-\frac{j}{2}} \varphi \left( \frac{t - k\tau_0 S_0^j}{S_0^j} \right) \quad (2)$$

در رابطه بالا،  $j$  و  $k$  اعداد صحیح هستند و  $S_0 > 1$  یک مرحله زمانی ثابت است. اثر گسسته‌سازی موجک این است که مقیاس فضای

قابل تغییر می‌باشد که مقدار بهینه آن باید محاسبه شود. توابع مورد استفاده در نورون‌های لایه میانی و خروجی به ترتیب از نوع خطی و سیگموئیدی هستند که در معادله ۳ و ۴ ارائه شده است (Modaresi et al., 2017):

$$f(x) = x \quad (3)$$

$$f(x) = \frac{1}{1 + e^{-ax}} \quad a > 0 \quad (4)$$

برای محاسبه توابع در هر نورون، وزن (w) و بایاس (b) برای ورودی‌های نورون‌ها به صورت  $(w_j x_j + b_j)$  در نظر گرفته می‌شود.  $(j = 1, 2, \dots, m)$  که مقادیر بهینه آن باید از طریق واسنجی مدل تعیین شود.

به منظور آموزش یا واسنجی شبکه عصبی MLP، از الگوریتم Feed Forward Back Propagation (FFBP) برای دستیابی به بهترین مدل‌سازی استفاده می‌شود، که در آن تابع خطا طبق معادله زیر به عنوان تابع هدف برای هر یک از تکرارها به حداقل می‌رسد (Araghinejad, 2014):

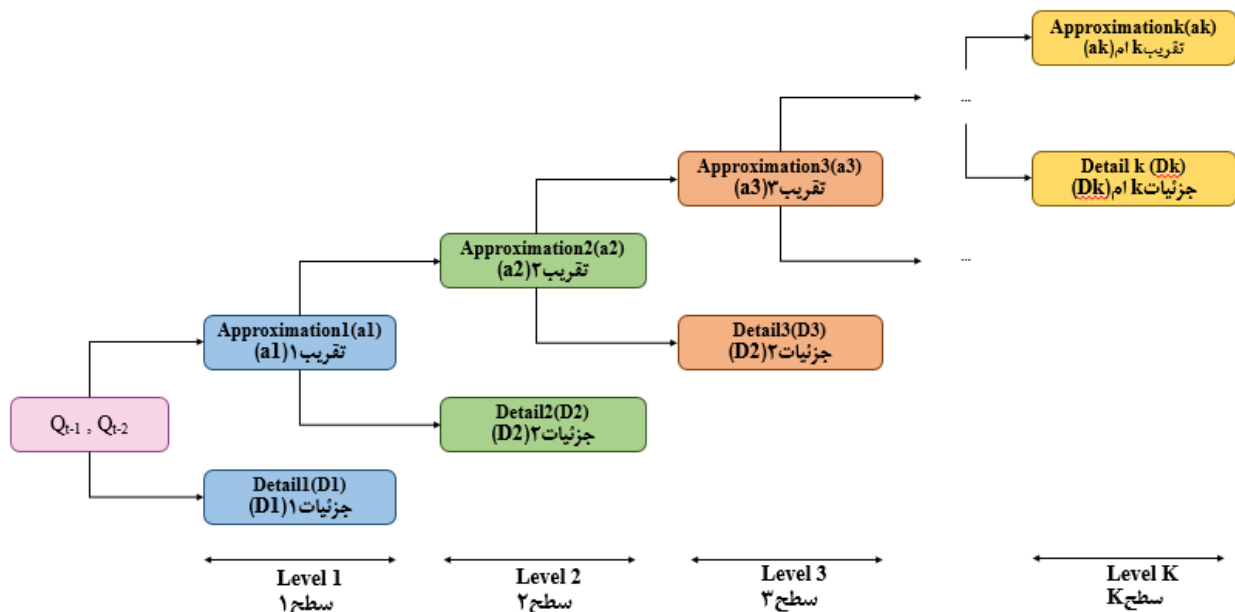
$$E = \frac{1}{nc} \sum_{i=1}^{nc} e_i^2 \quad (5)$$

در رابطه ۵، E تابع خطا،  $e_i$  خطای شبیه‌سازی مدل برای i امین داده آموزشی و nc تعداد جفت‌های آموزشی است.

زمانی اکنون در سطوح گسسته نمونه برداری می‌شود. مقدار  $S_0 = 2$  به گونه‌ای انتخاب شد که نمونه برداری از محور فرکانس با نمونه‌گیری دوتایی مطابقت داشته باشد. موجک مادر  $\varphi$ ، الگوریتم تبدیل موجک "a Trouns" است. ضریب انتقال  $\tau = 1$  برای اطمینان از نمونه‌گیری دوتایی در محور زمان انتخاب می‌شود (Cannas et al., 2006). شکل ۳ چگونگی تجزیه توسط تبدیل‌های موجک برای سطوح مختلف را نشان می‌دهد؛ تابع موجک با عبور دادن داده‌ها از فیلتر مربوطه، آنها را به دو دسته تقریب (Approximation) و جزئیات تقسیم (Detail) می‌کند. تقریب نماینده اجزا با فرکانس پایین و جزئیات شامل اجزایی با مقیاس کوچک یا فرکانس بالا بوده و فرآیند تجزیه امواج می‌تواند تا چندین مرحله ادامه یابد (Wang & Ding, 2003). تفاوت اصلی انواع تبدیل‌های موجک در نوع تابع موجک مادر است. در موجک‌های گسسته، این توابع از نوع پلکانی هستند در حالی که در موجک‌های پیوسته، از تبدیل پیوسته در موجک مادر استفاده می‌شود.

### مدل شبکه عصبی مصنوعی

در این مقاله، یک شبکه عصبی سه لایه با ساختار پرسپترون (MLP) استفاده شده است. در این نوع شبکه عصبی، تعداد نورون‌های لایه ورودی و خروجی به ترتیب برابر با تعداد متغیرهای پیش‌بینی‌کننده (m) پیش‌بینی‌شونده است، در حالی که تعداد نورون‌های لایه میانی



شکل ۳- چگونگی تجزیه سری زمانی X توسط تبدیل‌های موجک برای سطوح مختلف  
Figure 3- The decomposition of time series X using wavelet transforms for different levels

اجرای مدل، ۷۵ درصد داده‌ها (۳ گروه) برای آموزش و ۲۵ درصد باقیمانده (۱ گروه) برای صحت‌سنجی مدل استفاده شدند. در نهایت برای ارائه نتایج نهایی حاصل از ۴ بار اجرای مدل، از نتایج بدست آمده از هر بخش واسنجی و صحت‌سنجی میانگین گرفته شده است. شایان ذکر است که در هر بار اجرای مدل، تعداد نوروں‌های بهینه لایه میانی نیز از بازه (۳،۸) براساس یافته‌های مطالعات پیشین تعیین شده است (Modaresi et al., 2017).

