



Estimation of seepage in earth fill dams using deep learning and wavelet transform

Aida Hosseini Baghonam *, Vahid Noorani, Elnaz Sharghi, Zahra Dadashpour

Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

Review History:

Received: Aug. 20, 2023

Revised: Aug. 19, 2024

Accepted: Sep. 14, 2024

Available Online: Oct. 03, 2024

Keywords:

Earth Fill Dam Seepage

Artificial Neural Network

Long Short-Term Memory (LSTM)

Network

Wavelet Transform

Sattarkhan Earth Fill Dam

ABSTRACT: Seepage prediction is one of the important tools in preventing erosion and destruction earth-fill dams. In recent years, due to the uncertainty, complexity, and nonlinearity of seepage relationships, the use of artificial intelligence methods for the estimation and prediction of this phenomenon has gained attention. The objective of this research is to estimate seepage in the Sattarkhan earthfill dam located in northwest Iran. To achieve this objective, in this research, the long-short-term memory network and the wavelet-deep network hybrid model have been used in two different scenarios, and the results obtained from these models have been compared with the feed-forward neural network. The results obtained indicated that deep recurrent networks, in the modeling of the seepage phenomenon, outperformed the forward neural networks in terms of estimation accuracy. This can be attributed to their recursive connection between the output and input at each time step, as well as their ability to learn dependencies from previous time sequences. The modeling accuracy was improved by up to 7% as a result. Furthermore, the combined wavelet-deep network model demonstrated superior performance compared to other models, resulting in a 10% increase in modeling accuracy. In conclusion, the utilization of deep recurrent networks and the combined wavelet-deep network model in seepage modeling holds the potential to enhance estimation accuracy when predicting this phenomenon.

1- Introduction

Given the limited water resources, dam construction has been one of the oldest civil engineering activities for water control, storage, and transfer. Earthfill dams, made from earthen materials, face challenges such as seepage, slope instability, and surface erosion. Seepage is the most critical issue, as uncontrolled seepage can lead to dam failure [1]. Therefore, an optimal model for predicting future seepage is essential. While standard feed-forward neural networks (FNN) have been used in over 90% of artificial neural network applications for modeling water resource variables [2], their forward structure limits their effectiveness in dynamic systems. Recurrent neural networks (RNNs) have emerged as deep learning tools to address this limitation [3]. These intelligent models can process complex and nonlinear data, making them suitable for hydrological time series modeling, such as seepage. RNNs and LSTM networks can accurately predict dynamic behaviors in hydrological systems by learning long-term patterns and identifying complex relationships in the data. Traditional methods often struggle with volatile and non-stationary data, but intelligent models like LSTM can overcome issues like gradient vanishing or exploding, significantly enhancing prediction accuracy. To

better understand both short-term and long-term behaviors in hydrological time series, wavelet transforms can decompose the data into several subseries. This study employs deep learning for seepage modeling and uses a hybrid wavelet-deep network model to enhance the results [4, 5].

2- Methodology

In this study, data from the piezometers of cross-section No. 2 of the Sattarkhan dam were used for modeling. The earth fill Sattarkhan dam, located 110 kilometers northeast of Tabriz on the Ahar Chai River, controls surface flows, providing drinking water for Ahar, irrigation for about 11,000 hectares, and industrial water for local industries. The piezometric data consists of 982 daily readings taken from March 2017 to the end of 2019. In the first scenario, the piezometric head was estimated using data from the piezometer itself and the reservoir water level, along with two other piezometers. In the second scenario, the water level was estimated without using previous readings from the target piezometer, relying instead on data from other correlated piezometers. Modeling began with a feed-forward neural network, which, despite its ability to approximate nonlinear functions, has limitations in dynamic system modeling due to its lack of connections

*Corresponding author's email: hosseinibaghanam@gmail.com



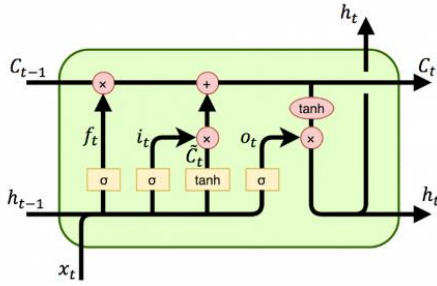


Fig. 1. LSTM Cell

from output to input. To address this, recurrent neural networks (RNNs) were employed, leveraging their recursive connections to utilize previous inputs. However, RNNs face challenges like the vanishing gradient problem, leading to the use of LSTM networks for more effective modeling. The structure of the LSTM cell is illustrated in Figure 1 and described by equations (1) to (6) [6].

$$f_t = \sigma(W_f [h_{t-1}, X_t] + b_f) \tag{1}$$

$$i_t = \sigma(W_i [h_{t-1}, X_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_c [h_{t-1}, X_t] + b_c) \tag{3}$$

$$C_t = i_t * \tilde{C}_t + f_t * C_{t-1} \tag{4}$$

$$o_t = \sigma(W_o [h_{t-1}, X_t] + b_o) \tag{5}$$

$$h_t = o_t * C_t \tag{6}$$

W_f , W_i , W_c , and W_o are learnable weight matrices, and b_f , b_i , b_c , and b_o are biases. f_t is the output of the forget gate, \tilde{C}_t is the output of the input gate, o_t is the output gate result, C_t is the cell state at time t , and h_t is the final network output. On the other hand, preprocessing input data is a critical and complex step in modeling nonlinear systems, to select an appropriate combination of inputs. In this research, wavelet transform was used for data preprocessing in the design of the recurrent-wavelet hybrid model. A key factor in using this transform is selecting the appropriate mother wavelet. The choice of the mother wavelet is crucial in wavelet-neural network hybrid models and can significantly impact the modeling results. The essence of the mother wavelet

Table 1. The DC value for Scenario 1 modeling using feedforward and recurrent neural networks.

