

Assessment of the performance of various wavelet transforms in combined wavelet-neural network modeling for monthly river flow prediction (Case study: Kardeh watershed)

Atefe Kazemi choolanak¹, Fereshte Modaresi^{2*}, Abolfazl Mosaedi³

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 (1370-1399). 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

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 variables of the runoff of the previous month (Q_{t-1}) and the runoff of the previous two months (Q_{t-2}) were analyzed by each of the Haar and Fejer-Korovkin2 discrete wavelet transforms and the two continuous Symlet3 and Daubechies2 wavelets in three levels and the results from each level of decomposition, it 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.

Conclusions

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

مجله علمی پژوهشی
فصلنامه علمی پژوهشی
مجله علمی پژوهشی

ارزیابی کارایی انواع تبدیل موجک در مدل سازی ترکیبی موجک- شبکه عصبی مصنوعی برای پیش بینی جریان ماهانه رودخانه (مطالعه موردی: رودخانه کارده)

عاطفه کاظمی چولانک^۱، فرشته مدرسی^{۲*}، ابوالفضل مساعدی^۳

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 صحت سنجی 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، بطوری که شاخص‌های RMSE، R 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 مولفه‌های ورودی به مدل ANN و کاهش زمان اجرای مدل، تجزیه در سطح دو انجام شود.

کلمات کلیدی: تبدیل موجک، شبکه عصبی مصنوعی، صحت سنجی متقاطع، مدل هیبریدی، موجک پیوسته، موجک گسسته.

مقدمه

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 فرایند محور و رویکردهای تجربی داده محور وجود دارد (Ahooghalandari et al., 2016). مطالعات صورت گرفته برای مقایسه این دو رویکرد اغلب نشان می

دهند که مدل‌های شبکه عصبی مصنوعی (ANN) پیش‌بینی‌های بهتری را نسبت به مدل‌های فیزیکی و مفهومی نظیر SWAT، JHACRES، 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 (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.

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 and 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 موفق‌تری 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 موفق‌تری دست یافته‌اند؛ به‌عنوان 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 Daubechies، Symlet، Coifet 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 And 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 And 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 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 چینشا 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 (Tayyab et al., 2019)؛ Chakraborty and Biswas, 2023؛ Dalkılıç and Hashemi, 2020). 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.