#### معیارهای ارزیابی مدل

برای ارزیابی و مقایسه کارایی مدل‌های بکار رفته در این تحقیق از سه شاخص ارزیابی نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی پیرسون (R) استفاده شد که به ترتیب در روابط ۶، ۷ و ۸ ارائه شده است (Moriassi et al., 2007):

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (7)$$

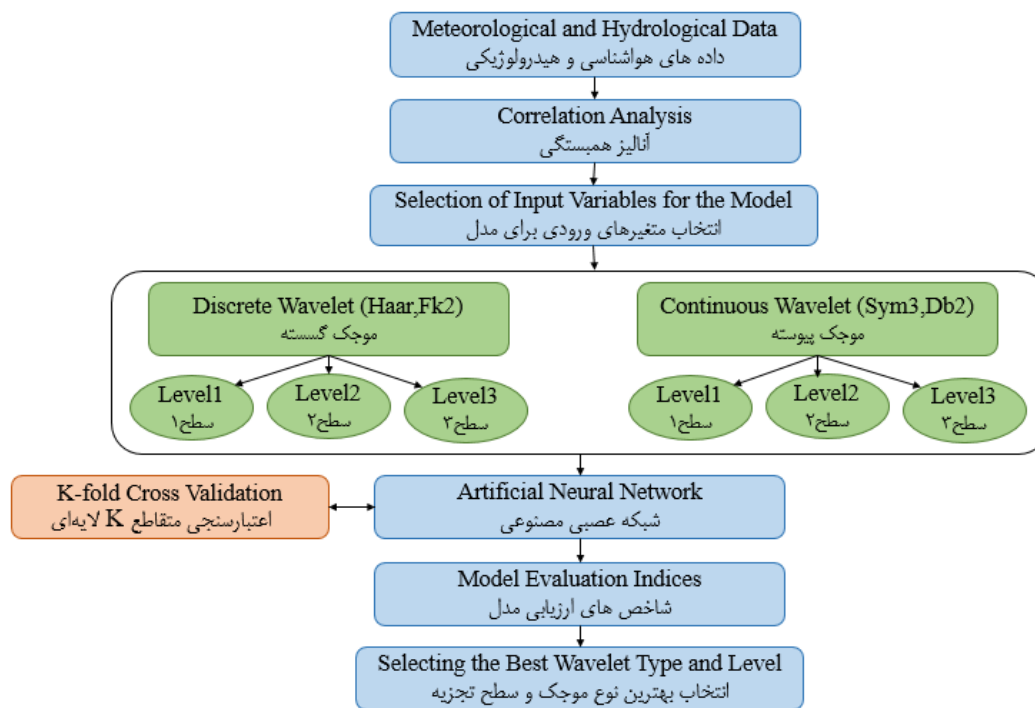
$$R = \frac{\sum_{i=1}^n (P_i - \bar{P}) - (O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (8)$$

#### مدل ترکیبی موجک- شبکه عصبی (WANN)

مدل WANN یک مدل ترکیبی از نوع سری است که در آن، خروجی تبدیل موجک به‌عنوان روش پیش‌پردازش کننده داده‌ها به عنوان ورودی به شبکه عصبی مصنوعی به‌عنوان مدل پیش‌بینی کننده وارد می‌شود. ترکیب آنالیز موجک و شبکه عصبی مصنوعی به معنای استفاده از قابلیت‌های موجک برای استخراج ویژگی‌ها و سپس استفاده از شبکه‌های عصبی برای یادگیری الگوها و پیش‌بینی داده‌ها است. این روش می‌تواند بهبود قابل توجهی در عملکرد مدل‌ها داشته باشد، زیرا از توانایی‌های هر دو روش بهره می‌برد.

در این تحقیق از دو مدل گسسته Haar و fk و دو مدل پیوسته Symlet3 و Daubechies که تحقیقات پیشین نشان‌دهنده قابلیت بالای آنها در افزایش دقت پیش‌بینی‌ها هستند (Momeneh & Güneş et Dalkiliç & Hashemi, 2020 ; Nourani., 2022 ; al., 2021)، در سه سطح تجزیه ۱، ۲ و ۳ استفاده شد و زیرسری‌های اصلی (ai) و جزئی (di) در هر تجزیه به‌عنوان ورودی به مدل شبکه عصبی مورد استفاده قرار گرفتند. فلوچارت مراحل انجام تحقیق در شکل ۴ آورده شده است.

برای واسنجی مدل شبکه عصبی مصنوعی از روش اعتبارسنجی متقاطع ۴ لایه‌ای (4-fold cross validation) استفاده شد. بدین صورت که داده‌ها به چهار گروه تقسیم شدند و هر یک از مدل‌های ترکیبی ۴ بار مورد واسنجی و صحت‌سنجی قرار گرفت و در هر بار



شکل ۴- شمای کلی روند تحقیق

Figure 4- Flowchart of the current research



(شکل ۵) و مشاهده شد که جریان هر ماه با جریان در یک و دو ماه قبل از خود دارای همبستگی بالایی در سطح اطمینان ۹۵٪ (P- $val < 0.05$ ) است، لذا دو متغیر جریان در زمان  $T-1$  و  $T-2$  ( $Q_{t-1}$  و  $Q_{t-2}$ ) به‌عنوان متغیرهای پیش‌بینی کننده جریان مورد استفاده قرار گرفتند و مدل زیر برای این مطالعه تعریف شد.

$$Q_t = f((Q_{t-1}) \cdot (Q_{t-2})) \quad (9)$$

### نتایج مدل ترکیبی WANN

با توجه به ورودی‌های انتخاب شده از مرحله قبل، هر یک از دو متغیر رواناب ماه قبل ( $Q_{t-1}$ ) و رواناب دو ماه قبل ( $Q_{t-2}$ ) توسط هر یک از تبدیل‌های موجک در سه سطح تجزیه شده و نتایج حاصل از هر سطح تجزیه به‌عنوان ورودی به مدل ANN داده شد (شکل ۶).

