

Research Paper



Noise reduction of monthly discharge time series using wavelet and chaos theory



Leila Malekani¹ , Reza Seyedi² , Mohammad Taghi Alami³

1. Assistant Professor, Department of Civil Engineering, Faculty of Technical and Engineering of Marand, University of Tabriz, Tabriz, Iran. lmalekani@yahoo.com
2. MSc of Water Resources Management, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. rezavadig2@gmail.com
3. Professor, Department of Water Resources Management, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. mtaalami@tabrizu.ac.ir

Keywords

Monthly discharge, Noise reduction, Wavelet, Chaos, ANN, Soofichay, Ajichay.

ABSTRACT**1- Introduction**

Rivers are an important and accessible water resource for fresh water supply. Given that Iran is located in an arid and semi-arid region and is currently facing water shortage problems, knowledge of the status of existing surface water allows it to be used for various purposes while adopting solutions that cause the least damage to these resources. For this purpose, researchers have tried to provide methods and models that can predict river flows well. With the development of artificial intelligence, its use in providing models has also expanded. Noise is usually present in hydrological data, which can lead to a decrease in prediction accuracy. Therefore, in addition to the development and introduction of various models, great importance has recently been placed on examining data and reduce or removing noise methods (Zerouali et al, 2021). A lot of research has been done to reduce or eliminate noise in random data such as river flow time series data, such as: Wang et al, 2024; Guo et al, 2023; Zerouali et al, 2021; Malekani, 2020 and etc.

Hydrology time series data consists of two different parts, the original signal and the noise value. Noise reduction means separating time series data into these two components, so that one component contains the original signal and the other contains noise (Rezaei & Jabbari, 2017). Noise reduction is an essential step in any measurement process that improves the accuracy of modeling and prediction. The conventional and classical statistical tool for distinguishing these two components is the Fourier transform and the wavelet transform, which are known as linear transforms. Wavelet transform is better than Fourier transform for non-stationary signals. The disadvantage of both methods is that many signals cover a spectral region of the original space as noise space, which causes the elimination of part of the original signal and it is necessary to develop and improve the filter techniques (Schreiber & Kantz, 1998). Therefore, in this study, two methods of wavelet and chaos theory were used to reduce the noise of the monthly discharge time series data of the Ajichay and Sufichay rivers, which are the most important sub-basins of Lake Urmia.

Received: 2025/02/19

Accepted: 2025/08/16

Published: 2025/10/20

*Correspondin Author: Leila malekani, lmalekani@yahoo.com

Malekani, leila., Eslami, mohammad., & Alami, Mohammad Taghi. (2025). Noise reduction of monthly discharge time series using wavelet and chaos theory. *Hydrogeomorphology*, 12(44): 95–115.

DOI: [10.22034/hyd.2025.65928.1778](https://doi.org/10.22034/hyd.2025.65928.1778)



Copyright: © by the authors

Publisher: University of Tabriz

2- Materials and methods

2-1- Case study

In this research, two watersheds, Ajichay and Sufichay, studied. The Ajichay river in northwest of Iran is one of the most important river discharging into Lake Urmia. Ajichay watershed has an area of about 11,457 square kilometers and covers 22% of the total area of Lake Urmia. The Sufichay river originates from the southern slopes of the Sahand mountain, located 30 kilometers south of Tabriz. The Sufichay river basin area is approximately 1,800 square kilometers and the length of this river is 70 kilometers. This river is the major source of water for both irrigation and domestic uses for the community residing in this region.

2-2- Artificial Neural Network

Neural networks are computational models that are capable of discovering the relationship between the inputs and outputs of a physical system. ANN based on a collection of nodes called neurons connected by weighted links. By analyzing measured data, these networks discover hidden patterns and rules among them and transfer them to the network structure (Bagherzadeh, 2019).

In this study, the Levenberg–Marquardt (LM) algorithm was applied to train the ANN models using feed-forward back-propagation training algorithms.

2-3- Noise reduction

In this research, two methods, chaos theory and wavelet, are used to separate the noise from the input data. According to the research, these methods are suitable for estimating, reducing, or eliminating the amount of noise. The accuracy of these methods is mainly verified by the prediction accuracy.

2-3-1- Chaos Theory

Chaos theory was first applied in meteorology by Edward Lorenz in 1965 and then developed to other sciences (Kocak et al, 2000). Error in measurement and input data adds noise to predictions (Lokem Gelman, 2017). Noise reduction is the process of removing noise from a time series data.

The purpose of noise reduction in chaotic deterministic dynamic systems is to replace erroneous measurements with the best value that has less error. In this method, the chaotic of the time series is first investigated. If the data is chaotic, after estimating the correlation dimension, noise reduction is done with the chaos theory. For this purpose, the GHKSS chaotic method, which was developed by Grassberger and is a nonlinear method, has been used.

2-3-1- Wavelet Transform

Mathematical transforms are used to obtain additional information from a signal that is not available from the signal itself. Mathematical transformations are used to obtain additional information from a signal that is not available from the signal itself. Among them, the most famous is the Fourier transform.

The Fourier transform provides information about the frequencies in a signal, but does not provide any information about when a particular frequency occurs. Therefore, the wavelet transform was developed and extended to solve some of the shortcomings of the Fourier transform.

Wavelet Transform is known a powerful mathematical tool designed in the field of signal processing. In wavelet analysis, like in Fourier analysis, we deal with the expansion of functions, but this expansion is done in terms of "wavelets". A wavelet function is a function that has two important properties: oscillatory and short-term. $\Psi(x)$ is a wavelet function if its Fourier transform $\Psi(\omega)$, satisfies the following condition:

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

This condition is known as the $\Psi(x)$ wavelet acceptance condition.

In this study, the wavelet toolbox of Matlab software has been used to analyze the wavelet signal.

2-4- Combinations of input data

Runoff time series usually have a Markovian behavior, meaning that the values of the parameters at present time are most probably to depend on the conditions of the series at past times (Yahyavi, 2013). Considering this characteristic, the inputs determined for modeling river flow, was selected a combination of flows in past times. The output of the model, in all input combinations, is Q_t .

Comb 1: Q_{t-1}

Comb 2: Q_{t-1}, Q_{t-2}

Comb 3: $Q_{t-1}, Q_{t-2}, Q_{t-3}$

Comb 4: $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$

Comb 5: $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$

Comb 6: Q_{t-12}

In this simulations, Q_t, Q_{t-1}, Q_{t-2} and ... are representing the discharge in present month and previous one, two and ... months ago respectively.

2-5- Model Evaluation Criteria

In this study has employed most common statistical techniques to evaluate model performance with ANN and effect of Noise reduction with chaos theory and wavelet. These include the Correlation coefficient (R), the Nash-Sutcliffe coefficient (NSE), the root mean square error (RMSE) and normalized RMSE.

3- Results and Discussion

In the chaos theory, first the delay time was calculated to Average mutual information method (AMI) and using the program mutual.exe from the TISEAN software package. the delay time of were obtained for the Sufichay and Ajichay rivers as three and five months respectively. After determining the delay time, the correlation dimension was calculated. The correlation dimension method is the most well-known method for determining chaos.

$\log C(R)/\log(R)$ versus $\log(R)$ diagram and Correlation dimension diagram for different embedding dimensions shows that the correlation dimension for the Sufichay and Ajichay rivers is estimated to be two and three, respectively. Finally, the GHKSS method was used to reduce noise.

In the wavelet method, first the selection of the best wavelet parameters has been done by means of a trial and error process. To remove noise using wavelet transform, three mother wavelets were used at two different decomposition levels, and after analyzing the original time series using the wavelet tool in MATLAB, the threshold values were calculated and the denoised time series was created.

The threshold value is a very important parameter in the wavelet threshold denoising algorithm. Results show that db4 wavelet and 3 level are the optimum mother wavelet and decomposition level for the denoised monthly discharge time series data.

To compare the results obtained from neural network modeling with raw and denoised data, first, by modeling the neural network with raw data, an appropriate input combination was selected. Then, the denoised data in the selected input combination was used for modeling with the neural network. The results of modeling with raw data showed that the neural network performed well in simulating the runoff of the Sufichay River in combinations number five, four and three, and with a small difference, combination number five (Comb 5) was selected. The same procedure was repeated for the Ajichay River, and the neural network performed relatively better with combination number six than the other combinations. Also, considering that combination four has a very close performance to combination number six, both combinations were examined for modeling with denoised data for this basin.

The RMSE value in modeling with raw data and noise reduction with chaos and wavelet for the Sufichay River is 0.08, 0.045, and 0.034, respectively, and the correlation coefficient is 0.85, 0.97, and 0.98, respectively, and the Nash-Sutcliffe efficiency coefficients is 0.71, 0.95, and 0.96. Therefore, it can be said that the wavelet method with the db4 mother wavelet at the resolution level of two, with a slight difference compared to the chaos theory in the noise reduction process, has improved the accuracy of the neural network results.

Considering that in the selection of the appropriate combination for simulating the monthly discharge of the Ajichay River using an artificial neural network, the two combinations (Comb 4) and (Comb 6) had close results, therefore, modeling of the noise-reduced data with an artificial neural network was performed using these two combinations.

The results showed that the best performance of the ANN model with noise-reduced data is when the data is denoised using Wavelet and the choices of the mother wavelet function are "db4" from Daubechies and also the decomposition level for the signal is two.

However, unlike the results of the Sufichay River, noise reduction using the chaos method for the Ajichay data with input combination six (Comb 6) did not improve the performance of the neural network, but in combination four for the same river, the results are almost the same as those of the Sufichay River, and the accuracy of the modeling results with noise reduction data in combination four is higher than in combination six. Finally, it can be said that noise reduction using the chaos method in combination four (Comb 4) had the best performance (Table 1).