	Network	Train Data	Test Data
Piezometer 212	FFNN	0.94	0.91
	Simple RNN	0.92	0.87
	LSTM	0.97	0.93
	WLSTM	0.98	0.96
Piezometer 218	FFNN	1.00	0.82
	Simple RNN	0.99	0.83
	LSTM	1.00	0.86
	WLSTM	0.99	0.88

lies in identifying the similarity between the analyzed time series and the wavelet sample used [7]. Since the time series studied had gradual changes, the Haar wavelet was used for data decomposition in this study. The Haar wavelet is one of the first and simplest wavelets. For training and evaluating the constructed models, the data was divided into two parts: training data and validation data. The first 70% of the dataset was used for training, while the remaining 30% was used for validation. The network was trained using the training data, and the model's output was compared with observational data to optimize the network's parameters. Finally, the trained network was evaluated using the validation data. In this study, common statistical indices such as Root Mean Square Error (RMSE), Determination Coefficient (DC), and Mean Absolute Error (MAE) were used. RMSE was selected for its precision in measuring prediction errors, DC for its ability to explain data variance, and MAE for its simplicity and robustness against outliers. These indices were used to evaluate the performance of the models employed in this research.

3- Results and Discussion

To perform the modeling, after selecting the input data, the data was first preprocessed; then, by defining the type of recurrent cell and the number of memory units, the architecture of the desired network was specified. With the definition of the loss function and optimizer algorithm, the defined network was fitted to the training data based on the number of iterations and batches determined for each iteration. To optimize the parameters, the model was evaluated using the training data. After the optimal parameters were determined, the validation data was used for prediction, and the defined models were validated using the specified evaluation criteria. For example, the DC value of the modeling performed in Scenario 1 for both piezometers is shown in Table 1.




Fig. 2. Correlation coefficient of piezometers 212 and 218 with other piezometers.

According to the results in Table 1, after selecting the optimal structure through trial and error for the WLSTM model, the DC values for piezometers 212 and 218 in Scenario 1 were obtained as 0.96 and 0.88, respectively. In Scenario 2, the correlation coefficient was used to identify the two piezometers that were influential in the modeling. The radar chart in Figure 2 illustrates the correlation coefficients of piezometers 212 and 218 with other piezometers present in the Sattarkhan dam body, where piezometer 212 shows the highest correlation with piezometers 211 and 213, while piezometer 218 has the highest correlation with piezometers 215 and 217. After determining the inputs in Scenario 2, the modeling steps were carried out similarly to Scenario 1.

In modeling Scenario 2 using the RNN network, the DC values for piezometers 212 and 218 were obtained as 0.96 and 0.71, respectively. For modeling with the LSTM network, the DC values for piezometers 212 and 218 were found to be 0.97 and 0.74, respectively. In the next step, modeling using the wavelet-deep network hybrid model estimated the piezometric heights of piezometers 212 and 218 with accuracies of 0.98 and 0.77, respectively. The modeling results indicate that recurrent networks provide higher estimation accuracy for hydrological time series, like seepage, compared to feedforward networks, making them suitable for dynamic system predictions. LSTM networks, which address the vanishing gradient problem, offer better accuracy than simple recurrent networks. While various artificial neural networks are effective for nonlinear hydraulic and hydrological modeling, their performance declines in time series with significant variations. Employing wavelet transforms as a preprocessing step improves modeling accuracy. In the second scenario of this research, piezometer water levels were estimated using data from other piezometers without relying on previous values, making this model particularly valuable in critical situations or when piezometers are out of service. This approach helps maintain prediction accuracy and reliability, especially when monitoring equipment malfunctions.

4- Conclusions

In this study, the seepage of the Sattarkhan Dam was modeled using feedforward and recurrent neural networks in two scenarios. The results showed that recurrent networks outperform feedforward networks in modeling time-dependent phenomena like seepage, increasing modeling accuracy. Wavelet transformation was applied in the preprocessing stage, leading to improved outcomes, with the combined recurrent-wavelet model achieving up to a 10% increase in accuracy compared to models without wavelet transformation. Additionally, using simultaneous data alongside target data enhanced modeling accuracy, indicating that data from highly correlated piezometers can be effectively utilized in case of piezometer failure. Modeling the piezometer closer to the upstream of the dam yielded more accurate results due to a greater correlation with upstream time series data. The study recommends similar modeling for other dam-related quantities, such as seepage. It also highlights the importance of tuning hyperparameters in deep networks and suggests using intelligent methods and algorithms for this purpose. Employing intelligent algorithms in deep learning modeling can reduce the time for hyperparameter tuning, enhance prediction accuracy, and improve overall model performance.

References

- [1] B. Nemati, H. Shafiee, Numerical modeling of seepage in earth dams using numerical methods, in: Fourth Conference on New Research in Science and Technology, 2015. (in Persian)
- [2] P. Coulibaly, C.K. Baldwin, Nonstationary hydrological time series forecasting using nonlinear dynamic methods, *Journal of Hydrology*, 307(1-4) (2005) 164-174.
- [3] S.J. Yoo, J.B. Park, Y.H. Choi, Stable predictive control of chaotic systems using self-recurrent wavelet neural network, *international journal of control, automation, and systems*, 3(1) (2005) 43-55.
- [4] V. Nourani, N. Behfar, Multi-station runoff-sediment modeling using seasonal LSTM models, *Journal of Hydrology*, 601 (2021) 126672.
- [5] M.G. Zamani, M.R. Nikoo, F. Niknazar, G. Al-Rawas, M. Al-Wardy, A.H. Gandomi, A multi-model data fusion methodology for reservoir water quality based on machine learning algorithms and bayesian maximum entropy, *Journal of Cleaner Production*, 416 (2023) 137885.
- [6] C. Olah, Understanding lstm networks–colah’s blog, Colah. github. io, (2015).
- [7] O.S. Jahromi, B.A. Francis, R.H. Kwong, Algebraic theory of optimal filterbanks, *IEEE transactions on signal processing*, 51(2) (2003) 442-457.