### نتایج مدل ترکیبی WANN در سطح تجزیه یک


در سطح یک، به ازای هر یک از متغیرهای پیش‌بینی کننده، دو سری زمانی حاصل از تجزیه موجک شامل یک زیر سیگنال اصلی ( $a_{1i}$ ) و یک زیرسیگنال جزئی ( $d_{1i}$ ) بعنوان ورودی به مدل شبکه عصبی داده شد. در شکل ۷، نتایج صحت‌سنجی بدست آمده از مدل‌های ترکیبی حاصل از ۴ آنالیز موجک پیوسته و گسسته در هر یک از لایه‌های صحت‌سنجی متقاطع براساس شاخص‌های NSE، RMSE و R نشان داده شده است.

در روابط فوق،  $P_i$  و  $O_i$  به ترتیب جریان ماهانه مشاهداتی و پیش‌بینی شده در زمان  $i$  و  $\bar{P}$  و  $\bar{O}$  به ترتیب میانگین جریان ماهانه مشاهداتی و پیش‌بینی شده و N تعداد داده‌ها می‌باشد. دامنه تغییرات شاخص نش-ساتکلیف از منفی بی‌نهایت تا یک می‌باشد. هرچه مقدار این شاخص به یک نزدیک‌تر باشد، خطای مدل کمتر است. شاخص RMSE از صفر تا بی‌نهایت تغییر می‌کند. هر چه مقدار این شاخص به صفر نزدیک‌تر باشد، نشان‌دهنده خطای کمتر و کارایی بهتر مدل می‌باشد. شاخص R در دامنه -۱ تا ۱ تغییر می‌کند. مقدار ۱ و -۱ به ترتیب نشان‌دهنده همبستگی کامل مستقیم و معکوس مقادیر مشاهداتی و پیش‌بینی شده می‌باشد. همچنین مقدار صفر این شاخص نشان می‌دهد که مقادیر مشاهداتی و پیش‌بینی شده هیچگونه همبستگی خطی معنی داری ندارند. بنابراین هرچه مقدار این شاخص به یک نزدیک‌تر باشد، کارایی مدل بهتر است و تغییرات مقادیر مشاهداتی و تخمین زده شده همسو می‌باشد.

### نتایج و بحث

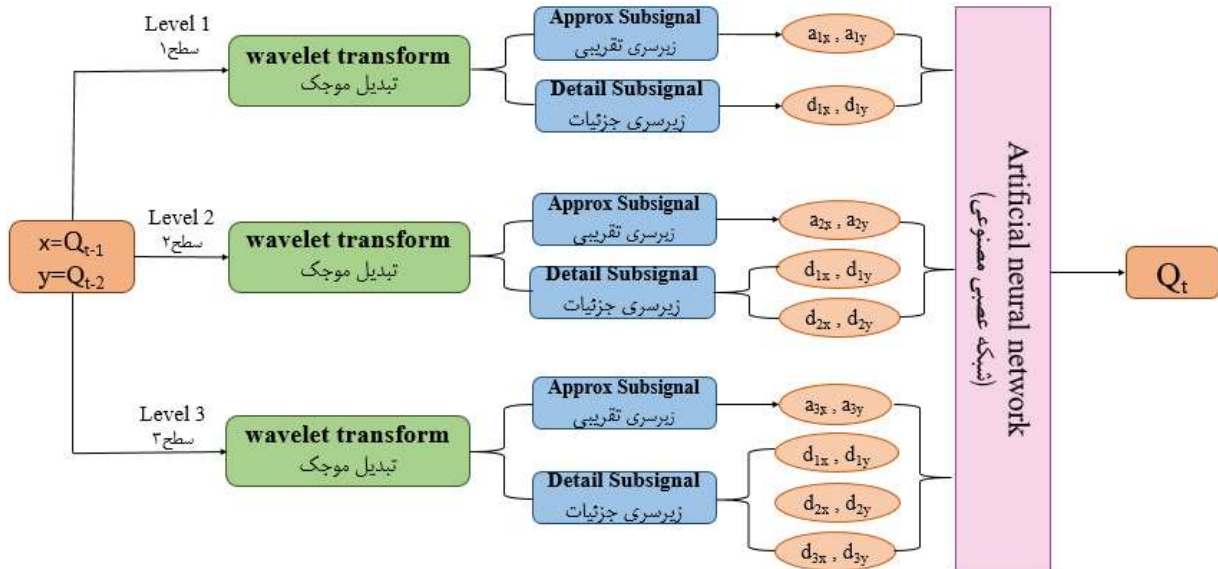
#### نتایج آنالیز همبستگی

به منظور تعیین بهترین متغیرهای پیش‌بینی کننده جریان، میزان همبستگی جریان هر ماه با بارش در تأخیرهای زمانی صفر تا ۵ ماه و نیز مقدار خودهمبستگی جریان تا ۵ ماه قبل مورد بررسی قرار گرفت



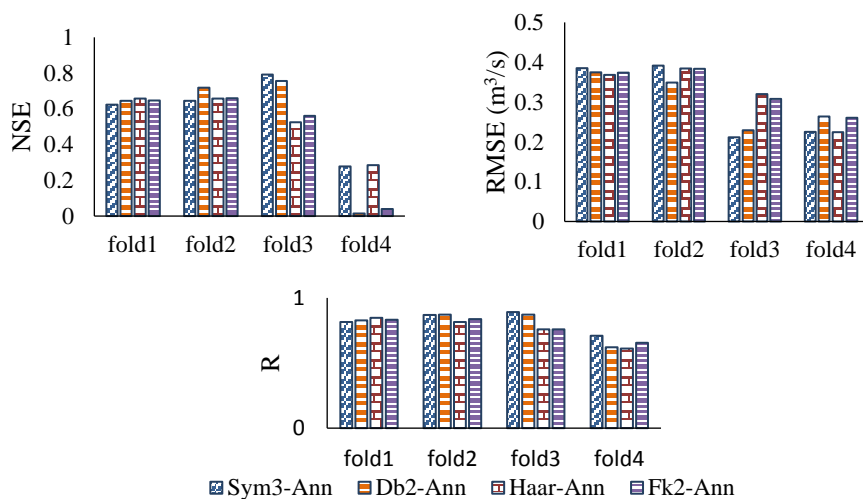
شکل ۵- همبستگی جریان با جریان ماه‌های قبل (الف) و همبستگی جریان با بارش همان ماه و ماه‌های قبل (ب)

Figure 5-The correlation of streamflow with streamflow for previous months (a) and the correlation of streamflow with precipitation for the same month preceding months (b)



شکل ۶- فلوجارت تشکیل مدل ترکیبی برای هریک از روش‌های آنالیز موجک

Figure 6- Flowchart for constructing a combined model for each of the wavelet analysis methods



شکل ۷- شاخص‌های ارزیابی مدل‌های ترکیبی در سطح اول تجزیه (صحت‌سنجی متقاطع)

Figure 7- The evaluation indices values of the hybrid models at the first level of decomposition (crossvalidation)

واسنجی و صحت‌سنجی نشان می‌دهد که ملاحظه می‌شود عملکرد مدل‌های ترکیبی با موجک پیوسته بهتر از موجک گسسته بوده است و از میان آنها، دقت نتایج مدل Sym3-ANN در هر دو مرحله واسنجی و صحت‌سنجی بهتر از سایر مدل‌ها می‌باشد و مدل ترکیبی Haar-ANN کمترین دقت را در این سطح تجزیه دارد.