Table (1): ANN results with raw and noise reduced data using chaos and wavelet

River & Combination	Data Type & Noise reduction method		Structure of ANN	Train			Test			Total		
				RMSE	R ²	E	RMSE	R ²	E	E	R ²	RMSE
Sufichay Comb5	Raw Data		5-8-1	0.0766	0.8494	0.7201	0.0886	0.8369	0.6993	0.0798	0.8457	0.7147
	Chaos		4-13-1	0.0452	0.9738	0.9480	0.0443	0.9734	0.9468	0.0449	0.9736	0.9478
	Level 2	db4	4-7-1	0.0332	0.9797	0.9594	0.0367	0.9769	0.9526	0.0341	0.9788	0.9576
Ajichay Comb4	Raw Data		4-6-1	0.1165	0.7556	0.5708	0.15	0.7262	0.486	0.1258	0.7390	0.5445
	Chaos		4-16-1	0.0611	0.9391	0.8811	0.0563	0.9423	0.8846	0.0598	0.9396	0.8824
	Level 2	db4	4-4-1	0.0708	0.9148	0.8288	0.0968	0.8829	0.7791	0.078	0.9051	0.8148
Ajichay Comb6	Raw Data		1-4-1	0.1089	0.7829	0.6125	0.121	0.78	0.6044	0.112	0.7818	0.6103
	Chaos		1-13-1	0.1315	0.6922	0.478	0.1004	0.7132	0.5007	0.1245	0.6958	0.4835
	Level 2	db4	1-16-1	0.0956	0.8497	0.7194	0.0825	0.8495	0.7187	0.0925	0.8489	0.7194

4- Conclusions

By comparing the values of the Nash-Sutcliffe efficiency obtained for the validation data, it can be concluded that the use of denoised data in modeling significantly increases the accuracy of the model results. So that at the Sufichay station, the use of denoised data using the wavelet method in modeling with an artificial neural network has increased the accuracy of the results by about 25 percent and the Nash-Sutcliffe value has increased from 0.6993 to 0.9526. In the Ajichay basin, the accuracy of the results has also increased from 0.486 to 0.8846 by using denoised data using the chaos method. The results of this study were similar to the results obtained by other researchers such as Partovyan et al. (2016), Karunasingha and Liong (2018), Boustani et al. (2019), Malekani (2020), Zerouali et al. (2021), Guo et al. (2023), Wang (2024).

Based on the results obtained, it is suggested that other newer models be used for modeling with raw data and reducing the noise. In this case, a better comparison can be made between the effect of the type of model and data in increasing the accuracy of the results. It is also suggested that this research be done with other hydrological parameters such as precipitation, sedimentation, evaporation and the efficiency of this method and the increase in the accuracy of the results be evaluated.



کاهش نویز از سری‌های زمانی دبی ماهانه با استفاده از موجک و نظریه آشوب



لیلا ملکانی^{۱*}، رضا سیدی^۲، محمدتقی اعلمی^۳

۱- استادیار گروه مهندسی عمران-آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران. lmalekani@yahoo.com
 ۲- استاد گروه مهندسی عمران-آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران. rezavadig2@gmail.com
 ۳- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی مرن، دانشگاه تبریز، تبریز، ایران. mtaalami@tabrizu.ac.ir

کلیدواژه‌ها

دبی ماهانه، کاهش نویز، موجک، نظریه آشوب، شبکه عصبی مصنوعی، صوفی‌چای، آجی‌چای.

چکیده

لازمه مدیریت بهینه منابع آبی اطلاع از میزان جریان در رودخانه و پیش‌بینی آن می‌باشد. افزایش دقت نتایج پیش‌بینی، هدف بسیاری از محققان است. وجود نویز در داده‌های هیدرولوژیکی می‌تواند منجر به کاهش دقت پیش‌بینی گردد بنابراین در تحقیقات اخیر در کنار توجه به توسعه و ارائه مدل با قابلیت‌های محاسباتی بالاتر، به بررسی داده‌های مورد استفاده نیز اهمیت داده می‌شود. هدف از این تحقیق بررسی تأثیر کاهش نویز (NR) داده‌های ورودی بر میزان دقت مدل‌ها می‌باشد. جهت مطالعه دو رودخانه‌ی آجی‌چای و صوفی‌چای انتخاب و نویز جریان رودخانه با دو روش نظریه آشوب و موجک کاهش گردید. سپس پیش‌بینی دبی ماهانه‌ی آنها با مدل ANN در سه حالت استفاده از داده‌های خام، NR یافته با آشوب و موجک انجام شده است. برای بررسی نتایج، RMSE، ضریب همبستگی و نش-ساتکلیف در این سه حالت مدل‌سازی محاسبه و به ترتیب ذکر می‌گردد. در رودخانه صوفی‌چای RMSE با داده‌های خام و NR یافته با آشوب و موجک $0/078$ ، $0/045$ و $0/034$ ، مقدار R^2 ، $0/846$ ، $0/974$ و $0/979$ و همچنین نش-ساتکلیف $0/715$ ، $0/948$ و $0/958$ می‌باشد. در رودخانه آجی‌چای RMSE در این سه حالت به ترتیب $0/126$ ، $0/06$ و $0/078$ ، مقادیر R^2 $0/74$ ، $0/94$ و $0/91$ و نش-ساتکلیف $0/545$ ، $0/882$ و $0/815$ بدست آمد. می‌توان گفت به کارگیری داده‌های NR یافته در مدل‌سازی جریان رودخانه موجب افزایش دقت پیش‌بینی می‌شود. همچنین مقایسه نتایج بین دو روش NR نشان می‌دهد که در رودخانه آجی‌چای روش آشوب و در صوفی‌چای موجک عملکرد بهتری دارد و نمی‌توان به صورت قطعی یکی از این روش‌ها را به عنوان روش بهتر جهت NR معرفی نمود.

تاریخ دریافت: ۱۴۰۳/۱۲/۰۱

تاریخ پذیرش: ۱۴۰۴/۰۵/۲۵

تاریخ انتشار: ۱۴۰۴/۰۷/۰۰

ارجاع به این مقاله: ملکانی، لیلا؛ سیدی، رضا؛ اعلمی، محمدتقی؛ (۱۴۰۴). کاهش نویز از سری‌های

زمانی دبی ماهانه با استفاده از موجک و نظریه آشوب. هیدروژنومورفولوژی، ۱۲(۴): ۹۵-۱۱۵.

*نویسنده مسئول: لیلا ملکانی

رایانامه: lmalekani@tabrizu.ac.ir

شناسه دیجیتال مقاله: 10.22034/hyd.2025.65928.1778



Copyright: © 2025 by the authors

Publisher: University of Tabriz

۱- مقدمه

آب یکی از فراوان‌ترین ترکیباتی است که در طبیعت وجود دارد و حدود سه چهارم سطح زمین را اشغال کرده است، اما توزیع ناهمگون منابع آب از لحاظ جغرافیایی موجب کمبود آب در برخی نقاط دنیا شده است. بیش از ۹۷ درصد آب‌های جهان در اقیانوس‌ها و دریاها قرار دارند و تقریباً دو درصد آن نیز در یخچال‌ها و منابع قطبی و همچنین به صورت رطوبت در خاک و اتمسفر زمین قرار دارد. بدین ترتیب انسان برای ادامه حیات و توسعه فقط به ۰/۶۲ درصد آب روی کره زمین دسترسی دارد. کشور ایران نیز در منطقه خشک و نیمه‌خشک واقع شده و در حال حاضر با مشکلات کم‌آبی مواجه است و تدوین برنامه‌های مدیریتی برای رودخانه‌ها امری اجتناب‌ناپذیر به نظر می‌رسد. اطلاع از وضعیت آب‌های سطحی، این امکان را به ما می‌دهد که ضمن استفاده از آنها در مصارف مختلف، راهکارهایی اتخاذ شود که کمترین آسیب را به این منابع برساند. بدین منظور محققان سعی در ارائه روش‌ها و مدل‌هایی داشتند که بتواند جریان رودخانه‌ها را به خوبی پیش‌بینی نماید. با توسعه هوش مصنوعی استفاده از قابلیت‌های آن در زمینه پیش‌بینی منجر به ارائه مدل‌های مختلف شده است. محققان سعی دارند تا دقت پیش‌بینی‌ها را بهبود دهند و برای این منظور علاوه بر توسعه مدل‌ها، اخیراً اهمیت زیادی به بررسی داده‌ها و کمی‌سازی و حذف نویزهای آنها می‌شود (زروالی^۱ و همکاران، ۲۰۲۱).

از جمله مطالعاتی مهم انجام شده می‌توان به موارد زیر اشاره نمود:

وانگ^۲ و همکاران (۲۰۲۴) مدل ترکیبی WD-AM-LSTM را برای پیش‌بینی جریان ده روزه رودخانه منتهی به مخزن ارائه نمودند. نتایج مدل‌سازی‌های مختلف آنها نشان داد که در صورت استفاده از روش موجک جهت نویزگیری^۳ دقت نتایج نسبت به حالتی که فرایند WD انجام نمی‌گیرد افزایش قابل توجهی دارد.

گو^۴ و همکاران (۲۰۲۳) جریان رودخانه Yellow در چین را با مدل ترکیبی CEEMDAN-LSSVM-GM مدل‌سازی نمودند. حرف N در این مدل اشاره به کاهش نویز دارد. نتایج این تحقیق نشان داد که به منظور افزایش دقت پیش‌بینی رواناب توسط سری‌های زمانی لازم است پیش‌پردازش داده‌ها انجام گیرد. فرایند پیش‌بینی را می‌توان با کاهش نویز یا تجزیه داده‌ها ساده نموده و ویژگی‌های غیرخطی و غیرهموار در سری هیدرولوژیکی را پیش از پیش‌بینی تجزیه و تحلیل کرد، که می‌تواند کارایی پیش‌بینی بعدی را به طور موثر بهبود بخشد.

منگ^۵ و همکاران (۲۰۲۳) عملکرد روش موجک در حذف نویز داده‌های جریان ماهانه رودخانه فوچون را مطالعه کردند و به این نتیجه دست یافتند که روش موجک توانایی بالایی در حذف نویز داده‌های جریان ماهانه رودخانه دارد.

بهرامی و اصیل (۲۰۲۳) عملکرد روش نظریه آشوب را در حذف نویز سری زمانی با مدل ANN بررسی نمودند و نشان دادند که با بکارگیری کاهش نویز، نتایج نهایی، کاهش حدود ۳۳ درصدی مقدار خطای مطلق میانگین را در مقایسه با حالت استفاده از داده خام نشان می‌دهند. همچنین عملکرد نظریه آشوب را بهتر از روش تجزیه و تحلیل طیف منفرد استنباط نموده‌اند.

زروالی و همکاران (۲۰۲۱) نیز یک مدل ترکیبی (ITTA-DWT) برای مدل‌سازی داده‌های بارش ارائه نمودند که در بخشی از این مدل نویز داده‌ها با به کارگیری روش موجک (DWT) شناسایی و گرفته می‌شود. نتایج این پژوهش نشان داد که با حذف نویز در داده‌های آب و هواشناسی دقت نتایج مدل‌ها بهتر می‌گردد.