تخمین تراوش سدخاکی با استفاده از مدل ترکیبی یادگیری عمیق و تبدیل موجک

آیدا حسینی بقانام^{*}، وحید نورانی، الناز شرقی، زهرا داداش‌پور

دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران.

تاریخچه داوری:

دریافت: ۱۴۰۲/۰۵/۲۹

بازنگری: ۱۴۰۳/۰۵/۲۹

پذیرش: ۱۴۰۳/۰۶/۲۴

ارائه آنلاین: ۱۴۰۳/۰۷/۱۲

کلمات کلیدی:

تراوش سد خاکی

شبکه عصبی مصنوعی

شبکه حافظه بلند - کوتاهمدت (LSTM)

تبدیل موجک

سد خاکی ستارخان

خلاصه: پیش‌بینی تراوش یکی از ابزارهای مهم در پیشگیری از فرسایش و تخریب سدهای خاکی است. در سال‌های اخیر باتوجه به عدم قطعیت، پیچیدگی و غیرخطی بودن روابط حاکم بر تراوش، استفاده از روش‌های هوش مصنوعی برای تخمین و پیش‌بینی این پدیده مورد توجه قرار گرفته است. هدف از این پژوهش تخمین تراوش سدخاکی ستارخان است. این سد در شمال غربی ایران قرار دارد. برای دستیابی به این هدف، در این پژوهش از شبکه حافظه بلند - کوتاهمدت و مدل ترکیبی موجک - شبکه عمیق در دو سناریو متفاوت استفاده شده است و نتایج به‌دست‌آمده از این مدل‌ها با شبکه عصبی پیشرو مقایسه شده است. نتایج به‌دست‌آمده نشان داد که شبکه‌های بازگشتی عمیق در مدل‌سازی پدیده تراوش، به دلیل ارتباط بازگشتی خروجی با ورودی در هر گام زمانی و توانایی یادگیری وابستگی‌ها در دنباله‌ای از زمان‌های قبل، نسبت به شبکه‌های عصبی پیشرو دقت تخمین بالاتری دارند به طوری که باعث افزایش دقت مدل‌سازی تا ۷٪ شده است. هم‌چنین مدل ترکیبی موجک - شبکه عمیق نسبت به سایر مدل‌ها عملکرد بهتری دارد به طوری که دقت مدل‌سازی را تا ۱۰٪ افزایش داده است. در نهایت می‌توان نتیجه گرفت که استفاده از شبکه‌های بازگشتی عمیق و مدل ترکیبی موجک - شبکه عمیق در مدل‌سازی تراوش، توانایی بهبود دقت تخمین در پیش‌بینی این پدیده را دارند.

۱- مقدمه

مرزی و اولیه به پارامترهای محیط مانند هدایت هیدرولیکی بدنه سد خاکی، به‌عنوان ورودی نیاز می‌باشد. این پارامترها پس از اجرای پروژه دچار تغییرات می‌شوند؛ بنابراین نتیجه حاصل از مدل‌های ریاضی در مقایسه با واقعیت دارای خطای قابل توجه می‌شود [۱]. با توجه به وجود عدم قطعیت‌های بارز و پیچیدگی‌ها در مسئله تراوش، استفاده از مدل‌های جعبه سیاه که توسط ورودی‌ها و خروجی‌های مشاهده شده فرایند مورد نظر را تخمین می‌زنند، می‌تواند موجب تسهیل مدل‌سازی این پدیده باشد [۵]. تاکنون برای بسیاری از مسائل هیدرولوژی و هیدرولیک، مدل‌های جعبه سیاه مانند ابزار محاسبات نرم و هوش مصنوعی بکار گرفته شده‌اند [۶]. هوش مصنوعی به معنای استخراج هوش، دانش، الگوریتم یا نگاشت از درون محاسبات عددی بر اساس بررسی داده‌های عددی است. مروری بر تاریخچه کاربرد محاسبات نرم، نشان می‌دهد که استفاده از محاسبات نرم در تعدادی از مسائل تراوش سد خاکی منجر به نتایج مطلوبی شده است [۵]. علت انتخاب مدل‌های هوشمند در این تحقیق به دلیل توانایی آن‌ها در پردازش داده‌های پیچیده و غیرخطی، به‌ویژه در مدل‌سازی سری‌های زمانی هیدرولوژیکی مانند تراوش است.

با توجه به محدود بودن منابع آب استفاده از سدسازی در مناطق مختلف جهان برای کنترل، ذخیره و انتقال آب از کهن‌ترین فعالیت‌های مهندسی عمران به شمار می‌رود. یکی از انواع سد جهت ذخیره‌سازی آب، سد خاکی می‌باشد. این نوع سدها از مصالح خاکی ساخته می‌شوند، بنابراین بروز تراوش در سدهای خاکی امری اجتناب‌ناپذیر است [۲]. سدهای خاکی با مشکلات متعددی نظیر تراوش، ناپایداری شیب‌ها، پوسته‌پوسته شدن و... مواجه‌اند. بدترین مشکل در این‌گونه سدها مسئله تراوش و عواقب آن است. چنانچه در ابتدای بروز تراوش از این پدیده جلوگیری نگردد، منجر به خرابی سد می‌گردد [۳]. بنابراین جهت پیش‌بینی مقدار تراوش در آینده داشتن یک مدل بهینه ضروری به نظر می‌رسد. با توجه به اهمیت تراوش، از مدل‌های جعبه سیاه و سفید مختلفی برای مدل‌سازی آن استفاده شده است. به عنوان مثالی از مدل‌های جعبه سفید می‌توان به تحلیل تراوش بر اساس معادلات ریچارد [۴] اشاره کرد. در استفاده از مدل‌های جعبه سفید، علاوه بر شرایط