#### نتایج مدل ترکیبی WANN در سطح دوم تجزیه

در سطح تجزیه دو، سه سری زمانی حاصل از آنالیز موجک شامل یک زیر سیگنال اصلی ( $a_{1i}$ ) و دو زیر سیگنال جزئی ( $d_{2i}$  و  $d_{1i}$ ) به

همانطور که مشاهده می‌شود، مقادیر شاخص‌های اعتبارسنجی در هر یک از چهار دسته متفاوت است. با توجه به شکل ۷ بین دو مدل پیوسته استفاده شده، در fold1 و fold2 مدل Db2-ANN دقت بالاتری نسبت به مدل Sym3-ANN دارد اما در fold3 و fold4 دقت بالاتر است بطوری که در میانگین کلی هم دقت بالاتری را نشان می‌دهد.

دقت دو مدل گسسته، در سه fold اول تفاوت زیادی ندارد اما در fold4 دقت مدل Fk2-ANN بطور قابل ملاحظه‌ای بالاتر است. بطور کلی بین هر چهار مدل ترکیبی، مدل Sym3-ANN عملکرد بهتری دارد. جدول ۲ مقادیر شاخص‌های ارزیابی مدل‌ها را در دو بخش

ازای هر یک از متغیرهای پیش‌بینی کننده بعنوان ورودی وارد مدل شبکه عصبی شد. مقادیر شاخص‌های اعتبارسنجی در سطح دو در هر بخش در شکل ۸ آورده شده است. در سطح دو، مقایسه نتایج دو مدل Db2-ANN و Sym3-ANN نشان می‌دهد فقط در fold2 دقت مدل Db2-ANN بالاتر بوده و در سه fold دیگر مدل Sym3-ANN دقت بالاتری داشته است. بین دو مدل Haar-ANN و Fk2-ANN در هر چهار fold دقت مدل Haar-

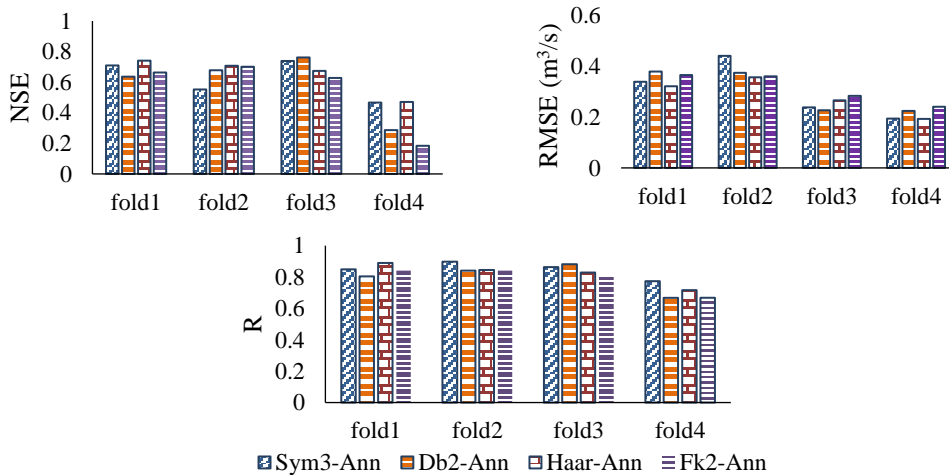
ازای هر یک از متغیرهای پیش‌بینی کننده بعنوان ورودی وارد مدل شبکه عصبی شد. مقادیر شاخص‌های اعتبارسنجی در سطح دو در هر بخش در شکل ۸ آورده شده است.

در سطح دو، مقایسه نتایج دو مدل Db2-ANN و Sym3-ANN نشان می‌دهد فقط در fold2 دقت مدل Db2-ANN بالاتر بوده و در سه fold دیگر مدل Sym3-ANN دقت بالاتری داشته است. بین دو مدل Haar-ANN و Fk2-ANN در هر چهار fold دقت مدل Haar-

جدول ۲- متوسط مقادیر شاخص‌های اعتبارسنجی مدل‌ها در سطح اول تجزیه

Table 2- The average value of the assessment indices at the first level of decomposition

Hybrid model مدل هیبریدی	The optimal number of neurons تعداد بهینه نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE (m <sup>3</sup> /s)	R	NSE	RMSE (m <sup>3</sup> /s)	R
Sym3-ANN	8	0.78	0.27	0.88	0.60	0.30	0.82
Db2-ANN	7	0.76	0.28	0.87	0.53	0.31	0.80
Haar-ANN	4	0.68	0.32	0.83	0.53	0.32	0.76
Fk2-ANN	7	0.69	0.31	0.84	0.47	0.34	0.77



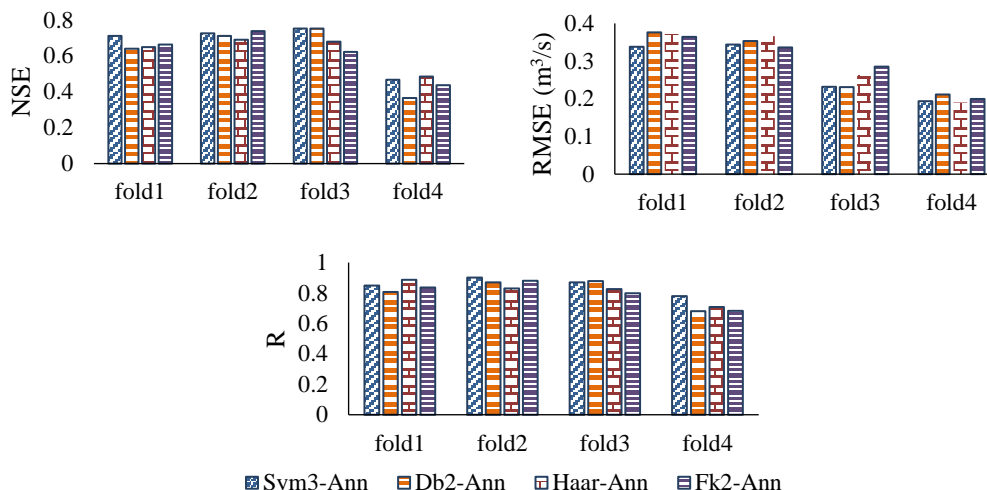
شکل ۸- شاخص‌های ارزیابی مدل‌های ترکیبی در سطح دوم تجزیه (صحت‌سنجی متقاطع)