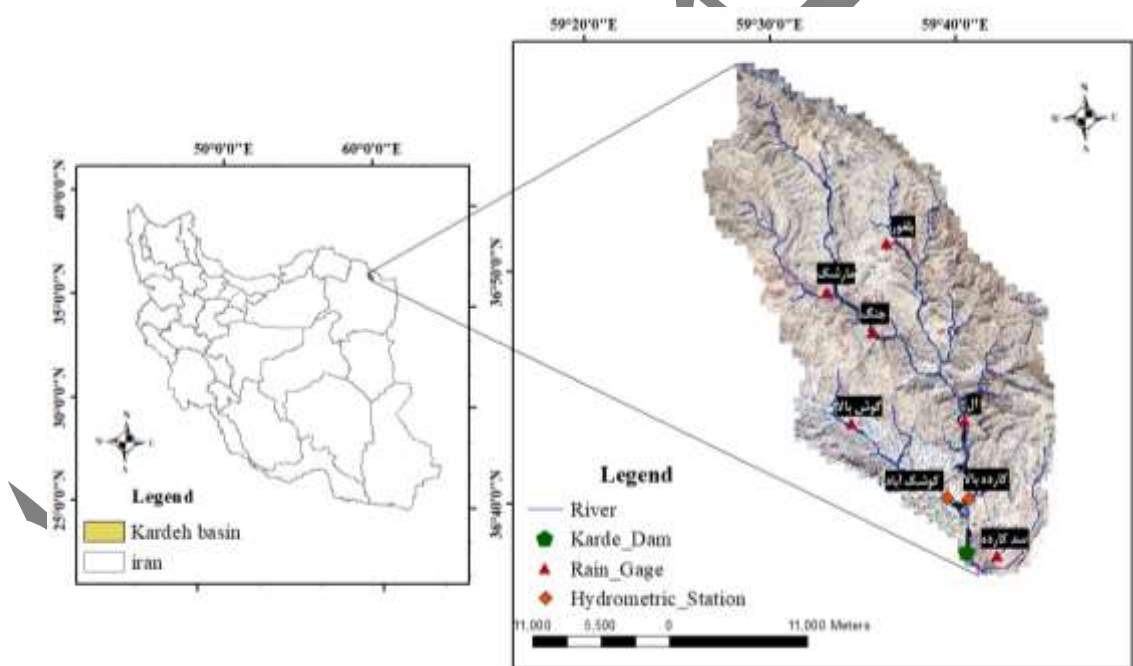
مواد و روش‌ها

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. به منظور برآورد رواناب ماهانه زیرحوضه بالادست سد کارده از آمار ماهانه ایستگاه‌های هواشناسی و هیدرومتری حوضه (جدول ۱ و شکل ۱) در بازه زمانی ۳۰ ساله (۱۳۷۰-۱۳۹۹) 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 (۱۳۷۰-۱۳۹۹)
 Table1- Geographical and statistical properties of the meteorological and hydrometric stations in the study area in the period 1991-2021

Station type نوع ایستگاه	Station نام ایستگاه	XUTM طول	YUTM عرض	Mean میانگین	Stdev انحراف معیار
Meteorological 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
 Fig. 1- The geographical location of the study area and its hydro-meteorological and hydrometric stations



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

Fig.2- Monthly variations of streamflow and precipitation within the study area over a 30-year period.

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 (Grossmann and Morlet., 1984; Nayak et al., 2013). تحلیل فوریه دارای یک نقطه ضعف اولیه است که اطلاعات زمانی را در تبدیل به حوزه فرکانسی از دست می‌دهد، در حالیکه WT شامل چند تفکیک پذیری در حوزه زمان و فرکانس است (Tiwari and 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 and 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 And 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 and Valdes, 2003)

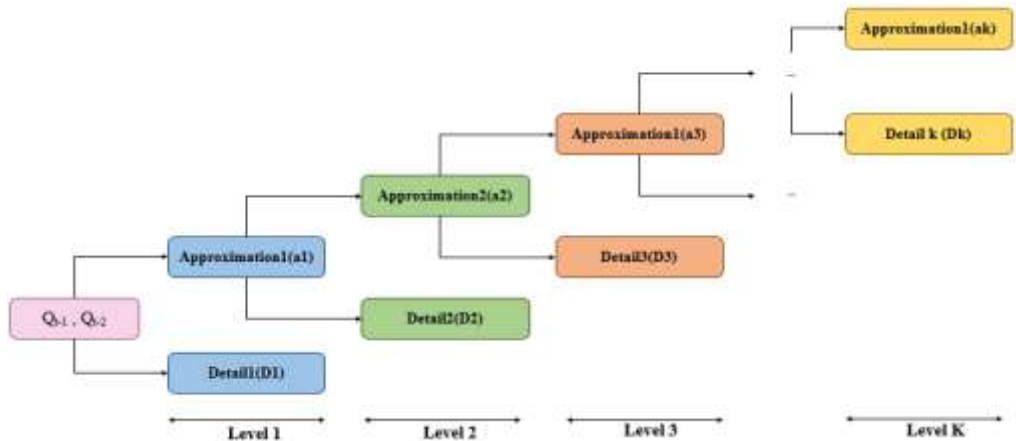
$$CWT_x^\varphi(\tau, s) = |s|^{-\frac{1}{2}} \varphi * \int_{-\infty}^{+\infty} \left(\frac{t-\tau}{s}\right) dt \quad (1)$$

که در آن S پارامتر مقیاس (عکس فرکانس)، τ پارامتر انتقال و $*$ نشان دهنده 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 بر اساس توان‌های دو عامل (مقیاس‌ها و موقعیت‌های دوتایی) هستند (Partal and 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 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 φ ، الگوریتم تبدیل موجک "a Trous" 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 and 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.



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

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 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, ..., 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.