^{*} نویسنده عهده‌دار مکاتبات: hosseinibagham@gmail.com

مدل‌های هوشمند، مانند شبکه‌های عصبی بازگشتی و LSTM، به دلیل قابلیت یادگیری الگوهای بلندمدت و شناسایی ارتباطات پیچیده در داده‌ها، می‌توانند پیش‌بینی‌های دقیقی در مورد رفتارهای دینامیکی سیستم‌های هیدرولوژیکی ارائه دهند. در حالی که روش‌های سنتی ممکن است نتوانند به‌خوبی از عهده مدل‌سازی داده‌های پرنوسان و ناپایستا برآیند، مدل‌های هوشمند با ساختارهای خاص خود مانند LSTM می‌توانند با مشکلاتی نظیر محوشدگی یا انفجار گرادیان مقابله کرده و دقت پیش‌بینی‌ها را به طور قابل توجهی افزایش دهند. انتخاب این مدل‌ها به دلیل انعطاف‌پذیری و کارایی بالای آن‌ها در مواجهه با پیچیدگی‌های داده‌های هیدرولوژیکی و نیاز به پیش‌بینی‌های دقیق و قابل اعتماد در مدیریت منابع آبی بوده است.

تایفور و همکاران [۶] در سال ۲۰۰۵ در کنار مدل عددی FEM (Finite Element Method) از یک مدل شبکه عصبی مصنوعی برای پیش‌بینی تراوش در سد خاکی استفاده کردند. آن‌ها از تراز سطح آب در بالادست و پایین‌دست سد به‌عنوان متغیرهای ورودی استفاده کردند و تراز آب در پیژومترهای نصب شده در سد، به‌عنوان خروجی مدل شبکه عصبی مصنوعی در نظر گرفته شده بود. آن‌ها به این نتیجه رسیدند که استفاده از شبکه عصبی مصنوعی همانند روش FEM دارای دقت مناسبی می‌باشد. ارسابین [۷] با استفاده از شبکه‌های عصبی مصنوعی پدیده تراوش در سد خاکی را مدل‌سازی کرده و برای آموزش و آزمون مدل پیشنهادی از اطلاعات به دست آمده توسط کلکتورها و پیژومترها استفاده شده است. از داده‌های مربوط به تراز سطح آب در بالادست و پایین‌دست به‌عنوان ورودی‌های مدل و دبی جمع‌آوری‌شده توسط کلکتورها و فشار پیژومتری درون سد به‌عنوان خروجی مدل استفاده شده است. ارسابین پژوهش خود به این نتیجه رسیده است که شبکه عصبی دارای عملکرد مناسبی در تخمین فشار پیژومترها و تراوش سد دارد. میائو و همکاران [۸] به پیش‌بینی دبی تراوش در سد خاکی دیالی در چین با استفاده از مدل شبکه عصبی بهینه شده توسط الگوریتم فراابتکاری وراثتی پرداختند. آن‌ها از ۳۸۱ داده اندازه‌گیری شده توسط ابزار دقیق در مدل‌سازی‌های خود استفاده کردند و عملکرد مدل خود را رضایت‌بخش ارزیابی نمودند. نورانی و همکاران [۱] در سال ۲۰۱۲ یک مدل واحد جعبه سیاه با استفاده از داده‌های تراز آب بالادست و پایین‌دست سد برای آنالیز تراوش از سد خاکی ستارخان ارائه کردند و به این نتیجه رسیدند که مدل ANN (Artificial Neural Network) می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی FEM باشد. بررسی‌های اخیر نشان می‌دهد که در بیش از ۹۰٪ کاربردهای شبکه‌های عصبی