دانشور و صمدزاده (۲۰۲۱) تحقیقی با هدف بررسی تاثیر فرایندهای پیش‌پردازش در نتایج مدل‌سازی رواناب دشت اردبیل انجام دادند. نتایج نشان داد که اعمال روش‌های پردازش زمانی رفع نویز موجکی و استفاده از تبدیل موجک در مدل‌سازی بارش-رواناب با شبکه عصبی مصنوعی به ترتیب به طور متوسط باعث بهبود ۴ و ۳۹ درصدی در مرحله آزمایش مدل شده است.

ملکانی (۲۰۲۰) با استفاده از تئوری آشوب، نویز مقادیر جریان رودخانه در سه حوضه ليقوان، نهند و اهرچای را کاهش داده و سپس با استفاده از شبکه عصبی با دو سری داده خام و کاهش نویز یافته مدل‌سازی انجام گرفت. نتایج تحقیق نشان داد که استفاده از داده‌هایی که نویز آنها کاهش یافته است دقت نتایج مدل‌سازی را به میزان قابل توجهی افزایش می‌دهد.

1 Zerouali
2 Wang

3 Wavelet Denoising
4 Gue

5 Meng

بوستانی و همکاران (۲۰۱۹) در تحقیقی که بر روی داده‌های دبی ماهانه رودخانه زرينه‌رود انجام دادند به این نتیجه رسیدند که پس از کاهش نويز با استفاده از نظريه آشوب، پیش‌بینی غیرخطی سری زمانی دقیق‌تر خواهد بود.

کاروناسینگا و لیونگ^۱ (۲۰۱۸) از روش کاهش نويز فیلتر کالمن برای پیش‌بینی سری زمانی جریان دو رودخانه در سیلیوونگ^۲ اندونزی استفاده کردند. آنها نشان دادند که استفاده از فرایند کاهش نويز بسته به مقدار نويز، دقت نتایج را تا ۱۵ الی ۴۰ درصد بهبود می‌بخشد. آنها با توجه به افزایش چشمگیر دقت نتایج، ارائه و توسعه روش‌های مختلف کاهش نويز را مهم دانستند.

پرتویان و همکاران (۲۰۱۸) از روش ANN و ANFIS برای شبیه‌سازی جریان ایستگاه پل آنیان که بر روی رودخانه‌ی زرينه‌رود قرار دارد استفاده کردند و نويز داده‌ها قبل از استفاده در مدل‌ها با استفاده از روش تبدیل موجک کاهش یافت. نتیجه‌گیری تحقیق نشان داد که استفاده از داده‌هایی که نويز آنها کاهش یافته، مقدار ضریب همبستگی را در مدل‌های ANN و ANFIS به ترتیب ۲۳ و ۱۴ درصد افزایش می‌دهد.

چنانچه اشاره شد بدلیل وجود نويز در اغلب داده‌های سری زمانی، اعمال فرایند کاهش نويز در داده‌ها می‌تواند منجر به بهبود نتایج مدل‌های پیش‌بینی آنها گردد. منظور از کاهش نويز، جداسازی داده‌های سری زمانی به دو جزء سیگنال اصلی و تصادفی (نويز) است (رضایی و جباری، ۱۳۹۶). ابزار مرسوم و کلاسیک آماری برای تمایز این دو جزء تبدیل فوری و تبدیل موجک می‌باشد که به‌عنوان تبدیل‌های خطی شناخته شده‌اند (دوایی و نظرآهاری^۳، ۲۰۱۵). عیب این روش‌ها این است که سیگنال‌های بسیاری ناحیه طیفی یکسان را به‌عنوان فضای نويز پوشش می‌دهند که باعث حذف بخشی از سیگنال اصلی می‌شود و لازم است تکنیک‌های فیلتر توسعه و بهبود داده شود (شورایبر و کانتز^۴، ۱۹۹۸). از این‌رو در این مطالعه از دو روش تبدیل موجک و نظریه آشوب جهت کاهش نويز داده‌های سری زمانی رواناب ماهانه رودخانه‌های آجی‌چای و صوفی‌چای که از مهمترین زیرحوضه‌های دریاچه ارومیه هستند استفاده شد. سپس جهت بررسی تاثیر کاهش نويز در دقت نتایج پیش‌بینی دبی ماهانه رودخانه با شبکه عصبی مصنوعی، مدلسازی در حالت‌های مختلف (با داده‌های قبل و بعد از کاهش نويز) بکار گرفته شد. طبق بررسی‌ها بهره‌گیری از دو روش متفاوت کاهش نويز و مقایسه عملکرد آنها در مطالعات دیگر انجام نگرفته است. ارزیابی نتایج مدلسازی‌های در حالت‌های مختلف انجام گرفته بر اساس معیارهای ارزیابی مرسوم RMSE، NRMSE، ضریب همبستگی و ضریب نش ساتکلیف انجام شده است.

۲- مواد و روش

۲-۱- معرفی منطقه و حوضه‌های مورد مطالعه


در این تحقیق دو حوضه آبریز آجی‌چای و صوفی‌چای، برای بررسی انتخاب شده است. حوضه آجی‌چای در شمال غرب ایران از مهم‌ترین زیرحوضه‌های دریاچه ارومیه است و به‌لحاظ موقعیت جغرافیایی بین عرض‌های جغرافیایی ۳۷°۴۲' تا ۳۸°۳۰' شمالی و طول‌های جغرافیایی ۴۵°۴۰' تا ۴۷°۵۳' شرقی واقع شده است. این حوضه با ۱۱۴۵۷ کیلومتر مربع مساحت، حدود ۲۲ درصد از کل مساحت حوضه آبخیز دریاچه ارومیه را دربر می‌گیرد و ۱۰ درصد از کل حجم جریان ورودی به دریاچه ارومیه را شامل می‌باشد. شیب متوسط این حوضه آبخیز ۸/۷۲ درصد برآورد شده است. طول شاخه اصلی آن تا محل پخش ۲۵۰ کیلومتر می‌باشد و جهت جریان آن عمدتاً از شرق به غرب می‌باشد (کاظم‌زاده و همکاران، ۲۰۱۷).

حوضه صوفی‌چای در موقعیت جغرافیایی ۳۷°۲۷' شمالی و ۴۶°۱۶' شرقی قرار دارد که از دامنه‌های جنوبی ارتفاعات سهند واقع در ۳۰ کیلومتری جنوب تبریز و از مجاورت سرچشمه مردق‌چای سرچشمه می‌گیرد. مساحت این حوضه در بالادست دریاچه ارومیه تقریباً ۱۸۰۰ کیلومتر مربع است و طول این رودخانه ۷۰ کیلومتر و دارای حداقل ارتفاع ۱۹۰۰ متر و حداکثر ارتفاع ۳۴۰۰ متر است و شیب متوسط آن ۷/۵ درصد می‌باشد (باقرزاده، ۲۰۱۹). شکل زیر موقعیت این دو حوضه را در استان آذربایجان شرقی نشان می‌دهد.

1 Karunasingha and Liong
2 Ciliwung

3 Davaie and Nazarahari

4 Schreiber and Kantz




شکل (۱): موقعیت حوضه‌های مورد مطالعه

Figure (1): The study area

۲-۲- شبکه عصبی مصنوعی

شبکه‌های عصبی مدل‌های محاسباتی هستند که قادر به کشف رابطه بین ورودی‌ها و خروجی‌های یک سیستم فیزیکی هستند که متشکل از شبکه‌ای از گره‌های به هم متصل می‌باشند. این شبکه‌ها با تحلیل داده‌های اندازه‌گیری شده و به عبارتی داده‌های تجربی، الگوها و قوانین پنهان موجود در بین آن‌ها را به ساختار شبکه منتقل می‌کنند به همین علت آن‌ها را سیستم‌های هوشمند می‌نامند. یک شبکه عصبی مصنوعی از سه نوع لایه تشکیل شده است: لایه ورودی، لایه پنهان و لایه خروجی. لایه‌های ورودی داده‌ها را در شبکه توزیع کرده و لایه پنهان این داده‌ها را پردازش می‌کند. در نهایت لایه خروجی نیز نتایج را استخراج می‌کند. یک شبکه عصبی ممکن است بیش از یک لایه پنهان داشته باشد. هر یک از لایه‌های قید شده دارای تعدادی نرون هستند و نرون‌های لایه‌های مختلف با هم در ارتباط بوده و داده‌ها را پردازش می‌کنند. شکل (۲) ساختار کامل یک شبکه عصبی مصنوعی را نشان می‌دهد.



شکل (۲): ساختار کلی یک شبکه عصبی مصنوعی

Figure (2): General structure of an artificial neural network

در اینجا دسته‌ای از ورودی‌ها که به صورت $(x_1, x_2, \dots, x_n)$ و در این تحقیق $(Q_{t-1}, Q_{t-2}, \dots, Q_{t-n})$ است، به سلول عصبی اعمال می‌شوند. این ورودی‌ها که جمعاً به عنوان یک بردار در نظر گرفته می‌شوند مشابه علایمی هستند که به سیناپس‌های سلول عصبی

بیولوژیکی فرستاده می‌شوند. هر سیگنال قبل از اینکه به واحد جمع که با علامت Σ نشان داده شده است اعمال شود، در یک وزن مربوط به خود $(w_{1j}, w_{2j}, \dots, w_{nj})$ ضرب می‌گردد که هر وزن مشابه با قدرت یک اتصال سیناپس بیولوژیکی منفرد است. همچنین هر نرون برای محاسبه خروجی خود، دارای یک تابع محرک است که به مجموع وزن‌دار ورودی‌هایش اعمال می‌شود. در این مطالعه از شبکه عصبی پیش‌خور از نوع شبکه‌های پس انتشار با الگوریتم آموزشی لوببرگ-مارکوارت (LM) استفاده شده است.

۲-۳- کاهش نویز

در این تحقیق برای جداسازی نویز داده‌های ورودی از دو روش نظریه آشوب و موجک استفاده می‌شود. مطابق تحقیقات انجام شده این روش‌ها برای تخمین، کاهش یا حذف میزان خطاها روش مناسبی هستند و دقت آنها عمدتاً به وسیله دقت پیش‌بینی به عنوان ابزار اصلی تشخیص، صحت‌سنجی می‌شود.