Figure 8- The evaluation indices values of the hybrid model at the second level of decomposition (cross-validation)

جدول ۳- متوسط مقادیر شاخص‌های اعتبارسنجی مدل‌ها در سطح دوم تجزیه

Table 3- The average value of the assessment indices at the second level of decomposition

Hybrid model مدل هیبریدی	The optimal number of neurons تعداد بهینه نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE (m <sup>3</sup> /s)	R	NSE	RMSE (m <sup>3</sup> /s)	R
Sym3-ANN	4	0.83	0.24	0.91	0.60	0.31	0.84
Db2-ANN	8	0.76	0.28	0.87	0.59	0.30	0.80
Haar-ANN	5	0.73	0.29	0.87	0.61	0.30	0.81
Fk2-ANN	8	0.73	0.29	0.86	0.54	0.32	0.79



شکل ۹- شاخص‌های ارزیابی مدل‌های ترکیبی در سطح سوم تجزیه (صحت‌سنجی متقاطع)

Figure 9- The evaluation indices values of the hybrid models at the third level of decomposition (crossvalidation)

واسنجی مدل ۰/۹ و در قسمت صحت‌سنجی ۰/۸۵ است که نسبت به سایر مدل‌ها عملکرد بالاتری را نشان می‌دهد. مدل ترکیبی Haar-ANN در سطح تجزیه سه دقت کمتری نسبت به سطح تجزیه دو دارد و سایر مدل‌ها نیز اگرچه دقت بالاتری نشان داده‌اند اما اختلاف معنی داری بین مقادیر شاخص‌ها در سطح دو و سه مشاهده نمی‌شود و لذا نیاز به تجزیه سری زمانی داده‌ها در سطوح بالاتر نمی‌باشد. با توجه به مقادیر شاخص‌های ارزیابی در هر سطح تجزیه، بین سه سطح تجزیه، سطح یک پایین‌ترین عملکرد را دارد و سطح سه عملکرد بالاتری را بجز در مدل Haar نشان داده است. مدل Haar در سطح دو عملکرد بالاتری را نشان داده است.

در جدول ۵، مقادیر شاخص‌های ارزیابی مدل ANN منفرد و بهترین نتایج هر مدل ترکیبی در بهترین سطح تجزیه مقایسه شده است. نتایج نشان می‌دهد که همه مدل‌های ترکیبی نتایج بهتری نسبت به مدل ANN منفرد ارائه می‌کنند. مقدار شاخص RMSE در بخش صحت‌سنجی همه مدل‌های ترکیبی ۰/۳ است که نسبت به مدل ANN منفرد کاهش یافته است.

### نتایج مدل ترکیبی WANN در سطح سوم تجزیه

در سطح سه، به ازای هر متغیر ورودی به مدل موجک، یک زیر سیگنال اصلی ( $a_{1i}$ ) و سه زیر سیگنال جزئی ( $d_{1i}$  و  $d_{2i}$  و  $d_{3i}$ ) حاصل از تجزیه توسط هر مدل پیوسته یا گسسته ایجاد می‌شود که بعنوان ورودی به مدل شبکه عصبی وارد می‌شوند. مقادیر شاخص‌های اعتبارسنجی در سطح سه در هر بخش در شکل ۹ آورده شده است.

در سطح سه، مقادیر شاخص‌ها در هر بخش نشان می‌دهد که دقت مدل Sym3-ANN در تمامی foldها از مدل Db2-ANN بالاتر است، در مقایسه نتایج دو مدل ترکیبی موجک گسسته و شبکه عصبی در دو fold اول دقت مدل Fk2-ANN بالاتر است در حالی که در دو fold بعد دقت مدل Haar-ANN بالاتر است. در جدول ۴ مشاهده می‌شود که عملکرد مدل ترکیبی Sym3-ANN در سطح سه نیز بهتر از سایر مدل‌ها می‌باشد بطوری که مقدار شاخص NSE در بخش واسنجی ۰/۸۱ و در بخش صحت‌سنجی به ۰/۶۲ رسیده است. مقدار RMSE در واسنجی ۰/۲۵ و در صحت‌سنجی ۰/۳ است که عملکرد بالای مدل ترکیبی Sym3-ANN را نشان می‌دهد. مقدار ضریب همبستگی در

جدول ۴- متوسط مقادیر شاخص‌های اعتبارسنجی مدل‌ها در سطح سوم تجزیه

Table 4- The average value of the assessment indices at the third level of decomposition

Hybrid model مدل هیبریدی	The optimal number of neurons تعداد بهینه نوروها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE (m <sup>3</sup> /s)	R	NSE	RMSE (m <sup>3</sup> /s)	R
Sym3-ANN	3	0.81	0.25	0.90	0.62	0.30	0.85
Db2-ANN	6	0.78	0.27	0.89	0.61	0.30	0.81
Haar-ANN	6	0.78	0.27	0.89	0.59	0.31	0.80
Fk2-ANN	7	0.73	0.29	0.86	0.60	0.30	0.80

در دو بخش واسنجی و صحت‌سنجی و شاخص NSE در بخش صحت‌سنجی تنها یک درصد نسبت به Fk2-ANN بالاتر می‌باشد و عملاً تفاوت معنی‌داری بین این دو مدل ملاحظه نمی‌شود. بررسی تعداد نورون‌های بهینه در شبکه‌های عصبی ترکیبی نیز نشان می‌دهد که مدل sym3-ANN توانسته است با کمترین تعداد نورون در لایه میانی، بهترین نتیجه را ارائه دهد که این امر نشان‌دهنده آموزش‌پذیری آسان و با کمترین پیچیدگی شبکه عصبی بوده است.