مصنوعی برای مدل‌سازی متغیرهای منابع آب، از شبکه‌های عصبی پیش‌خور استاندارد (FNN) استفاده شده است [۹]. ساختار روبه‌جلوی این شبکه‌ها، استفاده از آنها را در شناسایی و کنترل سیستم‌های دینامیکی محدود کرده است؛ بنابراین، شبکه‌های عصبی بازگشتی به‌عنوان ابزار یادگیری عمیق، جهت رفع این مشکل معرفی شدند [۱۰]. یادگیری عمیق یک شاخه پرکاربرد از یادگیری ماشین است و مجموعه‌ای از الگوریتم‌هایی است که ساختار سلسله‌مراتبی دارند و قابلیت بالایی در استخراج ویژگی از داده‌ها دارند. شبکه‌های بازگشتی عمیق در مدل‌سازی پدیده‌های وابسته به مقدار خود در زمان‌های قبل مانند تراوش، به دلیل ارتباط بازگشتی خروجی با ورودی در هرگام زمانی و توانایی یادگیری وابستگی‌ها در دنباله‌ای از زمان‌های قبل، دقت تخمین بالایی دارند [۱۱]. علت انتخاب مدل‌های هوشمند در این تحقیق به دلیل توانایی آن‌ها در پردازش داده‌های پیچیده و غیرخطی، به‌ویژه در مدل‌سازی سری‌های زمانی هیدرولوژیکی مانند تراوش است. مدل‌های هوشمند، مانند شبکه‌های عصبی بازگشتی و LSTM، به دلیل قابلیت یادگیری الگوهای بلندمدت و شناسایی ارتباطات پیچیده در داده‌ها، می‌توانند پیش‌بینی‌های دقیقی در مورد رفتارهای دینامیکی سیستم‌های هیدرولوژیکی ارائه دهند. در حالی که روش‌های سنتی ممکن است نتوانند به‌خوبی از عهده مدل‌سازی داده‌های پرنوسان و ناپایستا برآیند، مدل‌های هوشمند با ساختارهای خاص خود مانند LSTM می‌توانند با مشکلاتی نظیر محوشدگی یا انفجار گرادیان مقابله کرده و دقت پیش‌بینی‌ها را به طور قابل توجهی افزایش دهند. انتخاب این مدل‌ها به دلیل انعطاف‌پذیری و کارایی بالای آن‌ها در مواجهه با پیچیدگی‌های داده‌های هیدرولوژیکی و نیاز به پیش‌بینی‌های دقیق و قابل اعتماد در مدیریت منابع آبی بوده است. در سال‌های اخیر از مدل‌های یادگیری عمیق مانند LSTM برای مدل‌سازی پدیده‌های هیدرولوژیکی مختلفی مانند پیش‌بینی جریان [۱۲]، تخمین بار رسوب [۱۳]، پیش‌بینی سطح آب زیرزمینی [۱۴]، برآورد تبخیر و تعرق [۱۵] و ... استفاده شده است. همچنین در پژوهشی اشفقه و همکاران [۱۶]، از مدل‌های الگوریتم‌های یادگیری عمیق برای پیش‌بینی مقدار نفوذ یک سد در پاکستان استفاده کردند. هدف آنها استفاده از رویکرد RNN-LSTM برای پیش‌بینی تراوش سد با استفاده از داده‌های روزانه بود. با وجود انعطاف‌پذیری شبکه‌های عصبی در پیش‌بینی سری‌های زمانی هیدرولوژیکی، گاهی این شبکه‌ها در پیش‌بینی سری‌های زمانی به‌شدت ناپایدار و ناپایدار با مشکل مواجه می‌شوند. در این حالت استفاده از تبدیل‌های ریاضی مانند موجک با تجزیه سری زمانی به فرکانس‌های بالا و پایین، دقت مدل را تا حد

۲- مواد و روش‌ها

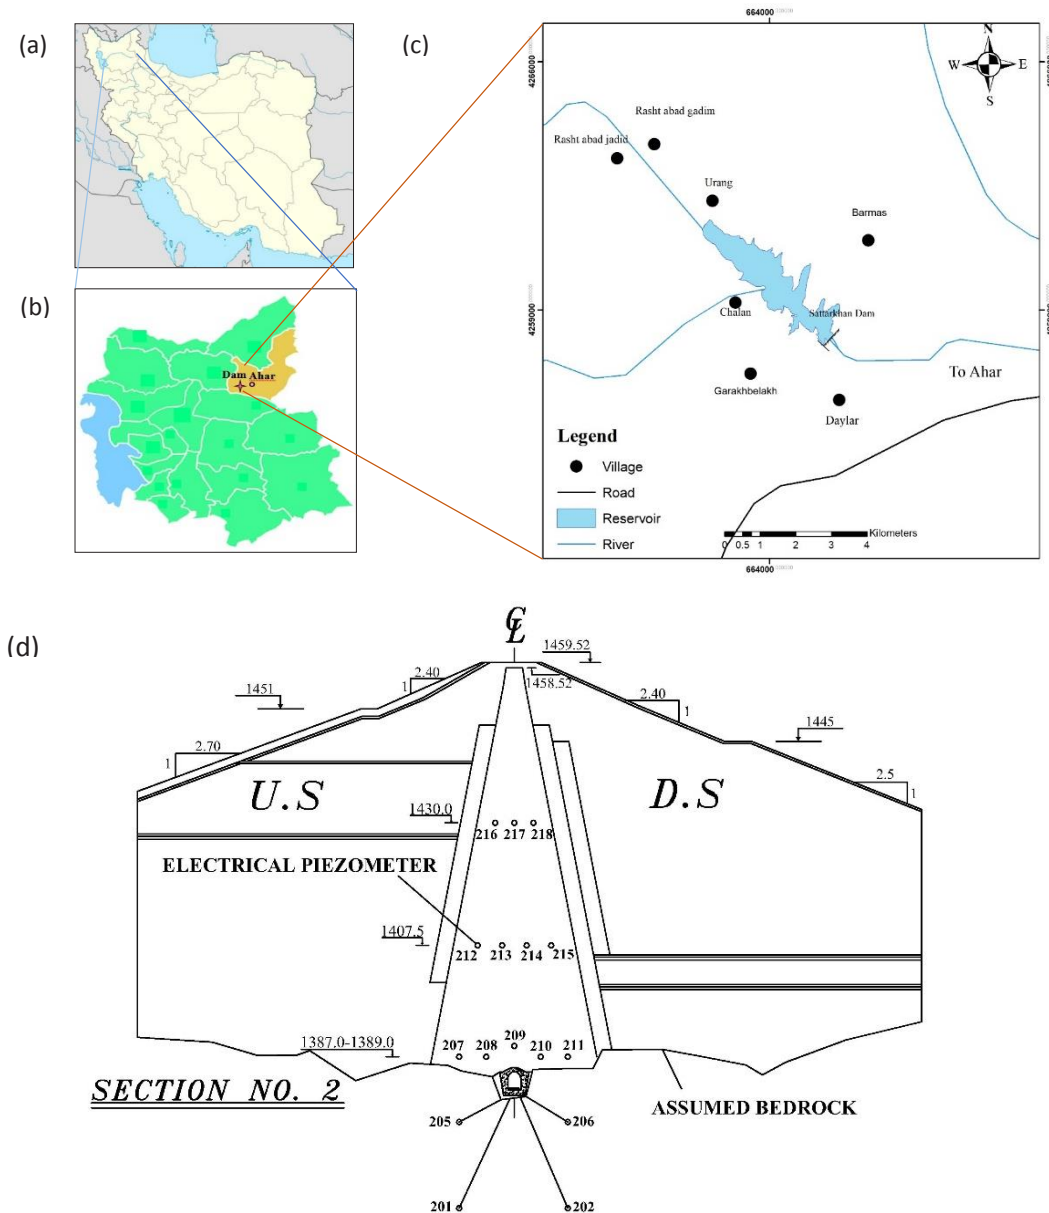
در این قسمت ابتدا به معرفی سد خاکی ستارخان، خصوصیات آماری داده‌های پیژومترهای مورد استفاده و سناریوهای تعیین شده برای انجام پژوهش پرداخته شده است. سپس ابزارهای استفاده شده معرفی شده و در آخر معیارهای ارزیابی برای صحت سنجی مدل‌ها ارائه شده است.