۲-۳-۱- نظریه آشوب

در چند دهه اخیر، تحولی عظیم در شیوه درک و بیان پدیده‌های طبیعی توسط محققین صورت گرفته است. نظریه آشوب به مطالعه سیستم‌هایی می‌پردازد که در نگاه اول به نظر می‌رسد رفتار تصادفی داشته باشند، اما در واقع همین سیستم تحت حاکمیت قوانین مشخصی است و یا به عبارتی در هر بی‌نظمی، نظم نهفته است. نظریه آشوب اولین بار در سال ۱۹۶۵ توسط دانشمندی بنام ادوارد لورنز در هواشناسی به کار برده شد و سپس در حیطه تمام علوم و مباحث تجربی، ریاضی، رفتاری، مدیریتی و اجتماعی وارد شده و اساس تغییرات بنیادی در علوم بویژه هواشناسی، نجوم، مکانیک، فیزیک، ریاضی، زیست‌شناسی، اقتصاد و مدیریت را فراهم آورده است (کوجاک و همکاران^۱، ۲۰۰۰).

در این روش، در واقع فرض می‌شود که داده‌های سری زمانی نظیر جریان رودخانه (S_n) از دو بخش متفاوت مقدار اصلی (X_n) و تصادفی (η_n) تشکیل شده‌اند $(S_n = X_n + \eta_n)$. هدف از کاهش نویز، جداسازی داده‌های سری زمانی به این دو جزء است به نحوی که یک جزء شامل سیگنال اصلی بوده و بخش دیگر حاوی جزء تصادفی باشد و انجام آن باعث کاهش خطای پیش‌بینی می‌شود (رضایی و جباری، ۲۰۱۷). هدف از کاهش خطا در سیستم‌های دینامیک قطعی آشوبی جایگزینی اندازه‌گیری‌های خطادار با بهترین مقداری است که خطای کمتری دارد. برای انتخاب روش مناسب برای کاهش خطا لازم است آشوبناکی سری زمانی‌های بررسی گردد. گام نخست در انجام تحلیل‌های آشوبی، بازسازی فضای حالت سپس تعیین بعد همبستگی می‌باشد. در صورت آشوب‌پذیری داده‌ها و پس از تخمین بعد همبستگی، کاهش نویز با نظریه آشوب انجام می‌شود. بدین منظور از روش آشوبی GHKSS که بوسیله گراسبرگر توسعه داده شده و یک روش غیرخطی می‌باشد و همچنین از روش موجک استفاده شده است.

۲-۳-۲- تبدیل موجک

تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال می‌باشد. تبدیل‌های ریاضی برای به دست آوردن اطلاعات اضافی از سیگنال که از خود سیگنال قابل دستیابی نیستند، استفاده می‌شوند. برای پردازش سیگنال، شمار زیادی از تبدیلات ریاضی مورد استفاده قرار گرفته‌اند، که در میان آنها تبدیل فوریه مشهورترین به شمار می‌آید (یحییوی رحیمی، ۲۰۱۳). تبدیل فوریه اطلاعات مربوط به فرکانس‌های موجود در یک سیگنال را ارائه می‌کند، در حالی که از زمان رخ دادن یک فرکانس خاص هیچ اطلاعی به دست نمی‌دهد. اگر سیگنال از نوع ایستا باشد، به این اطلاعات نیازی نیست. اما در مواردی که سیگنال غیرایستا می‌باشد، آگاهی داشتن از زمان رخ دادن یک فرکانس خاص، اهمیت می‌یابد، به همین دلیل تبدیل موجک به منظور رفع بعضی از کاستی‌های تبدیل فوریه بوجود آمد و بسط داده شده است. در آنالیز موجک هم مانند آنالیز فوریه با بسط تابع‌ها سر و کار داریم ولی این بسط بر حسب «موجک‌ها»

¹¹ Kocak et al.

انجام می‌شود. موجک تابع مشخص مفروضی با میانگین صفر است و برخلاف چندجمله‌ای‌های مثلثاتی، موجک‌ها در فضا به صورت موضعی بررسی می‌شوند و به این ترتیب ارتباط نزدیک‌تری بین بعضی توابع و ضرایب آن‌ها امکان‌پذیر می‌شود و پایداری عددی بیشتری در بازسازی و محاسبات فراهم می‌گردد. هر کاربردی را که مبتنی بر تبدیل سریع فوریه است می‌توان با استفاده از موجک‌ها فرمول‌بندی کرد و اطلاعات فضایی (یا زمانی) موضعی بیشتری به دست آورد. به طور کلی، این موضوع بر پردازش سیگنال، تصویر و الگوریتم‌های عددی سریع برای محاسبه‌ی عملگرهای انتگرالی اثر می‌گذارد (گراسمن و مورلت^۱، ۱۹۸۴).

تابع موجک، تابعی است که دو ویژگی مهم را دارا باشد: نوسانی و کوتاه مدت بودن. $\psi(x)$ تابع موجک است اگر و فقط اگر تبدیل فوریه آن $\Psi(\omega)$ ، شرط زیر را فراهم نماید:

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

این شرط با عنوان شرط پذیرفتگی موجک $\psi(x)$ شناخته می‌شود. رابطه فوق را می‌توان معادل با فرمول زیر دانست که باید برقرار شود:

$$\psi(0) = \int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (2)$$

این ویژگی تابع با میانگین صفر، چندان محدود کننده نبوده و توابع بسیاری را می‌توان براساس آن تابع موجک نامید. $\psi(x)$ تابع موجک مادر است که توابع مورد استفاده در تحلیل با دو عمل ریاضی انتقال و مقیاس کردن، در طول سیگنال مورد تحلیل، تغییر اندازه و محل می‌یابند و در نهایت ضرایب موجک در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با رابطه زیر قابل محاسبه است:

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (3)$$

یکی از اصلی‌ترین توانایی‌های موجک، قابلیت آن در تجزیه یک سری اصلی زمانی به چندین زیرسری زمانی است. هر کدام از زیر سری‌های زمانی ویژگی خاصی دارند (نماینده فرکانس یا دوره تناوب فصلی خاصی هستند). از آنجایی که در کارهای هیدرولوژیکی اغلب با سری‌های زمانی گسسته سر و کار داریم، برای تجزیه سری زمانی اغلب از فرم گسسته تبدیل موجک استفاده می‌شود که به اختصار DWT^2 نامیده می‌شود. در DWT پارامترهای انتقال و مقیاس به صورت غیرپیوسته و با بهره‌گیری از روند دودویی انتخاب می‌شوند، به نحوی که:

$$a = 2m, \quad b = 2mn \quad (4)$$

که m و n اعداد صحیح هستند. در نتیجه با جایگذاری به جای a و b در رابطه (۳) خواهیم داشت:

$$\psi_{m,n}(x) = 2^{-m/2} \psi(2^{-m}x - n) \quad (5)$$

برای سری زمانی گسسته x_i ، تبدیل دودویی موجک به صورت زیر بیان می‌شود:

$$T_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} \psi(2^{-m}i - n) x_i \quad (6)$$

که در این رابطه N طول سری زمانی و $T_{m,n}$ ضریب موجک برای a و b منتخب است و معکوس آن به شکل زیر محاسبه می‌شود:

$$x_i = \bar{T}(t) + \sum_{m=1}^M \sum_{n=0}^{2^{M-m}-1} T_{m,n} 2^{-m/2} g(2^{-m}i - n) \quad (7)$$

که در آن M طوری انتخاب شده که داشته باشیم، $N = 2M$. رابطه فوق به شکل زیر خلاصه می‌گردد:

$$x_i = \bar{T}(t) + \sum_{m=1}^M W_m(t) \quad (8)$$

در رابطه اخیر $\bar{T}$ زیرسری زمانی تخمین (که دوره تناوب فصلی غالب سری زمانی اصلی را دارد) از مرتبه M داشته و W_m ها زیرسری های زمانی جزئی از مراتب $m = 1, 2, \dots, M$ هستند. در این تحقیق از دو سطح تجزیه مختلف (رند به بالا و رند به پایین) استفاده شده و با توجه به تعداد داده های سری زمانی این تحقیق سطوح تجزیه ۲ و ۳ مورد مطالعه قرار گرفته شده است.

۴-۲- ترکیب های ورودی مدل

سری های زمانی رواناب معمولاً عملکردی مارکوفی دارند، یعنی مقادیر پارامترها در زمان حال به احتمال زیاد وابسته به شرایط سری در زمان های گذشته هستند (یحیوی رحیمی، ۲۰۱۳). لذا ورودی های تعیین شده برای مدل سازی جریان رودخانه با در نظر گرفتن ویژگی پدیده های مارکوفی، ترکیبی از جریان در زمان های گذشته می باشد. به منظور ارائه مدلی با دقت قابل قبول برای مدل سازی دبی رودخانه شش ترکیب ورودی مختلف شامل دبی در زمان های گذشته تعریف شد.

Comb 1: Q_{t-1}

Comb 2: Q_{t-1}, Q_{t-2}

Comb 3: $Q_{t-1}, Q_{t-2}, Q_{t-3}$

Comb 4: $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$

Comb 5: $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$

Comb 6: Q_{t-12}

خروجی مدل، در تمامی ترکیب های ورودی، Q_t ، دبی ماهانه در زمان حال و Q_{t-1} دبی ماه قبل می باشد و منظور از $Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$ و Q_{t-12} به ترتیب دبی دو، سه، چهار، پنج ماه و دوازده ماه قبل می باشد.

۵-۲- ارزیابی مدل ها

در این پژوهش در انتخاب بهترین ساختار مدل شبکه عصبی و نیز جهت بررسی عملکرد روش های کاهش نویز از معیارهای رایج ارزیابی چون ضریب همبستگی، نش-ساتکلیف و جذر میانگین مربعات خطا و و نرمال شده آن استفاده شد.

$$R^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (11)$$


$$NRMSE = \frac{RMSE}{x_{max} - x_{min}} \quad (12)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی رواناب، N تعداد گام های زمانی، $\bar{x}$ و $\bar{y}$ نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می باشند. x_{min} و x_{max} حداکثر و حداقل مقدار اعداد بکار رفته می باشد. علاوه بر معیارهای فوق جهت مشاهده و تحلیل بیشتر نتایج از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی نیز استفاده شده است.