در شکل ۱۰ مقادیر جریان مشاهداتی و جریان مدل‌سازی شده توسط مدل منفرد ANN و چهار مدل ترکیبی در بهترین سطح تجزیه ارائه شده است. با توجه به شکل ۱۰ مشاهده می‌شود که مدل‌های هیبریدی توانسته‌اند دبی‌های کمتر را با دقت بهتری نسبت به مدل ANN منفرد برآورد نمایند. همچنین برآورد مقادیر حداکثری نیز در مدل‌های ترکیبی بسیار بهبود یافته است که این با نتایج دالکلیک و هاشمی (Dalkiliç & Hashemi, 2020) و بیلماز و همکاران (Yilmaz et al., 2022) مطابقت دارد. در این میان، ضعیف‌ترین عملکرد موجک‌ها مربوط به موجک هار بود. همچنین موجک Kf2 که کمتر در مطالعات هیدرولوژی به کار گرفته شده بود، نیز عملکردی متوسط داشته است که این موضوع با نتایج احمدی و مداح (Ahmadi & Maddah, 2020) مطابقت دارد.

مقدار شاخص NSE بیشترین مقدار را در دو بخش واسنجی و صحت‌سنجی در مدل ترکیبی Sym3-ANN دارد که بترتیب ۰/۸۱ و ۰/۶۲ می‌باشد که بطور قابل ملاحظه‌ای نسبت به مدل ANN منفرد بهبود یافته و همچنین نسبت به سایر مدل‌های ترکیبی نتایج بهتری در دو بخش واسنجی و صحت‌سنجی ارائه می‌کند که این نتایج همسو با نتایج فریره و همکاران (Freire et al., 2019) می‌باشد. مقدار شاخص R نیز بالاترین مقدار را در مدل ترکیبی Sym3-ANN دارد لذا مدل Sym3-ANN در سطح تجزیه سه بالاترین دقت مدل‌سازی را دارد. در مقایسه دیگری بین دو مدل ترکیبی Db2-ANN در سطح سه و مدل Haar-Ann در سطح دو ملاحظه می‌شود که مقادیر شاخص‌های ارزیابی مدل‌ها در بخش صحت‌سنجی دقت یکسانی را برای این دو مدل ارائه داده‌اند اما مدل ترکیبی Db2-ANN در بخش واسنجی دقت بالاتری داشته است که با نتایج مهسواران و خوسا (Maheswaran & Khosa, 2012) همسو می‌باشد و لذا مدل Db2-ANN بعد از مدل ترکیبی Sym-ANN دقت بالاتری دارد. مقادیر شاخص‌ها برای دو مدل پیوسته نشان می‌دهد که در دو بخش واسنجی و صحت‌سنجی دقت مدل ترکیبی Sym3-Ann بالاتر از مدل Db2-Ann است. همچنین مقادیر شاخص‌ها برای دو مدل گسسته نشان می‌دهد که مدل Haar-ANN در سطح دو اختلاف چندانی با دقت مدل Fk2-ANN ندارد بطوری‌که در مدل Haar-ANN ضریب همبستگی

جدول ۵- مقایسه نتایج بهترین مدل‌های ترکیبی با مدل شبکه عصبی منفرد در مراحل واسنجی و صحت‌سنجی

Table 5- Comparison of the results of the best combined models with a singular neural network model in the calibration and validation stages

Model Name نام مدل	Decomposition level سطح تجزیه	The optimal number of neurons تعداد بهینه نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
			NSE	RMSE (m <sup>3</sup> /s)	R	NSE	RMSE (m <sup>3</sup> /s)	R
ANN	-	6	0.64	0.34	0.80	0.42	0.36	0.73
Sym3-ANN	Level3	3	0.81	0.25	0.90	0.62	0.30	0.85
Db2-ANN	Level3	6	0.78	0.27	0.89	0.61	0.30	0.81
Haar-ANN	Level2	5	0.73	0.29	0.87	0.61	0.30	0.81
Fk2-ANN	Level3	7	0.73	0.29	0.86	0.60	0.30	0.80



شکل ۱۰- مقایسه جریان مشاهداتی با جریان پیش‌بینی شده با مدل‌های شبکه عصبی منفرد و ترکیبی

Figure 10- Comparison between observed data flow and predicted flow using singular and combined neural network models

## نتیجه‌گیری

Fk2 ساختاری گسسته دارند در تجزیه داده‌های جریان ماهانه که از نوع پیوسته هستند، کارایی مناسبی نداشته‌اند؛ بطوری‌که در بررسی نتایج هر مدل ترکیبی مشاهده شد که مدل‌های موجک پیوسته نسبت به مدل‌های موجک گسسته عملکرد بهتری دارند و نتایج مدل شبکه عصبی منفرد را تا حد قابل قبولی بهبود می‌بخشند، بطوری‌که مدل‌های گسسته تا ۹ درصد و مدل‌های پیوسته تا ۱۱ درصد نتایج مدل ANN منفرد را بهبود بخشیده‌اند. از آنجایی‌که آب و هوا و ویژگی‌های حوضه می‌تواند بر نوع نوسانات داده‌ها و در نتیجه نتایج حاصل از تجزیه مدل موجک تأثیرگذار باشد، انتخاب مدل موجک مناسب برای به‌دست آوردن بهترین نتایج مهم است. با توجه به وجود تفاوت‌های موجود میان نتایج تحقیقات مختلف در انتخاب بهترین نوع موجک، پیشنهاد می‌شود که برای دستیابی به بهترین پیش‌بینی‌ها، از هر دو نوع موجک پیوسته و گسسته در مدل‌سازی‌ها استفاده شده و بهترین نتایج برگزیده شود. همچنین، نتایج تحقیق حاضر نشان داد که انتخاب سطح تجزیه نیز در دقت نتایج حاصل مدل ترکیبی حائز اهمیت است؛ در این تحقیق اگرچه در سطح سوم تجزیه داده‌ها برای اکثر مدل‌ها نتایج بهتری ارائه داد اما دقت نتایج در سطح دو و سه تفاوت معنی‌داری نداشتند؛ از آنجایی‌که تعداد کمتر متغیرهای ورودی در مدل‌های شبکه عصبی منجر به دقت بالاتری در نتایج مدل‌سازی می‌شود، پیشنهاد می‌شود جهت کاهش مؤلفه‌های ورودی به مدل شبکه عصبی و در نتیجه کاهش زمان اجرای مدل، تجزیه در سطح دو صورت گیرد.