۲-۱- منطقه مورد مطالعه

سد خاکی ستارخان در ۱۱۰ کیلومتری شمال شرقی تبریز و در ۱۵ کیلومتری غرب شهر اهر بر روی رودخانه اهر چای احداث گردیده است. این رودخانه از جنوب شهر اهر عبور می‌کند و در ادامه مسیر خود به رودخانه ارس و در نهایت به دریای خزر می‌ریزد. با احداث این سد، جریان‌های سطحی رودخانه اهر چای کنترل شده و آب شرب شهرستان اهر، آب مورد نیاز حدود ۱۱۰۰۰ هکتار از اراضی کشاورزی پایین‌دست، آب صنعتی مس سونگون و سایر صنایع شهرستان تأمین می‌شود. شکل ۱ موقعیت سد ستارخان و مقطع شماره ۲ سد را نشان می‌دهد.

طول تاج سد ۳۴۰ متر (m)، ارتفاع سد از روی پی سنگی ۸۲ متر (m) و از روی بستر آبرفتی ۹۵ متر (m) است. مساحت حوزه آبریز رودخانه اهرچای در محل سد ۹۵۰ کیلومتر مربع (km^2) و متوسط آورد سالانه آن ۹۲ میلیون متر مکعب (Mm^3) است. عملیات اجرایی ساختمانی سد ستارخان در سال ۱۳۷۳ شروع و در سال ۱۳۸۳ به اتمام رسید. سد ستارخان، سدی از نوع خاکی است و حجم مخزن در تراز نرمال آب ۱۳۵ میلیون متر مکعب (Mm^3) و حجم مفید آن ۱۲۰ میلیون متر مکعب (Mm^3) است. طول دریاچه تشکیل شده از این سد در تراز عادی آب ۸ کیلومتر (km) و سطح این دریاچه ۲٫۷ کیلومتر مربع (km^2) است. رقوم بستر رودخانه ۱۴۰۰ متر (m)، تراز سرریز ۱۴۵۱ متر (m) و تراز تاج سد ۱۴۵۹ متر (m) از سطح دریا قرار دارد. سیستم آب‌بندی بکار رفته در این سد، پرده تزریق است که در پی و تکیه‌گاه‌های سد اجرا شده است. این پرده تزریق در پی و جناحین سد حدود ۳۲٫۰۰۰ متر مربع (m^2) گستردگی دارد که از طریق ۱۵٫۰۰۰ متر حفاری گمانه‌های به عمق تا ۸۵ متر (m) صورت می‌گیرد. در طول محور سد ۴ مقطع ابزاربندی در نظر گرفته شده است به صورتی که دو مقطع در محل ارتفاع میانگین سد بر روی تکیه‌گاه‌ها و دو مقطع در بخش میانی دره در نظر گرفته شده است [۲۴]. در این پژوهش از داده‌های پیژومترهای مقطع شماره ۲ سد ستارخان برای مدل‌سازی استفاده شده است. مقطع شماره ۲ سد و موقعیت پیژومترها در شکل ۱ قسمت d نشان داده شده‌اند. داده‌های

قابل توجهی بالا می‌برد [۱۷]. موجک یک تبدیل ریاضی است که با اعمال آن بر یک سیگنال می‌توان اطلاعات اضافه‌ای به دست آورد که در سیگنال خام اولیه قابل دسترس نمی‌باشند. امروزه ابزارهای شناخته شده بسیاری در زمینه پردازش سیگنال وجود دارند که با توجه به نوع پردازش، ابزار مناسب از میان انواع مختلف آن به کار گرفته می‌شود. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد و سری‌های زمانی نا ایستا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرارداد و با وارد کردن آن‌ها به شبکه عصبی، قدرت شبکه را در امر پیش‌بینی بالا برد [۱۸، ۱۹]. به همین دلیل در سال‌های اخیر مدل‌های ترکیبی موجک- شبکه عصبی برای پیش‌بینی فرآیندهای هیدرولوژیکی مورد استفاده قرار گرفته‌اند [۲۰]. به عنوان نمونه برای استفاده از مدل‌های ترکیبی موجک- شبکه عصبی برای مدل‌سازی تراوش می‌توان به پژوهش روشنگر و همکاران [۲۱] در سال ۲۰۱۶ اشاره کرد. در این پژوهش به پیش‌بینی دبی نشت روزانه از سد خاکی زون با استفاده از ترکیب مدل موجک و روش رگرسیون فرایند گوسی پرداختند. نتایج تحقیقات آنها نشان می‌دهد مدل ترکیبی دارای دقت مناسبی در تخمین دبی نشت در سد خاکی زنون است. در پژوهشی دیگر [۲۲]، از روش‌های نوآورانه‌ای مانند مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی برای مدل‌سازی تراوش از سد خاکی استفاده شد. نتیجه این پژوهش نشان می‌دهد که مدل ترکیبی موجک- شبکه عصبی مصنوعی می‌تواند به عنوان یک روش دقیق برای پیش‌بینی تراوش در سدهای خاکی استفاده شود و دقیق‌تر از مدل شبکه عصبی مصنوعی است. همانطور که اشاره شد تاکنون برای بررسی تراوش سد خاکی از روش‌های مختلف مبتنی بر هوش مصنوعی و یادگیری عمیق و مدل‌های ترکیبی استفاده شده است. لیکن برای بررسی تراوش سد خاکی ستارخان در مرور ادبیات فنی مطالعه‌ای مبنی بر استفاده از مدل ترکیبی یادگیری عمیق و تبدیل موجک یافت نشد. از آنجاییکه سری زمانی فرآیندهای هیدرولوژیکی بسیار پیچیده بوده بنابراین استفاده از تبدیل موجک و تجزیه سری زمانی به چند زیرسری موجب درک بهتر و درست‌تر از رفتار کوتاه و بلند مدت سری زمانی داده‌ها می‌شود. در این پژوهش برای مدل‌سازی تراوش از یادگیری عمیق استفاده شده است و از سوی دیگر جهت ارتقا نتایج مدل‌سازی استفاده از مدل ترکیبی موجک - شبکه عصبی [۱۳، ۲۳] برای مدل‌سازی تراوش سد خاکی در این پژوهش بکار گرفته شده است.