۳- یافته ها و بحث

نمودار و ویژگی های توصیفی و نمودار داده های سری های زمانی مورد استفاده در شکل (۳) و جدول (۱) نشان داده شده است. پارامترهای آماری دبی ماهانه در جدول با واحد مترمکعب بر ثانیه می باشد. از این داده ها ۷۵ درصد برای آموزش و ۲۵ درصد باقی مانده به منظور

تست و صحت‌سنجی به کار رفتند.



شکل (۳): نمودار سری زمانی داده‌های خام: الف) رودخانه صوفی‌چای ب) آجی‌چای
Figure (3): Time series graph of raw data: a) Sufichay river b) Ajichay river


جدول (۱): خصوصیات آماری داده‌های دبی ماهانه مورد استفاده

Table (1): Statistical characteristics of the monthly streamflow data used in study

نام رودخانه	نام ایستگاه	دوره آماری	تعداد داده‌ها	حداقل	حداکثر	میانگین	انحراف معیار	چولگی
صوفی‌چای	تازه‌کند	۱۳۵۴ - ۱۴۰۰	۴۸۰	۰/۳۰	۳۰/۹۷۸	۳/۵۷	۴/۵۶	۲/۳۹
آجی‌چای	مرکید	۱۳۷۴ - ۱۴۰۰	۳۱۲	۰	۵۰/۲۸۷	۵/۱۹	۹/۳۳	۲/۷۲

۳-۱- بررسی روش کاهش نویز با استفاده از نظریه آشوب و تبدیل موجک


ابتدا زمان تاخیر با استفاده از برنامه کامپیوتری mutual.exe از بسته نرم‌افزاری TISEAN محاسبه شد و نتایج آن برای رودخانه‌های صوفی‌چای و آجی‌چای به ترتیب سه و پنج ماه بدست آمد. سپس با توجه به زمان تاخیر بدست آمده، بعد همبستگی محاسبه گردید، بعد همبستگی شناخته‌شده‌ترین روش تعیین آشوبناکی می‌باشد. به منظور بررسی آشوب‌پذیری و تخمین بعد همبستگی مناسب می‌توان از نمودار $\log C(r)/\log(r)$ در مقابل تغییرات $\log(r)$ استفاده نمود. شکل (۴)، نمودار تغییرات نسبت $\log C(r)/\log(r)$ در مقابل $\log(r)$ را نشان می‌دهد که بعد همبستگی برای رودخانه‌های صوفی‌چای و آجی‌چای به ترتیب دو و سه تخمین زده شده است. به دلیل وجود نویز در داده‌ها به ازای مقادیر کوچک $\log(r)$ نوساناتی در نمودار مشاهده می‌شود. سپس از روش GHKSS که یک روش غیرخطی می‌باشد برای کاهش نویز استفاده شد.



شکل (۴): نمودار تغییرات $\text{LogC}(r)/\text{Log}(r)$ در مقابل $\text{Log}(r)$ و نمودار تغییرات بعدهمبستگی با افزایش بعدمحاط

Figure (4): $\log C(r)/\log(r)$ versus $\log(r)$ diagram and the graph of changes in correlation dimension with the increase of the embedding dimension

برای رفع نویز به وسیله تبدیل موجک از سه موجک مادر در دو سطح تجزیه مختلف دو و سه استفاده شد و پس از تجزیه و تحلیل سری زمانی اصلی توسط جعبه ابزار موجک متلب، مقادیر آستانه کلی محاسبه شده و سری زمانی کاهش نویز یافته ایجاد شد. از روش آستانه موجک به طور گسترده‌ای برای کاهش نویز و بهبود دقت پردازش سیگنال استفاده می‌شود (شیائو و همکاران، ۲۰۲۲). نتایج بررسی این بخش نشان داد که سطح تجزیه دو و موجک مادر db4 در کاهش نویز از سری زمانی ماهانه، شباهت بیشتری نسبت به سایر موجک‌های مادر بررسی شده در این پژوهش دارد. شکل (۵) نمودار سری زمانی کاهش نویز یافته با موجک مادری که بیشترین شباهت را به سری زمانی اصلی دارد.



شکل (۵): نمودار سری زمانی داده‌های خام و داده‌های کاهش نویز یافته بوسیله موجک: (الف) رودخانه صوفی‌چای (ب) آجی‌چای

Figure (5): Time series graph of raw data and NRW data: a) Sufichay river b) Ajichay river

۳-۲- مدل‌سازی شبکه عصبی با داده‌های خام و کاهش نویز یافته

جهت مقایسه نتایج بدست آمده از مدل‌سازی شبکه عصبی با داده‌های خام و کاهش نویز یافته، ابتدا با مدل‌سازی شبکه عصبی با داده‌های خام، ترکیب ورودی مناسب انتخاب شده و با استفاده از ترکیب ورودی منتخب، برای داده‌های کاهش نویز یافته، مدل‌سازی توسط شبکه عصبی انجام شده است. در این تحقیق برای شبکه عصبی، سه لایه ورودی، میانی و خروجی در نظر گرفته شده است که تعداد نرون لایه اول بنا به ترکیب ورودی از یک تا پنج متغیر است و تعداد نرون لایه خروجی برابر یک در نظر گرفته شده که همان دبی در زمان حال می‌باشد و تعداد نرون مناسب برای لایه میانی از بین تعداد نرون یک تا ۲۰، هرکدام که نتایج بهتری داشت انتخاب شده است. سپس مدل‌سازی ANN با شش ترکیب ورودی مختلف انجام شد و نتایج مدل‌سازی جریان رودخانه صوفی‌چای در جدول (۲) ارائه شده است.

جدول (۲): نتایج شبکه عصبی در مدل‌سازی جریان رودخانه‌های صوفی‌چای و آجی‌چای با داده‌های خام

Table (2): Neural network results in modelling the runoff of Sufichay and Ajichay rivers with raw data

نام حوضه	ترکیب ورودی	آموزش			صحت‌سنجی			کل داده‌ها			ساختمان ANN
		NSE	R2	RMSE	NSE	R2	RMSE	NSE	R2	RMSE	
شمال غربی	Comb1	۰/۷۲۵۵	۰/۹۹۷	۰/۵۲۶۲	۰/۱۲۵۰	۰/۶۳۵۳	۰/۴۰۲۱	۰/۱۰۶۶	۰/۷۰۰۵	۰/۴۹۰۷	۱-۸-۱
	Comb2	۰/۷۹۱۴	۰/۹۰۱	۰/۶۱۳۵	۰/۱۰۱۶	۰/۷۸۸۶	۰/۶۰۴۸	۰/۰۹۳۰	۰/۷۹۰۰	۰/۶۱۲۱	۱-۸-۲
	Comb3	۰/۸۳۸۱	۰/۷۹۱	۰/۷۰۱۷	۰/۰۹۱۱	۰/۸۳۱۴	۰/۶۸۲۵	۰/۰۸۲۲	۰/۸۳۵۰	۰/۶۹۶۹	۱-۶-۳
	Comb4	۰/۸۴۷۵	۰/۷۶۹	۰/۷۱۸۲	۰/۰۸۹۱	۰/۸۳۸۵	۰/۶۹۶۰	۰/۰۸۰۱	۰/۸۴۴۷	۰/۷۱۲۷	۱-۵-۴
	Comb5	۰/۸۴۹۴	۰/۷۶۶	۰/۷۲۰۱	۰/۰۸۸۶	۰/۸۳۶۹	۰/۶۹۹۳	۰/۰۷۹۸	۰/۸۴۵۷	۰/۷۱۴۷	۱-۸-۵
	Comb6	۰/۸۱۱۷	۰/۰۸۹۹	۰/۶۵۶۶	۰/۰۸۹۰	۰/۷۵۹۳	۰/۵۷۶۶	۰/۰۸۹۷	۰/۸۰۰۹	۰/۶۴۰۱	۱-۶-۱
شمال شرقی	Comb1	۰/۷۴۸۳	۰/۱۱۸۱	۰/۵۵۹۲	۰/۱۵۱۹	۰/۷۱۶۸	۰/۴۷۲۸	۰/۱۲۷۴	۰/۷۳۰۲	۰/۵۳۲۴	۱-۱۰-۱
	Comb2	۰/۷۴۰۵	۰/۱۱۹۶	۰/۵۴۸۰	۰/۱۵۹۱	۰/۶۵۴۶	۰/۴۲۱۳	۰/۱۳۰۶	۰/۷۱۳۸	۰/۵۰۸۴	۱-۳-۲
	Comb3	۰/۷۴۸۳	۰/۱۱۸۱	۰/۵۵۹۲	۰/۱۵۱۹	۰/۷۱۶۸	۰/۴۷۲۸	۰/۱۲۷۴	۰/۷۳۰۲	۰/۵۳۲۴	۱-۱۰-۳
	Comb4	۰/۷۵۵۶	۰/۱۱۶۵	۰/۵۷۰۸	۰/۱۵۰۰	۰/۷۲۶۲	۰/۴۸۶۰	۰/۱۲۵۸	۰/۷۳۹۰	۰/۵۴۴۵	۱-۶-۴
	Comb5	۰/۷۳۷۴	۰/۱۲۰۹	۰/۵۳۸۰	۰/۱۵۰۹	۰/۷۲۵۴	۰/۴۷۹۷	۰/۱۲۹۰	۰/۷۲۸۵	۰/۵۲۰۶	۱-۷-۵
	Comb6	۰/۷۸۲۹	۰/۱۰۸۹	۰/۶۱۲۵	۰/۱۲۱۰	۰/۷۸۰۰	۰/۶۰۴۴	۰/۱۱۲۰	۰/۷۸۱۸	۰/۶۱۰۳	۱-۴-۱

با توجه به نتایج جدول (۲) می‌توان بیان نمود که شبکه عصبی در شبیه‌سازی رواناب رودخانه صوفی‌چای در ترکیب‌های شماره پنج، چهار و سه عملکرد مناسبی داشته است و با اختلاف کم ترکیب شماره پنج (Comb5) انتخاب می‌گردد. برای رودخانه آجی‌چای نیز با ترکیبات مذکور، مشاهده شد که شبکه عصبی با ترکیب شماره شش عملکرد نسبتاً بهتری نسبت به سایر ترکیبات داشته است، همچنین با توجه به این که ترکیب چهار عملکرد بسیار نزدیکی به ترکیب شماره شش دارد، هر دو ترکیب جهت مدل‌سازی با داده‌های کاهش نویز یافته برای این حوضه بررسی می‌شود.