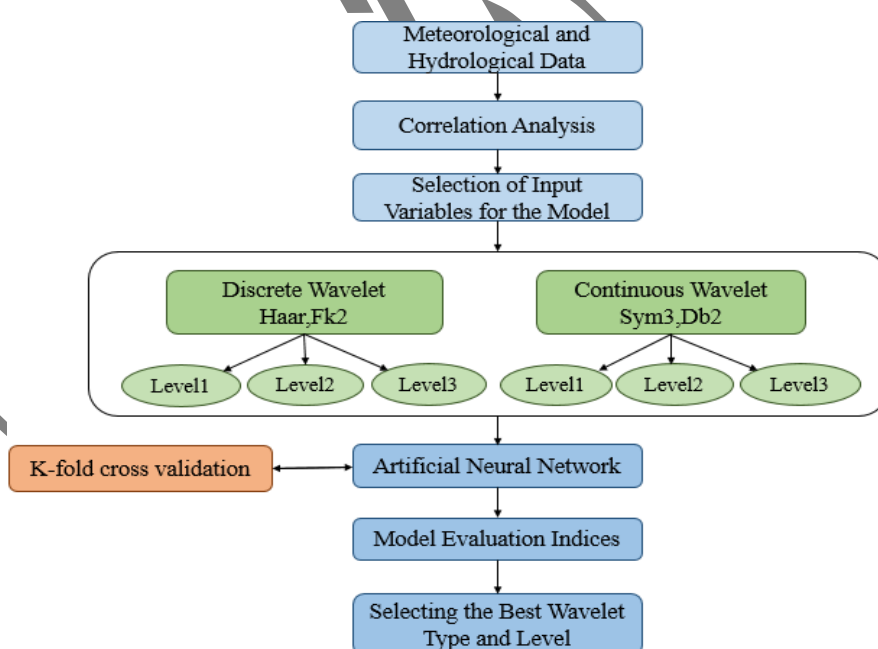
مدل ترکیبی موجک- شبکه عصبی (WANN)

مدل WANN یک مدل ترکیبی از نوع سری است که در آن، خروجی تبدیل موجک به عنوان روش پیش پردازش کننده داده‌ها به عنوان ورودی به شبکه عصبی مصنوعی به عنوان 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 نشان دهنده قابلیت بالای آنها در افزایش دقت پیش‌بینی‌ها هستند (Momeneh And Nourani., 2022)؛ And Hashemi, (Güneş et al., 2021; Dalkiliç 2020)، در سه سطح تجزیه ۱، ۲ و ۳ استفاده شد و زیرسری‌های اصلی (ai) و جزئی (di) در هر تجزیه بعنوان ورودی به مدل شبکه عصبی مورد استفاده قرار گرفتند. فلوجارت مراحل انجام تحقیق در شکل ۴ آورده شده است.

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



شکل ۴- شمای کلی روند تحقیق

Fig4- Flowchart of the current research

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 (Moriasi et al., 2007):

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

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

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


در روابط فوق، P_i و O_i به ترتیب جریان ماهانه مشاهداتی و پیش‌بینی شده در زمان i ، \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. هرچه مقدار این شاخص به صفر نزدیکتر باشد، نشان دهنده خطای کمتر و کارایی بهتر مدل می‌باشد. شاخص R در دامنه -1 تا 1 تغییر می‌کند. مقدار 1 و -1 به ترتیب نشان دهنده 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 معنی‌داری 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) و مشاهده شد که جریان هر ماه با جریان در یک و دو ماه قبل از خود دارای همبستگی بالایی در سطح اطمینان ۹۵٪ ($P\text{-val} < 0.05$) است، لذا دو متغیر جریان در زمان $T-1$ و $T-2$ (Q_{t-1}) و Q_{t-2}) به عنوان متغیرهای پیش‌بینی کننده جریان مورد استفاده قرار گرفتند و مدل زیر برای این مطالعه تعریف شد.

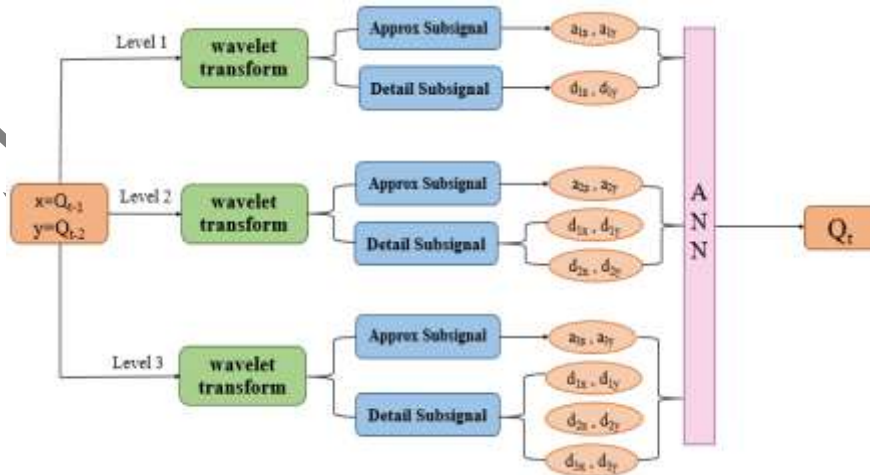
$$Q_t = f((Q_{t-1}) \cdot (Q_{t-2})) \quad (9)$$



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

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 به عنوان ورودی به مدل ANN داده شد (شکل ۶).