شکل ۱. (a) موقعیت آذربایجان شرقی در ایران، (b) موقعیت شهرستان اهر در آذربایجان شرقی، (c) موقعیت سد ستارخان، (d) مقطع شماره ۲ سد ستارخان.

Fig. 1. (a) Location of East Azerbaijan in Iran, (b) Location of Ahar County in East Azerbaijan, (c) Location of the Sattar Khan Dam, (d) Cross-section 2 of the Sattar Khan Dam.

t بر اساس رابطه (۱) انجام می‌گیرد.

$$p_i(t) = f(L(t).P_i(t')) \quad (1)$$

در رابطه (۱) منظور از $p_i(t)$ هد پیزومتر i در زمان t است و منظور از $L(t)$ و $P_i(t')$ به ترتیب هد پیزومتر i در زمان‌های قبل از t و تراز آب بالادست در زمان t و زمان‌های قبل از t است.

پیزومتریک مورد استفاده، داده‌های قرائت شده از اول فروردین ۹۶ تا پایان سال ۹۸ شامل ۹۸۲ داده است که به صورت روزانه قرائت شده‌اند. مشخصات آماری داده‌های پیزومترهای ۲۱۲ و ۲۱۸ در جدول ۱ ذکر شده است.

۲-۲- سناریو ۱) مدل‌سازی تک پیزومتری

در سناریو اول برای تخمین ارتفاع پیزومتریک هر پیزومتر از داده‌های خود پیزومتر و تراز آب مخزن استفاده شود. تخمین ارتفاع پیزومتر i در زمان

جدول ۱. مشخصات آماری پیزومترهای استفاده شده از مقطع ۲.

Table 1. Statistical characteristics of the piezometers used in Cross-section 2.

پیزومتر	بیشینه هد (متر)	کمینه هد (متر)	میانگین هد (متر)	انحراف معیار هد (متر)
۲۱۲	۱۳۳۰/۶۳	۱۲۸۶/۲۹	۱۲۹۵/۰۴	۲/۹۷
۲۱۸	۱۴۴۵/۰۴	۱۴۴۴/۳۰	۱۷۳۲/۷۹	۰/۲۱

۲-۳- سناریو ۲ (مدل سازی چند پیزومتری)

در این سناریو برای مدل سازی از داده های ۲ پیزومتر دیگر استفاده شده است. در سناریو ۲ ارتفاع پیزومتر I تابعی از زیرسری های ۲ پیزومتر دیگر و تراز آب بالادست است. در این روش ارتفاع هر پیزومتر از رابطه (۲) به دست می آید.

$$p_i(t) = f(L(t), P_m(t), P_n(t)) \quad (2)$$

که در رابطه (۲) P_m و P_n به ترتیب، زیرسری های پیزومترهای m ام و n ام در زمان t و زمان های قبل از t هستند. در این سناریو از ضریب همبستگی برای تعیین ۲ پیزومتر مؤثر در مدل سازی استفاده شده است. باتوجه به اینکه در سناریو ۲ برای تخمین تراز آب هر پیزومتر بدون استفاده از مقادیر مشاهده شده خود پیزومتر در زمان های قبل، از پیزومترهای دیگری که همبستگی معناداری با پیزومتر موردنظر دارند، استفاده شده است.