۳-۳- مقایسه نتایج داده‌های خام و کاهش نویز یافته در مدل‌سازی با شبکه عصبی

در این قسمت با استفاده از ترکیب مناسبی که از قسمت قبل برای شبیه‌سازی داده‌های خام رودخانه‌های مورد مطالعه به‌دست آمده، مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته، انجام شد و نتایج زیر بدست آمده است.

براساس جدول (۳) مقدار RMSE در مدل‌سازی با داده‌های خام و کاهش نویز یافته با آشوب و موجک برای رودخانه صوفی‌چای به ترتیب ۰/۰۸ و ۰/۰۴۵ و ۰/۰۳۴ و مقدار ضریب همبستگی نیز به ترتیب برابر ۰/۸۵ و ۰/۹۷ و ۰/۹۸ و همچنین مقدار معیار کارایی نش-ساتکلیف به ترتیب برابر ۰/۷۱ و ۰/۹۵ و ۰/۹۶ می‌باشد بنابراین می‌توان گفت که، تاثیر کاهش نویز در نتایج مدل‌سازی شبکه عصبی قابل ملاحظه می‌باشد و برای رودخانه صوفی‌چای روش موجک با موجک مادر db4 در سطح تفکیک دو با اختلاف جزئی نسبت به نظریه آشوب در فرآیند کاهش نویز موجب بهبود دقت نتایج شبکه عصبی شده است.

جدول (۳): نتایج شبکه عصبی با داده‌های خام و کاهش نویز یافته در رودخانه صوفی چای (Comb 5)


Table (3): Neural network results with raw and noise- reduced data in the Sufichay (Comb5)

کل داده‌ها			صحت‌سنجی			آموزش			ساختار ANN	نوع داده‌ها و روش کاهش نویز
NSE	R^2	RMSE	NSE	R^2	RMSE	NSE	R^2	RMSE		
۰/۷۱۴۷	۰/۸۴۵۷	۰/۰۷۹۸	۰/۶۹۹۳	۰/۸۳۶۹	۰/۰۸۸۶	۰/۷۲۰۱	۰/۸۴۹۴	۰/۰۷۶۶	۱-۸-۵	خام
۰/۹۴۷۸	۰/۹۷۳۶	۰/۰۴۴۹	۰/۹۴۶۸	۰/۹۷۳۴	۰/۰۴۴۳	۰/۹۴۸۰	۰/۹۷۳۸	۰/۰۴۵۲	۱-۱۳-۴	NRC*
۰/۶۷۱۹	۰/۸۲۰۵	۰/۰۷۸۸	۰/۶۳۵۲	۰/۷۹۸۷	۰/۰۸۹۸	۰/۶۸۵۶	۰/۸۲۸۷	۰/۰۷۴۸	۱-۸-۴	Haar
۰/۸۴۹۰	۰/۹۲۲۳	۰/۰۵۵۳	۰/۸۳۱۳	۰/۹۲۶۵	۰/۰۶۷۰	۰/۸۵۷۷	۰/۹۲۶۲	۰/۰۵۰۸	۱-۴-۴	db2
۰/۹۵۷۶	۰/۹۷۸۸	۰/۰۳۴۱	۰/۹۵۲۶	۰/۹۷۶۹	۰/۰۳۶۷	۰/۹۵۹۴	۰/۹۷۹۷	۰/۰۳۳۲	۱-۷-۴	db4
۰/۶۳۳۷	۰/۷۹۸۳	۰/۰۷۸۸	۰/۵۸۱۳	۰/۷۶۸۲	۰/۰۷۳۹	۰/۶۴۵۹	۰/۸۰۶۹	۰/۰۸۰۳	۱-۱۳-۴	Haar
۰/۷۳۳۵	۰/۸۵۷۲	۰/۰۶۴۳	۰/۷۳۴۷	۰/۸۷۱۵	۰/۰۵۹۶	۰/۷۳۳۰	۰/۸۵۶۵	۰/۰۶۵۸	۱-۷-۴	db2
۰/۸۳۲۵	۰/۹۱۳۹	۰/۰۵۶۷	۰/۸۰۳۳	۰/۹۰۲۱	۰/۰۵۸۵	۰/۸۳۹۴	۰/۹۱۷۳	۰/۰۵۶۱	۱-۷-۴	db4

* NRC: Noise- reduced data with the chaos theory (داده کاهش نویز یافته با نظریه آشوب)


** NRW: Noise- reduced data with the wavelet transform (داده کاهش نویز یافته با نظریه آشوب)

شکل (۶) نحوه پراکنش داده‌ها در اطراف مدل برازش شده را در ترکیب پنجم نشان می‌دهد. با توجه به میزان R^2 و شکل نمودارها، داده‌های کاهش نویز یافته به روش موجک برای رودخانه صوفی چای، بهترین برازش را داشته‌اند.



شکل (۶): نمودارهای پراکنش مدل‌سازی شبکه عصبی با داده‌های خام و کاهش نویز یافته در رودخانه صوفی چای (Comb 5)
Figure (6): Scatter plots of neural network modelling with raw and noise reduced data in the Sufichay (Comb 5)

شکل (۷) نمودار سری زمانی مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته به روش موجک در رودخانه صوفی چای را نشان می‌دهد.



شکل (۷): نمودارهای سری زمانی مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته به روش موجک در رودخانه صوفی چای
Figure (7): Time series of ANN modelling with noise-reduced data by wavelet method in the Sufichay


با توجه به این که در قسمت انتخاب ترکیب مناسب برای شبیه‌سازی شبکه‌عصبی برای رودخانه آجی‌چای که با داده‌های خام انجام شده بود دو ترکیب (Comb 4) و (Comb 6) نتایج نزدیک به هم داشتند با استفاده از این دو ترکیب، مدل‌سازی داده‌های کاهش نویز یافته با شبکه‌عصبی، صورت گرفت و نتایج آن‌ها به صورت جداگانه در جداول (۴) و (۵) ارائه شده است.

جدول (۴): نتایج شبیه‌سازی شبکه‌عصبی با ورودی‌های خام و کاهش نویز یافته آجی‌چای (Comb 4)

Table (4): Neural network results with raw and noise reduced data in the Ajichay (Comb4)

کل داده‌ها			صحت‌سنجی			آموزش			ساختار ANN	نوع داده‌ها و روش کاهش نویز
NSE	R^2	RMSE	NSE	R^2	RMSE	NSE	R^2	RMSE		
۰/۵۴۴۵	۰/۷۳۹۰	۰/۱۲۵۸	۰/۴۸۶۰	۰/۷۲۶۲	۰/۱۵۰۰	۰/۵۷۰۸	۰/۷۵۵۶	۰/۱۱۶۵	۱-۶-۴	خام
۰/۸۸۲۴	۰/۹۳۹۶	۰/۰۵۹۸	۰/۸۸۴۶	۰/۹۴۲۳	۰/۰۵۶۳	۰/۸۸۱۱	۰/۹۳۹۱	۰/۰۶۱۱	۱-۱۶-۴	NRC
۰/۶۳۹۹	۰/۸۰۳۹	۰/۱۱۲۲	۰/۵۷۶۶	۰/۷۶۰۸	۰/۱۳۲۳	۰/۶۶۵۲	۰/۸۲۱۱	۰/۱۰۴۹	۱-۹-۴	Haar
۰/۶۸۷۴	۰/۸۲۹۵	۰/۰۹۸۲	۰/۶۶۴۷	۰/۸۲۱۷	۰/۱۱۸۰	۰/۶۹۵۰	۰/۸۳۳۹	۰/۰۹۰۷	۱-۳-۴	db2
۰/۸۱۴۸	۰/۹۰۵۱	۰/۰۷۸۰	۰/۷۷۹۱	۰/۸۸۲۹	۰/۰۹۶۸	۰/۸۲۸۸	۰/۹۱۴۸	۰/۰۷۰۸	۱-۴-۴	db4
۰/۴۷۳۵	۰/۶۹۰۳	۰/۱۳۰۹	۰/۴۲۹۲	۰/۶۵۷۹	۰/۱۳۶۷	۰/۴۸۸۱	۰/۷۰۰۷	۰/۱۲۸۹	۱-۷-۴	Haar
۰/۵۲۶۳	۰/۷۲۶۱	۰/۱۱۴۵	۰/۵۲۰۹	۰/۷۲۲۳	۰/۱۰۶۸	۰/۵۲۷۶	۰/۷۲۷۴	۰/۱۱۶۹	۱-۵-۴	db2
۰/۶۳۲۴	۰/۷۹۵۴	۰/۱۰۱۸	۰/۶۱۱۹	۰/۷۸۳۲	۰/۱۰۳۷	۰/۶۳۸۸	۰/۷۹۹۳	۰/۱۰۱۲	۱-۴-۴	db4


بر اساس جدول (۴) مقدار RMSE در مدل‌سازی با داده‌های خام و کاهش نویز یافته با آشوب و موجک به ترتیب ۰/۱۲۶ و ۰/۰۶ و ۰/۰۷۸ و مقدار ضریب همبستگی نیز برابر ۰/۷۴ و ۰/۹۴ و ۰/۹ و همچنین مقدار نش به ترتیب برابر ۰/۵۴ و ۰/۸۸ و ۰/۸۱ می‌باشد بنابراین می‌توان گفت هر دو روش کاهش نویز تاثیر نسبتاً بالایی در دقت مدل‌سازی رودخانه آجی‌چای داشته است و از بین این دو روش، کاهش نویز بوسیله آشوب با اختلاف کمی دقت مدل را در رودخانه آجی‌چای افزایش داده است و از بین موجک‌های مادر، db4 در سطح تجزیه دو، موجب عملکرد بهتر شبکه عصبی نسبت به سایر حالت‌های موجک شده است. شکل (۸) نیز نحوه پراکنش داده‌ها در اطراف مدل برازش شده را نشان می‌دهد و با توجه به میزان R^2 و شکل نمودارها، داده‌های کاهش نویز یافته به روش آشوب برای رودخانه آجی‌چای، بهترین برازش را داشته‌اند.



شکل (۸): نمودارهای پراکنش مدل‌سازی شبکه عصبی با داده‌های خام و کاهش نویز یافته در آجی‌چای (Comb 4)

Figure (8): Scatter plots of ANN modelling with raw and noise- reduced data in the Ajichay (Comb 4)

شکل (۹) نیز نمودار سری زمانی مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته به روش آشوب در ترکیب چهار برای رودخانه صوفی‌چای را نشان می‌دهد.