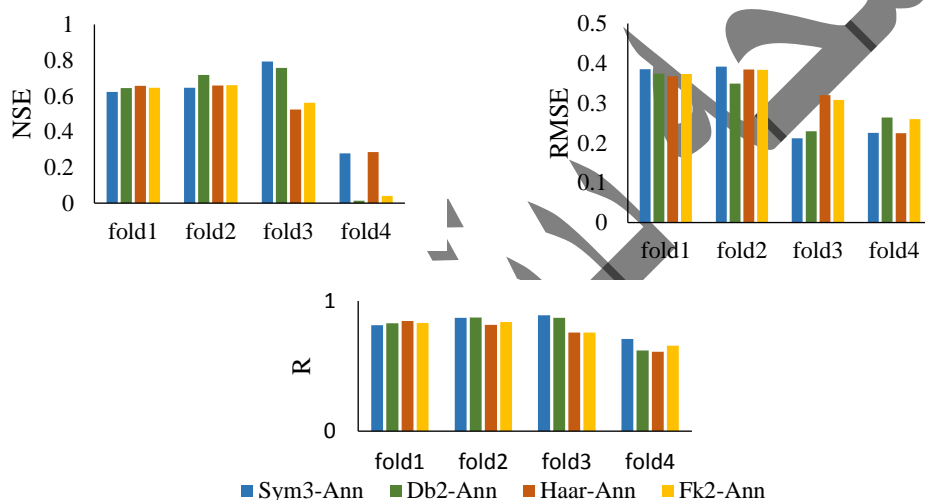


شکل ۶- فلوچارت تشکیل مدل ترکیبی برای هر یک از روش‌های آنالیز موجک
 Fig.6- Flowchart for constructing a combined model for each of the wavelet analysis methods

۱. 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 صحت سنجی بدست آمده از مدل‌های ترکیبی حاصل از ۴ آنالیز موجک پیوسته و گسسته در هر یک از لایه‌های صحت سنجی متقاطع بر اساس شاخص‌های NSE، RMSE و R نشان داده شده است.

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 Sym3ANN بالاتر است بطوری که در میانگین کلی هم دقت بالاتری را نشان می‌دهد.



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

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

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 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.

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	The optimal number of neurons تعداد بهینه نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE(m ³ /s)	R	NSE	RMSE(m ³ /s)	R
مدل هیبریدی 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

۲. 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_{1i} و d_{2i}) به 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.



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

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

در سطح دو، مقایسه نتایج دو مدل Sym3-ANN و Db2-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-ANN بالاتر است. همچنین جدول ۳ مقادیر شاخص‌ها را در دو بخش واسنجی و صحت‌سنجی در سطح دو نشان می‌دهد که ملاحظه می‌شود عملکرد مدل ترکیبی Sym3-ANN بهتر از سایر مدل‌ها می‌باشد، همچنین نتایج نشان می‌دهد بطور کلی تمامی مدل‌های ترکیبی در سطح تجزیه دو عملکرد بالاتری نسبت به سطح تجزیه یک ارائه داده‌اند.