وجود تغییرات آماری در داده‌ها سبب می‌شود که مدل‌سازی جریان رودخانه با مدل‌های داده‌مبناء با مشکلاتی در فرآیند یادگیری مدل همراه باشد. از این رو لازم است با استفاده از مدل‌سازی تلفیقی، دقت پیش‌بینی جریان ارتقاء یابد. هدف از پژوهش حاضر، ارزیابی عملکرد انواع مدل موجک گسسته و پیوسته در سطوح تجزیه متفاوت در بهبود کارایی مدل شبکه عصبی مصنوعی برای پیش‌بینی رواناب بود. بدین منظور، حوضه آبریز کارده واقع در حوضه قره قوم، در شمال شرق ایران به عنوان منطقه مطالعاتی مورد ارزیابی قرار گرفت و جریان ورودی به سد کارده که یکی از منابع اصلی تأمین آب شرب شهر مشهد است مورد مدل‌سازی قرار گرفت بررسی همبستگی متغیرهای بارش و جریان ماهانه این رودخانه نشان داد که رواناب در دو گام زمانی T-1 و T-2 بهترین متغیرهای پیش‌بینی‌کننده (در سطح اطمینان ۹۵٪) جریان رودخانه هستند. در این تحقیق، کارایی دو مدل آنالیز موجک گسسته Haar و Fejer-Korovkin2 و دو مدل پیوسته Symlet3 و Daubechies2 در سه سطح تجزیه در ترکیب با مدل شبکه عصبی به منظور پیش‌بینی جریان مورد ارزیابی قرار گرفت. کارایی مدل‌های هیبریدی WANN با استفاده از روش صحت‌سنجی متقاطع در ۴ سطح ارزیابی شد. نتایج نشان داد که مدل‌های ترکیبی در مقایسه با مدل شبکه عصبی منفرد کارایی بهتری داشتند. از آنجا که دو مدل Haar و

## References

- Abda, Z., Chettih, M., & Zerouali, B. (2021). Assessment of neuro-fuzzy approach based different wavelet families for daily flow rates forecasting. *Journal of Model Earth Syst Environ*, 7, 1523–1538. <https://doi.org/10.1007/s40808-020-00855-1>
- Adamowski, J.F., & Sun, K. (2010). Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390(1), 85-91. <https://doi.org/10.1016/j.jhydrol.2010.06.033>
- Ahmadi, F., & Maddah, M.A. (2020). Development of wavelet-Kstar algorithm hybrid model for the monthly

- precipitation prediction (case study: synoptic station of shvaz). *Journal of Soil and Water Research*, 52(2), 409-420. (In Persian). <https://doi.org/10.22059/IJSWR.2021.314110.668808>
4. Ahmadi, M., Moeini, A., Ahmadi, H., Motamedvaziri, B., & Zehtabiyani, G.R. (2019). Comparison of the performance of SWAT, IHACRES and artificial neural networks models in rainfall-runof simulation (case study: Kan watershed, Iran). *Journal of Physics and Chemistry of the Earth*, 111, 65–77. <https://doi.org/10.1016/j.pce.2019.05.002>
  5. Ahooghalandari, M., Khiadani, M., & Kothapalli, G. (2016). Assessment of Artificial Neural Networks and IHACRES models for simulating streamflow in Marillana catchment in the Pilbara, Western Australia. *Austr Journal Water Resource*, 19, 116–126.
  6. Araghinejad, S. (2014). Data-driven modeling: using MATLAB in water resources and environmental engineering. *Journal of Water Science and Technology Library*, 67, 265.
  7. Belayneh, A., & Adamowski, J. (2012). Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression. *Journal of Applied Computational Intelligence and Soft Computing*, 1–13. <https://doi.org/10.1155/2012/794061>
  8. Cannas, B., Alessandra, F., See, L., & Sias, G. (2006). Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning. *Physics and Chemistry of the Earth*, 31(18), 1164–1171. <https://doi.org/10.1016/j.pce.2006.03.020>
  9. Chakraborty, S., & Biswas, S. (2023). River discharge prediction using wavelet-based artificial neural network and long short-term memory models: a case study of Teesta River Basin, India. *Stochastic Environmental Research and Risk Assessment*, 37(8), 1-22. <https://doi.org/10.1007/s00477-023-02443-y>
  10. Chen, C.H. (1999). Wevelet approach to optimizing dynamic system. *Control Theory and Applications. IEE Proceedings*, 146(2), 213-219. <https://doi.org/0.1049/ip-cta:19990516>
  11. Danandeh Mehr, A., Kahya, E., & Olyaie, E. (2013). Streamfow prediction using linear genetic programming in comparison with a neurowavelet technique. *Journal of Hydrology*, 505, 240–249. <https://doi.org/10.1016/j.jhydrol.2013.10.003>
  12. Dastorani, M.T., Hajibigloo, M., & Shojae, H. (2022). Identification of the land use changes on river flooding bed, affective on reservoir water quality (Case study: headwater of Kardeh reservoir). *Geography and Development*, 20(66), 255-282. <https://doi.org/10.22111/J10.22111.2022.6739>
  13. Dalkılıç, H.Y., & Hashimi, S.A. (2020). Prediction of daily streamfow using artificial neural networks (ANNs), wavelet neural networks (WNNs), and adaptive neuro-fuzzy inference system (ANFIS) models. *Water Supply*, 20(4), 1396–1408. <https://doi.org/10.2166/ws.2020.062>
  14. Freire, P.K.d.M.M., Santos, C.A.G., & da Silva, G.B.L. (2019). Analysis of the use of discrete wavelet transforms coupled with ANN for shortterm streamflow forecasting. *Apply Soft Computer*, 80, 494–505. <https://doi.org/10.1016/j.asoc.2019.04.024>
  15. Graps A. (1995). An InTRODuction to wavelet. *Computing in Science and Engineering*, 2, 50-61. <https://doi.org/10.1109/99.388960>
  16. Grossmann, A., & Morlet, J. (1984). Decomposition of Hardy functions into square integrable wavelets of constant shape. *SIAM Journal on Mathematical Analysis*, 15(4), 723–736. <https://doi.org/10.1137/0515056>
  17. Güneş, M., Parim, C., Yıldız, D., & Büyüklü, A. (2021). Predicting monthly streamflow using a hybrid wavelet neural network: case study of the Çoruh River Basin. *Polish Journal of Environmental Studies*, 30(4), 3065–3075. <https://doi.org/10.15244/pjoes/130767>
  18. Jimeno-Saez, P., Senent-Aparicio, J., Perez-Sanchez, J., & PulidoVelazquez, D. (2018). A comparison of SWAT and ANN models for daily runoff simulation in diferent climatic zones of peninsular Spain. *Water*, 10(2), 192. <https://doi.org/10.3390/w10020192>
  19. Katipoglu, O.M. (2023). Monthly streamfow prediction in Amasya, Türkiye, using an integrated approach of a feedforward backpropagation neural network and discrete wavelet transform. *Modeling Earth Systems and Environment*, 9(2), 1-13. <https://doi.org/10.1007/s40808-022-01629-7>
  20. Kim, T.W., Valdes, 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. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(319\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(319))
  21. Maheswaran, R., Khosa, R. (2012). Comparative study of different wavelets for hydrologic forecasting. *Computers and Geosciences*, 46, 284–295. <https://doi.org/10.1016/j.cageo.2011.12.015>
  22. Mallat, S. (1999). A Wavelet Tour of Signal Processing, 2nd ed. Academic, New York.
  23. Misiti, M., Misiti, Y., Oppenheim, G., & Poggi, J.M. (2001). Wvelet toolbox for use with Matlab.
  24. Modaresi, F., Araghinejad, S., & Ebrahimi, K. (2017). A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and k-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions. *Water Resources Management*, 32(5), 243-258. <https://doi.org/10.1007/s11269-017-1807-2>
  25. Momeneh, S., & Nourani, V. (2022). Application of a novel technique of the multi-discrete wavelet transforms