شکل (۹): نمودارهای سری زمانی مدل سازی شبکه عصبی با داده های کاهش نویز یافته به روش آشوب در حوضه آجی چای (Comb4)
Figure (9): Time series graphs of ANN modelling with reduced-noise data by chaos method in the Sufichay (Comb4)

جدول (۵): نتایج شبکه عصبی با ورودی های خام و کاهش نویز یافته آجی چای (Comb 6)

Table (5): ANN results with raw and noise reduced data in the Ajichay (Comb 6)

کل داده‌ها			صحت‌سنجی			آموزش			ساختار ANN	نوع داده‌ها و روش NR	
NSE	R^2	RMSE	NSE	R^2	RMSE	NSE	R^2	RMSE			
۰/۶۱۰۳	۰/۷۸۱۸	۰/۱۱۲۰	۰/۶۰۴۴	۰/۷۸۰۰	۰/۱۲۱۰	۰/۶۱۲۵	۰/۷۸۲۹	۰/۱۰۸۹	۱-۴-۱	خام	
۰/۴۸۳۵	۰/۶۹۵۸	۰/۱۲۴۵	۰/۵۰۰۷	۰/۷۱۳۲	۰/۱۰۰۴	۰/۴۷۸۰	۰/۶۹۲۲	۰/۱۳۱۵	۱-۱۳-۱	آشوب	
۰/۶۱۶۴	۰/۷۸۷۸	۰/۱۱۲۲	۰/۵۹۱۷	۰/۷۷۶۸	۰/۱۲۱۳	۰/۶۲۵۴	۰/۷۹۲۵	۰/۱۰۹۰	۱-۱۱-۱	Haar	NRW Level 2
۰/۵۲۳۹	۰/۷۲۶۶	۰/۱۱۷۲	۰/۵۳۲۲	۰/۷۵۴۸	۰/۱۱۶۲	۰/۵۲۰۹	۰/۷۲۲۴	۰/۱۱۷۶	۱-۷-۱	db2	
۰/۷۱۹۴	۰/۸۴۸۹	۰/۰۹۲۵	۰/۷۱۸۷	۰/۸۴۹۵	۰/۰۸۲۵	۰/۷۱۹۴	۰/۸۴۹۷	۰/۰۹۵۶	۱-۱۶-۱	db4	
۰/۳۵۶۰	۰/۵۹۸۴	۰/۱۴۶۲	۰/۳۴۱۱	۰/۵۸۴۶	۰/۱۷۱۷	۰/۳۶۳۶	۰/۶۰۷۶	۰/۱۳۶۶	۱-۱۴-۱	Haar	NRW Level 3
۰/۳۹۸۴	۰/۶۳۱۷	۰/۱۲۴۸	۰/۳۹۳۷	۰/۶۴۱۴	۰/۱۳۲۶	۰/۴۰۰۳	۰/۶۳۵۶	۰/۱۲۲۱	۱-۱۵-۱	db2	
۰/۲۵۲۱	۰/۵۰۲۹	۰/۱۴۸۶	۰/۲۴۴۳	۰/۵۰۴۳	۰/۱۶۹۹	۰/۲۵۴۹	۰/۵۰۴۹	۰/۱۴۰۷	۱-۹-۱	db4	

بر اساس جدول (۵) می توان گفت عملکرد شبکه عصبی با داده های کاهش نویز یافته به روش موجک با موجک مادر db4 در سطح تجزیه دو، بهبود می یابد اما برخلاف نتایج رودخانه صوفی چای، کاهش نویز به روش آشوب در ترکیب شش (Comb 6) برای داده های آجی چای موجب بهبود عملکرد شبکه عصبی نشده است ولی در ترکیب چهار برای همین رودخانه نتایج تقریباً همانند رودخانه صوفی چای می باشد. مقایسه مقادیر جدول ۵ و ۶ نیز نشان می دهد که ترکیب چهارم بویژه با داده های کاهش نویز یافته با هر دو روش بهتر عمل می نماید و دقت نتایج مدل سازی با داده های کاهش نویز در استفاده از ترکیب چهار بیشتر از ترکیب شش می باشد. در ادامه نحوه پراکنش داده ها در اطراف مدل برازش شده رسم شد و با توجه به میزان R^2 و شکل نمودارها، می توان نتیجه گرفت که داده های کاهش نویز یافته به روش موجک در ترکیب شش برای رودخانه آجی چای، بهترین برازش را داشته اند (شکل ۹).




شکل (۱۰): نمودارهای پراکنش مدل سازی شبکه عصبی با داده های خام و کاهش نویز یافته در آجی چای (Comb6)

Figure (10): Scatter plots of neural network modelling with raw and noise-reduced data in the Ajichay (Comb6)

نمودارهای شکل (۱۰) نشان می دهد که ترکیب ششم، ترکیب مناسبی برای مدل سازی دبی ماهانه رودخانه آجی چای نمی باشد و در

حالت‌های مختلف مدلسازی (داده خام، NRW و NRC) مقدار ضریب همبستگی پایین می‌باشد. در نمودار سمت راست مقادیر به محورهای افقی و بویژه قائم نزدیک است که بیانگر نتیجه مطلوب مدلسازی است. شکل (۱۰) موید نتایج جدول (۵) نیز می‌باشد و بیانگر آن است که نتایج مدلسازی با ترکیب ششم دقت کمتری داشته و بهتر است برای مدلسازی رواناب رودخانه آجی‌چای از ترکیب چهارم استفاده شود. شکل (۱۱) نیز نمودار سری زمانی مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته به روش تبدیل موجک در ترکیب شش برای رودخانه صوفی‌چای را نشان می‌دهد.



شکل (۱۱): نمودارهای سری زمانی مدل‌سازی شبکه عصبی با داده‌های کاهش نویز یافته به روش موجک در آجی‌چای

Figure (11): Time series graphs of neural network modelling with reduced-noise data by wavelet method in the Ajichay

- به‌طور خلاصه از نتایج جدول‌های (۳) تا (۵) در رودخانه‌های صوفی‌چای و آجی‌چای، می‌توان جمع‌بندی زیر را نمود:
- عملکرد شبکه عصبی با داده‌های کاهش نویز یافته بهبود می‌یابد و دقت مدل را به مقدار قابل توجهی افزایش می‌دهد به طوری که در ایستگاه صوفی‌چای استفاده از داده‌های کاهش نویز یافته به روش موجک در مدلسازی با ANN موجب شده است که مقدار نش-ساتکلیف از ۰/۶۹۹۳ به ۰/۹۵۲۶ برسد و به عبارتی دقت نتایج به میزان ۰/۲۵ (حدود ۳۶ درصد) افزایش یابد. در حوضه آجی‌چای نیز در شرایطی که از داده‌های کاهش نویز یافته به روش آشوب استفاده شد، مقدار نش-ساتکلیف از ۰/۴۸۶ به ۰/۸۸۴۶ افزایش یافته است که گویای افزایش ۸۲ درصدی میزان دقت نتایج است. این نتیجه‌گیری با نتایج بدست آمده توسط محققان دیگر چون پرتویان و همکاران (۲۰۱۸)، کاروناسینگا و لیونگ (۲۰۱۸)، بوستانی و همکاران (۲۰۱۹)، ملکانی (۲۰۲۰)، زروآلی و همکاران (۲۰۲۱)، گو و همکاران (۲۰۲۳)، بهرامی و اصیل (۲۰۲۳)، وانگ (۲۰۲۴)، عطار و همکاران (۲۰۲۴) همخوانی دارد و در تحقیقات آنها نیز دقت نتایج در حالتی که از داده‌های ورودی NR استفاده گردید افزایش داشته است.
 - هر دو روش کاهش نویز عملکرد مناسب و نزدیک به هم در افزایش دقت مدل‌سازی شبکه عصبی داشته‌اند در رودخانه صوفی‌چای به‌صورت جزئی تبدیل موجک و در رودخانه آجی‌چای نظریه آشوب عملکرد بهتری جهت کاهش نویز نشان داده است. مطالعات دیگر نیز تنها یکی از این روش‌ها را جهت NR انتخاب نموده و با نتایج داده‌های خام مقایسه نموده‌اند و قیاسی بین این دو روش انجام نشده است. بنابراین نمی‌توان نتیجه‌گیری کلی در بیان برتری عملکرد و نتایج آنها نسبت به همدیگر عنوان نمود.
 - مقایسه دو ترکیب مختلف در رودخانه آجی‌چای نشان می‌دهد که انتخاب نوع ترکیب حائز اهمیت است. در یک ترکیب نامناسب، اعمال فرایندهای پیش پردازش داده نظیر کاهش نویز موجب نتایج مطلوب نمی‌گردد و چنین اعمالی کارایی خود را در ترکیب‌های مناسب بهتر نشان می‌دهد.

۴- نتیجه‌گیری

هدف از این تحقیق بررسی تاثیر کاهش نویز داده‌های ورودی به مدل هوشمند بر میزان دقت نتایج مدلسازی است. همچنین هدف دیگر ارزیابی و مقایسه روش‌های مختلف کاهش نویز می‌باشد. بدین منظور بر روی داده‌های رواناب ماهانه دو حوضه مهم استان آذربایجان شرقی آجی‌چای و صوفی‌چای، دو روش متفاوت کاهش نویز (آشوب و موجک) اعمال گردید. دلیل این‌که از داده‌های رواناب ماهانه استفاده شد

این است که عموماً مدل‌سازی داده‌های بلندمدت مانند داده‌های ماهانه دقت پایین‌تری نسبت به مدل‌سازی با داده‌های کوتاه مدت نظیر داده‌های روزانه دارد و افزایش دقت تخمین دبی ماهانه رودخانه در مدیریت منابع آب که بعضاً بلندمدت می‌باشد مهم می‌باشد. جهت بررسی اهداف تحقیق، مدل‌سازی با سه سناریو صورت گرفت. حالت اول مدل‌سازی رواناب ماهانه حوضه با استفاده از شبکه عصبی مصنوعی و بکارگیری داده‌های خام. حالت دوم مدل‌سازی رواناب ماهانه حوضه با استفاده از شبکه عصبی مصنوعی و بکارگیری داده‌های کاهش نویز یافته توسط تئوری آشوب (NRC) و حالت سوم مدل‌سازی رواناب ماهانه حوضه با استفاده از شبکه عصبی مصنوعی و بکارگیری داده‌های کاهش نویز یافته به کمک روش موجک (NRW). همچنین جهت رسیدن به بهترین ساختار شبکه عصبی مصنوعی با استفاده از برنامه نوشته شده در محیط Matlab ساختار و ورودی‌های مختلف مورد بررسی قرار گرفت و شش ترکیب متفاوت ورودی در نظر گرفته شد. جهت ارزیابی دقت نتایج مدل‌سازی دبی ماهانه در دو رودخانه صوفی‌چای و آجی‌چای از چهار معیار رایج RMSE و NRMSE، ضریب همبستگی و NSE استفاده شده است. خلاصه این نتایج در جدول (۶) آورده شده است.