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

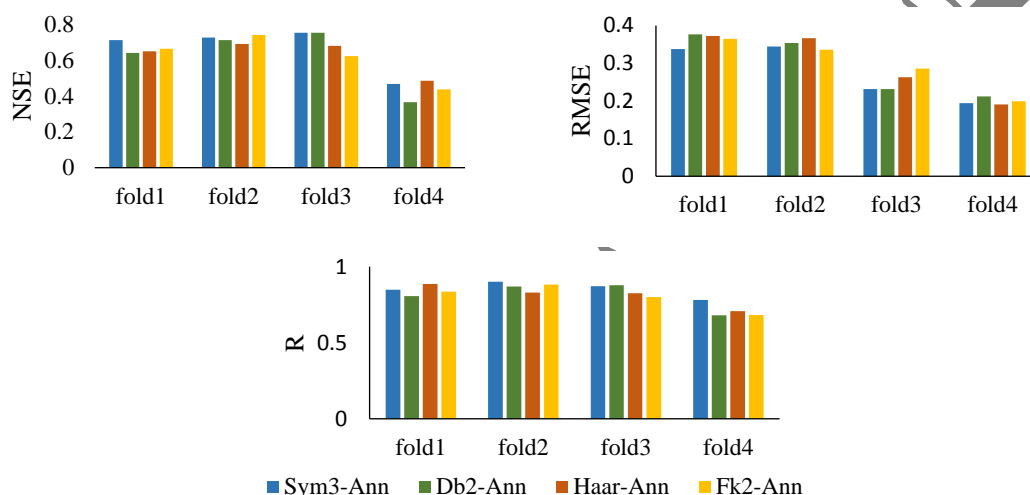
Table 3- The average value of the assessment indices at the second level of decomposition

Hybrid model	The optimal number of neurons تعداد بهینه نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE(m^3/s)	R	NSE	RMSE(m^3/s)	R
مدل هیبریدی 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

۳. 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_{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.



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

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

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 حالیکه 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 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.

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 نورون‌ها	Calibration واسنجی			Validation صحت‌سنجی		
		NSE	RMSE(m ³ /s)	R	NSE	RMSE(m ³ /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 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. 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 and 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 در دو بخش واسنجی و صحت‌سنجی و شاخص NSE در بخش صحت‌سنجی تنها یک درصد نسبت به Fk2-ANN بالاتر می‌باشد و عملاً تفاوت معنی داری 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 نشان دهنده آموزش پذیری آسان و با کمترین پیچیدگی شبکه عصبی بوده است.

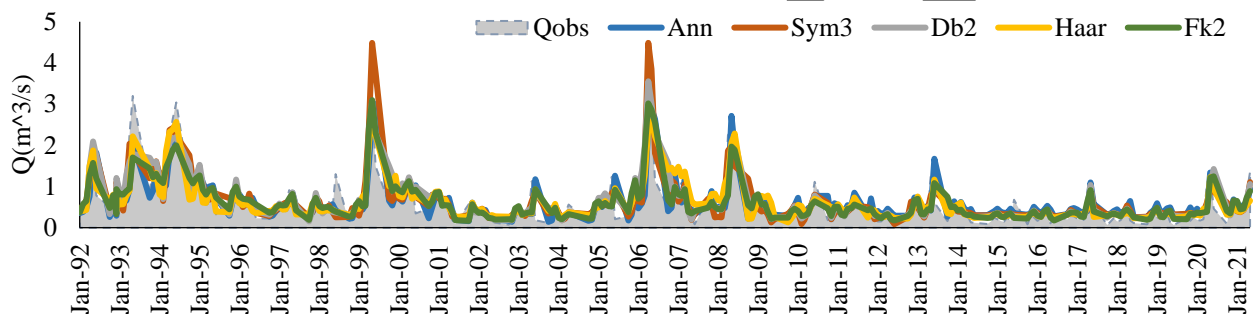
جدول ۵- مقایسه نتایج بهترین مدل‌های ترکیبی با مدل شبکه عصبی منفرد در مراحل واسنجی و صحت‌سنجی

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 ³ /s)	R	NSE	RMSE(m ³ /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

در شکل ۱۰ مقادیر جریان مشاهداتی و جریان مدل سازی شده توسط مدل منفرد ANN و چهار مدل ترکیبی در بهترین سطح تجزیه ارائه شده است. با توجه به شکل ۱۰ مشاهده می شود که مدل های هیبریدی توانسته اند دبی های کمتر را با دقت بهتری نسبت به مدل ANN منفرد برآورد نمایند. همچنین برآورد مقادیر حداکثری نیز در مدل های ترکیبی بسیار بهبود یافته است که این با نتایج دالکلیک و هاشمی (Dalkiliç And Hashemi, 2020) و بیلماز و همکاران (Yilmaz *et al.*, 2022) مطابقت دارد. در این میان، ضعیف ترین عملکرد موجک ها 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 And Maddah, 2020) مطابقت دارد.



شکل ۱۰- مقایسه جریان مشاهداتی با جریان پیش بینی شده با مدل های شبکه عصبی منفرد و ترکیبی

Fig.10 Comparison between observed data flow and predicted flow using singular and combined neural network models.