- in hybrid with artificial neural network to forecast the daily and monthly streamflow. *Modeling Earth Systems and Environment*, 8(2), 4629–4648. <https://doi.org/10.1007/s40808-022-01387-6>
26. Moriasi, D.N., Arnold, J.G., & Van Liew, M.W. (2007). Model evaluation guidelines for systemic quantification of accuracy in watershed simulations. *Transactions of ASABE*, 50(3), 885-900. <https://doi.org/10.13031/2013.23153>
  27. Nayak, P., Venkatesh, B., Krishna, B., & Jain, S.K. (2013). Rainfall-runof modeling using conceptual, data driven, and wavelet based computing approach. *Journal of Hydrology*, 493, 57–67. <https://doi.org/10.1016/j.jhydrol.2013.04.016>
  28. Okkan, U. (2013). Wavelet neural network model for reservoir inflow prediction. *Scientia Iranica*, 19, 1445-1455. <https://doi.org/10.1016/j.scient.2012.10.009>
  29. Partal, T., Kisi, O. (2007). Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology* 342(1):199–212. <https://doi.org/10.1016/j.jhydrol.2007.05.026>
  30. Poonia, V., & Tiwari, H.L. (2020). Rainfall-runoff modeling for the Hoshangabad Basin of Narmada River using artificial neural network. *Arabian Journal of Geosciences*, 13(18), 1–10. <https://doi.org/10.1007/s12517-020-05930-6>
  31. Rajendra, P., Murthy, K.V.N., Subbarao, A., & Boadh, R. (2019). Use of ANN models in the prediction of meteorological data. *Modeling Earth Systems and Environment*, 5(14), 1051–1058. <https://doi.org/10.1007/s40808-019-00590-2>
  32. Santos, C.A.G., & Silva, G.B.L. (2014). Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models. *Hydrological Sciences Journal* 59(2) :312–324. <https://doi.org/10.1080/02626667.2013.800944>
  33. Santos, C.A.G., Freire, P.K.M.M., Silva, G.B.L., & Silva, R.M. (2014). Discrete wavelet transform coupled with ANN for daily discharge forecasting into Três Marias reservoir. *Proceedings of the International Association of Hydrological Sciences*, 364, 100–105. <https://doi.org/10.5194/piahs-364-100-2014>
  34. Shoaib, M., Shamseldin, A.Y., & Melville, B.W. (2014). Comparative study of different wavelet based neural network models for rainfall-runoff modelling. *Journal of Hydrology*, 515(1-2), 47-58. <https://doi.org/10.1016/j.jhydrol.2014.04.055>
  35. Siddiqi, T.A., Ashraf, S., Khan, S.A., & Iqbal, M.J. (2021). Estimation of datadriven streamflow predicting models using machine learning methods. *Arabian Journal of Geosciences*, 14(11), 1058-1567. <https://doi.org/10.1007/s12517-021-07446-z>
  36. Sithara, S., Pramada, S.K., & Thampi, S.G. (2020). Sea level prediction using climatic variables: a comparative study of SVM and hybrid wavelet SVM approaches. *Acta Geophysica*, 68, 1779–1790. <https://doi.org/10.1007/s11600-020-00484-3>
  37. Sun, Y., Niu, J., & Sivakumar, B. (2019). A comparative study of models for short-term streamflow forecasting with emphasis on waveletbased approach. *Stochastic Environmental Research and Risk Assessment*, 33, 1875–1891. <https://doi.org/10.1007/s00477-019-01734-7>
  38. Tareke, K.A., & Awoke, A.G. (2023). Hydrological drought forecasting and monitoring system development using artificial neural network (ANN) in Ethiopia. *Heliyon*, 9(2). <https://doi.org/10.1016/j.heliyon.2023.e13287>
  39. Tayyab, M., Zhou, J., Dong, X., Ahmad, I., & Sun, N. (2019). Rainfall-runof modeling at Jinsha River basin by integrated neural network with discrete wavelet transform. *Meteorology Atmospheric Physics*, 131(1), 115–125. <https://doi.org/10.1007/s00703-017-0546-5>
  40. Tiwari, D.K., Tiwari, H.L., & Nateriya, R. (2022). Runoff modeling in Kolar river basin using hybrid approach of wavelet with artificial neural network. *Journal of Water and Climate Change*, 13(3), 963. <https://doi.org/10.2166/wcc.2021.246>
  41. Tiwari, M.K., & Chatterjee, C. (2011). A new wavelet-bootstrap-ANN hybrid model for daily discharge forecasting. *Journal of Hydroinformatics*, 13(3), 500–519. <https://doi.org/10.2166/hydro.2010.142>
  42. Wagena, M.B., Goering, D., Collick, A.S., Bock, E., Fuka, D.R., Buda, A., & Easton, Z.M. (2020). Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling & Software*, 126(4), 104669. <https://doi.org/10.1016/j.envsoft.2020.104669>
  43. Wambua, R.M. (2014). Drought forecasting using indices and artificial neural networks for upper tana River Basin, Kenya-A review concept. *Journal of Civil & Environmental Engineering*, 4(4), 1-12. <https://doi.org/10.4172/2165-784X.1000152>
  44. Wang, W., & Ding, J. (2003). Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1(1), 67-71.
  45. Yilmaz, M., Tosunoğlu, F., Kaplan, N.H., Üneş, F., & Hanay, Y.S. (2022). Predicting monthly streamflow using artificial neural networks and wavelet neural networks models. *Modeling Earth Systems and Environment*, 8(4), 3-20. <https://doi.org/10.1007/s40808-022-01403-9>
  46. Young, C.C., Liu, W.C., & Wu, M.C. (2017). A physically based and machine learning hybrid approach for accurate rainfall modeling during extreme typhoon events. *Applied Soft Computing*, 53(3-4), 205–216. <https://doi.org/10.1016/j.asoc.2016.12.052>