جدول (۶): مقایسه کلی مقادیر معیارهای ارزیابی برای داده‌های صحت‌سنجی

Table (6): General comparison of the Nash-Sutcliffe efficiency criterion results for validation data

NSE			ضریب همبستگی، R^2			NRSME (%)			RMSE (m^3/s)			ترکیب منتخب	حوضه
NRW	NRC	داده خام	NRW	NRC	داده خام	NRW	NRC	داده خام	NRW	NRC	داده خام		
۰/۹۵۲۶	۰/۹۴۶۸	۰/۶۹۹۳	۰/۹۷۶۹	۰/۹۷۳۴	۰/۸۳۶۹	۰/۱۶۷	۰/۲۳۴	۰/۲۸۷	۰/۰۳۶۷	۰/۰۴۴۳	۰/۰۸۸۶	Comb 5	صوفی‌چای
۰/۷۷۹۱	۰/۸۸۴۶	۰/۴۸۶	۰/۸۸۲۹	۰/۹۴۲۳	۰/۷۲۶۲	۰/۲۱۶	۰/۱۶۵	۰/۲۹۸	۰/۰۹۶۸	۰/۰۵۶۳	۰/۱۵۰۰	Comb 4	آجی‌چای

با توجه به مقادیر جدول (۶)، میزان تغییر دقت نتایج مدل‌سازی با داده‌های NR نسبت به مدل‌سازی با داده‌های خام بر حسب درصد محاسبه و در جدول (۷) ارائه شده است.

جدول (۷): میزان تغییر نتایج مدل‌سازی با داده‌های NR نسبت به مدل‌سازی با داده‌های خام

Table (7): The amount of change in modeling results with NR data compared to modeling with raw data

NSE		R^2		NRMSE		RMSE		میزان تغییر (%)	
NRW	NRC	NRW	NRC	NRW	NRC	NRW	NRC	ترکیب منتخب	حوضه
۳۶/۲۲	۳۵/۳۹	۱۶/۷۳	۱۶/۳۱	-۴۱/۸۱	-۱۸/۴۷	-۵۸/۵۸	-۵۰	Comb 5	صوفی‌چای
۶۰/۳۱	۸۲/۰۲	۲۱/۵۸	۲۹/۷۶	-۲۷/۵۲	-۴۴/۶۳	-۳۵/۴۷	-۶۲/۴۷	Comb 4	آجی‌چای

با توجه به نتایج حاصله از جدول (۷) می‌توان گفت اعمال عملیات پیش‌پردازش NR بر روی داده‌ها، موجب ارتقاء عملکرد مدل پیش‌بینی می‌گردد. با مقایسه نتایج دو روش کاهش نویز نتیجه‌گیری می‌شود که میزان کاهش خطا و افزایش دقت در مدل‌سازی دبی ماهانه رودخانه صوفی‌چای با داده‌های NRW نسبت به روش NRC بیشتر می‌باشد اما در حوضه آجی‌چای اثرگذاری داده‌های کاهش نویز یافته با آشوب (NRC) در کاهش خطا و افزایش دقت نتایج بیشتر از روش تبدیل موجک (NRW) است.

برای رسیدن به یک نتیجه‌گیری جامع، پیشنهاد می‌شود در حوضه‌های متعدد بررسی انجام گیرد. همچنین علاوه بر ANN از مدل‌های دیگر و جدیدتر جهت مدل‌سازی با داده‌های خام و کاهش نویز یافته استفاده شود. در این صورت می‌توان مقایسه بین تاثیر نوع مدل و داده بکار رفته را در افزایش دقت نتایج مورد ارزیابی قرار داد. همچنین پیشنهاد می‌گردد این تحقیق با دیگر پارامترهای هیدرولوژیکی نظیر بارش، رسوب، تبخیر نیز انجام گیرد و کارایی این روش و میزان افزایش دقت نتایج بر روی دیگر پارامترهای دیگر نیز مورد ارزیابی قرار گیرد.

References

- Attar, N.F., Sattari, M.T. & Apaydin, H. A. (2024). Novel stochastic tree model for daily streamflow prediction based on a noise suppression hybridization algorithm and efficient uncertainty quantification. *Water Resources Management*, 38, 1943–1964. <https://doi.org/10.1007/s11269-023-03688-6>.
- Bahrami A.R. & Asil Gharebaghi, S. (2023). Improved noise reduction method for chaotic time series using neural network and singular spectrum analysis, *Modares Mechanical Engineering*, 24 (1), 53-63. <https://doi.org/10.22034/MME.24.1.53>.
- Boustani, M., Farzin, S., Mousavi, S.F. & Karami, H. (2019). Effect of denoise reduction of time series on its analysis using Chaos theory (case study: Zayandehrud river), *Eco Hydrology*, 6(1), 15-27. <https://doi.org/10.22059/ije.2018.260455.906>.
- Daneshvar Vousoughi, F. and Samadzadeh, R. (2021). Predicting runoff with pre-processing approaches in Ardabil plain. *Journal of Hydrogeomorphology*, 8(26), 116-99. doi: 10.22034/hyd.2021.44060.1570.
- Davaie Markazi, A.H. & Nazarahari, M. (2015). Application of DWT for acoustic signal identification of ship using feature extraction methods and ensemble learning, *Modares Mechanical Engineering*, 15(8), 75-84. <https://doi.org/20.1001.1.10275940.1394.15.8.10.0>.
- Guo, S., Wen, Y., Zhang, X. & Chen, H. (2023). Runoff prediction of lower Yellow river based on CEEMDAN–LSSVM–GM (1, 1) model. *Scientific Reports*, 13(1), 1511. <https://doi.org/10.1038/s41598-023-28662-5>.
- Karunasingha, D.S.K. & Liong, S.Y. (2018). Enhancement of chaotic hydrological time series prediction with real-time noise reduction using Extended Kalman Filter, *Journal of Hydrology*, 565, 737-746. <https://doi.org/10.1016/j.jhydrol.2018.08.044>.
- Kazemzadeh, M., Malekian, A., Moghaddamnia, A. R. & Khalighi Sigaroudi, Sh. (2017). Shift changes and heterogeneity analysis of hydro-climate variables (a case study: Aji Chai watershed), *Eco Hydrology*, 4(1), 163-175. <https://doi.org/10.22059/ije.2017.60899>.
- Kocak K. Saylan L. & Sen O. 2000. Nonlinear Time Series Prediction of O3 Concentration in Istanbul. *Atmosphere Environment*, 34: 1267-1271. [https://doi.org/10.1016/S1352-2310\(99\)00323-4](https://doi.org/10.1016/S1352-2310(99)00323-4).
- Malekani, L. (2020). Reduced chaotic noise to improve the accuracy of estimates of monthly flow (case study: Nahandchai, Aharchai and Lighvanchai Rivers), *Journal of Irrigation and Water Engineering*, 11(1), 89-103. <https://doi.org/10.22125/iwe.2020.114955>.
- Meng, J., Wang, Y., Guo, H., & Ding, Y. (2023). Application of Wavelet Denoising Algorithm in Monthly Runoff Series of Fuchun River Hydropower Station. *International Seminar on Computer Science and Engineering Technology (SCSET)* 719-723. <https://doi.org/10.1109/SCSET58950.2023.00162>.
- Nourani, V., Andalib, G., & Sadikoglu, F. (2017). Multi-station streamflow forecasting using wavelet denoising and artificial intelligence models. *Procedia Computer Science*, 120, 617-624.
- Partovyan, A., Nourani, V. & Alami, M.T. (2018). Noise injection-denoising techniques to improve artificial intelligence-based rainfall runoff modelling, *Water Resource Engineering*, 11(36), 81-94. <https://doi.org/20.1001.1.20086377.1397.11.36.8.9>.
- Rezaei, H. & Jabbari Gharabagh, S. (2017). Noise reduction effect on Chaotic analysis of Naziuchay river flow, *Water and Soil Science*, 27(3), 239-250. <https://doi.org/10.22098/mmws.2021.9431.1043>.
- Schreiber, T. & Kantz. H. (1998). Nonlinear projective filtering II: Application to real time series, arXiv preprint chao-dyn/9805025. <https://doi.org/10.48550/arXiv.chao-dyn/9805025>.
- Wang, Y. Y., Wang, W. C., Xu, D. M., Zhao, Y. W., & Zang, H. F. (2024). A compound approach for ten-day runoff prediction by coupling wavelet denoising, attention mechanism, and LSTM based on GPU parallel

acceleration technology. *Earth Science Informatics*, 17(2), 1281-1299. <https://doi.org/10.1007/s12145-023-01212-3>.

Xiao, H., Hu, D. & Wang, J. (2022). Threshold selection of wavelet denoising based on optimization algorithms, *International Conference on Innovations and Development of Information Technologies and Robotics (IDITR)*, Chengdu, China, 2022, pp. 88-92. <https://doi.org/10.1109/IDITR54676.2022.9796485>.

Yahyavi Rahimi, A. (2013). Using the threshod method to obtain error-free input in runoff sediment modelling using the artificial neural network model method, MSc in Water Engineering, Faculty of civil Engineering, University of Tabriz.

Yang, Y., Li, W., & Liu, D. (2024). Monthly Runoff Prediction for Xijiang River via Gated Recurrent Unit, Discrete Wavelet Transform, and Variational Modal Decomposition. *Water*, 16(11), 1552. <https://doi.org/10.3390/w16111552>.

Zerouali, B., Al-Ansari, N., Chettih, M., Mohamed, M., Abda, Z., Santos, C. A. G., & Elbeltagi, A. (2021). An enhanced innovative triangular trend analysis of rainfall based on a spectral approach. *Water*, 13(5), 727. <https://doi.org/10.3390/w13050727>.