جمع بندی

وجود تغییرات آماری در داده ها سبب می شود که مدل سازی جریان رودخانه با مدل های داده مبناء با مشکلاتی در فرآیند یادگیری مدل همراه باشد. از این رو لازم است با استفاده از مدل سازی تلفیقی، دقت پیش بینی 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 پیش بینی 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 مدل سازی 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 پیش بینی کننده (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 پیش بینی جریان مورد ارزیابی قرار گرفت. کارایی مدل های هیبریدی WANN با استفاده از روش صحت سنجی متقاطع در ۴ سطح ارزیابی شد. نتایج نشان داد که مدل های ترکیبی در مقایسه

با مدل شبکه عصبی منفرد کارایی بهتری داشتند. از آنجا که دو مدل Haar و Fk2 ساختاری گسسته دارند در تجزیه داده های جریان ماهانه که از نوع پیوسته هستند، کارایی مناسبی نداشته‌اند؛ بطوریکه در بررسی نتایج هر مدل ترکیبی مشاهده شد که مدل های موجک پیوسته نسبت به مدل های موجک گسسته عملکرد بهتری دارند و نتایج مدل شبکه عصبی منفرد را تا حد قابل قبولی بهبود می‌بخشند، بطوریکه مدل های گسسته تا ۹ درصد و مدل های پیوسته تا ۱۱ درصد نتایج مدل ANN منفرد را بهبود بخشیده‌اند. از آنجایی که آب و هوا و ویژگی های حوضه می‌تواند بر نوع نوسانات داده‌ها و در نتیجه نتایج حاصل از تجزیه مدل موجک تأثیر گذار باشد، انتخاب مدل موجک مناسب برای به دست آوردن بهترین نتایج مهم است. با توجه به وجود تفاوت های موجود میان نتایج تحقیقات مختلف در انتخاب بهترین نوع موجک، پیشنهاد می‌شود که برای دستیابی به بهترین پیش بینی ها، از هر دو نوع موجک پیوسته و گسسته در مدل سازی ها 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 اگر چه در سطح سوم تجزیه داده‌ها برای اکثر مدل ها نتایج بهتری ارائه داد اما دقت نتایج در سطح دو و سه تفاوت معنی داری نداشته‌اند؛ از آنجایی که تعداد کمتر متغیرهای ورودی در مدل های شبکه عصبی منجر به دقت بالاتری در نتایج مدل سازی می‌شود، پیشنهاد می‌شود جهت کاهش مولفه های ورودی به مدل شبکه عصبی و در نتیجه کاهش زمان اجرای مدل، تجزیه در سطح دو صورت گیرد.

منابع

- 1- Abda, Z., Chettih, M., Zerouali, B. (2021). Assessment of neuro-fuzzy approach based diferent wavelet families for daily fow rates forecasting. *Journal of Model Earth Syst Environ*, 7:1523–1538. <https://doi.org/10.1007/s40808-020-00855-1>
- 2- 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>
- 3- 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., Zehtabian, 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 Phys Chem 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. <https://ro.ecu.edu.au/ecuworkspost2013/1977/>
- 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., Olyae, 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., Shojaee, 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. *Appl Soft Compute*, 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. *Pol J Environ Stud*, 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). *Wavelet 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-runoff 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, Ö. (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. *Model Earth Syst Environ*, 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 data driven 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 Geophys*, 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 wavelet based approach. *Stoch Environ Res Risk Assess*, 33:1875–1891. <https://doi.org/10.1007/s00477-019-01734-7>
- 38- Tayyab, M., Zhou, J., Dong, X., Ahmad, I., Sun, N. (2019). Rainfall-runoff modeling at Jinsha River basin by integrated neural network with discrete wavelet transform. *Meteorol Atmos Phys*, 131(1): 115–125. <https://doi.org/10.1007/s00703-017-0546-5>
- 39- 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>
- 40- 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>
- 41- 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>
- 42- 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>
- 43- Wang, W., Ding, J. (2003). Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1(1): 67-71.
- 44- 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>
- 45- Young, C.C., Liu, W.C., Wu, M.C. (2017). A physically based and machine learning hybrid approach for accurate rainfall-runoff modeling during extreme typhoon events. *Applied Soft Computing*, 53(3-4): 205–216. <https://doi.org/10.1016/j.asoc.2016.12.052>