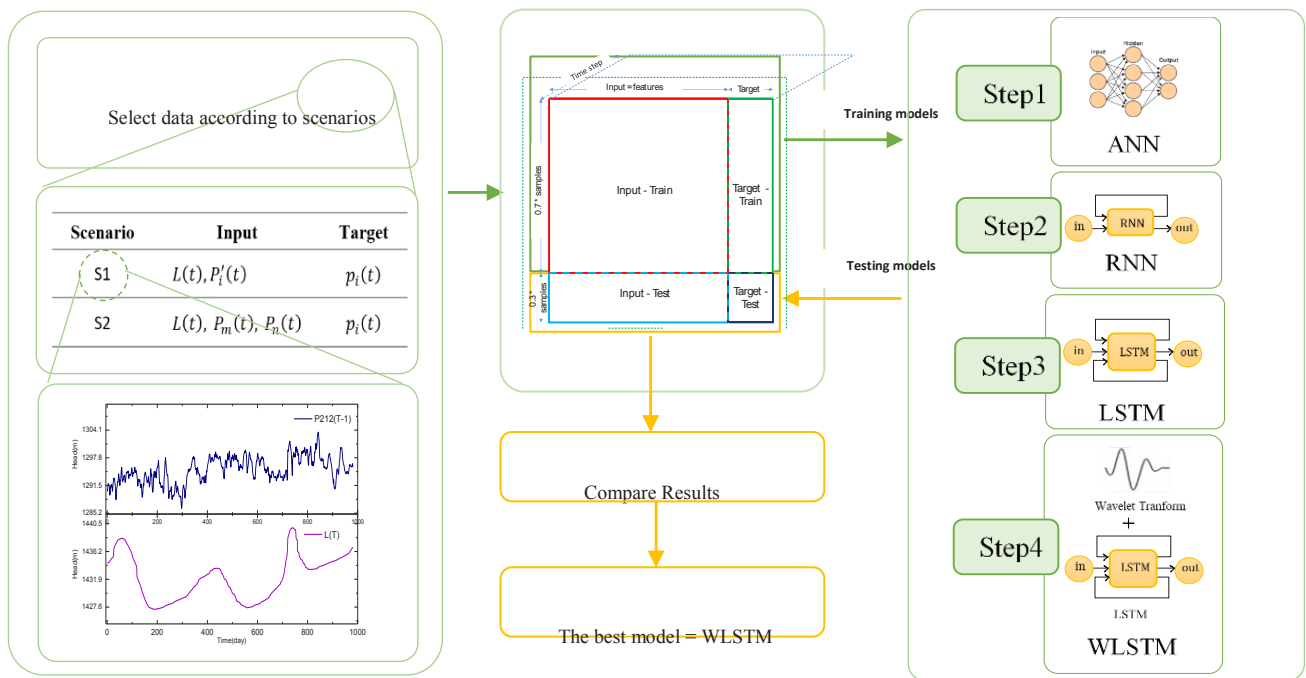
۲-۴- روش تحقیق

در این پژوهش برای مدل سازی تراوش ابتدا از شبکه عصبی پیشرو استفاده شده است این شبکه ها توسط لایه ورودی و یک لایه مخفی و در نهایت یک لایه خروجی قادر هستند هر نوع تابع غیرخطی را تقریب بزنند. در کنار این توانایی ها، شبکه های عصبی پیشرو دارای معایبی نیز هستند. ساختار روبه جلوی این شبکه ها، استفاده از آنها را در شناسایی و کنترل سیستم های دینامیکی محدود کرده است. هیچ گونه اتصال از خروجی به ورودی در شبکه های پیشرو وجود ندارد. به همین دلیل این شبکه ها برای تقریب زدن، شناسایی و یا کنترل سیستم های دینامیکی مناسب نیستند؛ بنابراین در گام بعدی از شبکه های عصبی بازگشتی برای مدل سازی استفاده شده است. نکته کلیدی شبکه های عصبی بازگشتی ارتباط بازگشتی است که حافظه ای از

ورودی های قبلی را در هر گام به شبکه اعمال می کند که می تواند بر خروجی شبکه تأثیر بگذارد. شبکه های بازگشتی دارای مشکلاتی مانند محوشدگی گرادیان هستند که در ادامه توضیح داده شده است؛ بنابراین در گام بعدی از شبکه LSTM برای مدل سازی استفاده شد. از سویی دیگر پیش پردازش داده های ورودی یک مرحله مهم و پیچیده در مدل سازی سیستم های غیرخطی، جهت انتخاب ترکیبی مناسب از آنها است. پیش پردازش داده ها سبب کاهش تعداد مراحل سعی و خطا می شود و منجر به شناخت پارامترهای مهم و مؤثر بر پدیده مورد مطالعه جهت مدل سازی با استفاده از روش های هوشمند می گردد. به طور کلی می توان گفت منظور از پیش پردازش داده ها تبدیلاتی که بر روی داده های خام صورت می گیرد و آنها را به گونه ای تجزیه می کند که برای پردازش های بعدی مؤثرتر و ساده تر شوند [۲۵]. در این تحقیق برای تعریف مدل ترکیبی شبکه بازگشتی - موجک، از تبدیل موجک در پیش پردازش داده ها استفاده شده است. در شکل ۲ مراحل مدل سازی این پژوهش ارائه شده است.

در این پژوهش به منظور آموزش و ارزیابی مدل های ساخته شده داده های مورد استفاده به دو قسمت داده های آموزش و صحت سنجی تقسیم شده است به طوری که از ۷۰٪ ابتدایی مجموعه داده ها برای آموزش و از ۳۰٪ انتهایی داده ها برای صحت سنجی مدل ها استفاده شده است. انتخاب ۷۰٪ از داده ها برای آموزش و ۳۰٪ برای صحت سنجی مدل بر اساس مطالعات و تجربیات گسترده در زمینه یادگیری ماشین و مدل سازی داده ها انجام شده است. این نسبت با توجه به پژوهش های قبلی در زمینه مدل سازی تراوش سدخاکی برای تقسیم بندی داده ها مورد استفاده قرار گرفته است [۵]، زیرا ۷۰٪ داده ها به اندازه کافی متنوع و گسترده هستند تا مدل را به خوبی آموزش دهند و ۳۰٪ باقیمانده نیز برای ارزیابی عملکرد مدل و بررسی توانایی آن در تعمیم دادن به داده های جدید مناسب است.

آموزش شبکه توسط داده های آموزش صورت گرفته و از مقایسه



شکل ۲. مراحل مدل سازی پژوهش.

Fig. 2. Stages of the research modeling.


۲-۶- شبکه‌های عصبی بازگشتی (Recurrent Neural Network - RNN)

اگر شبکه دارای ارتباط چرخشی باشد آن را شبکه عصبی بازگشتی (Recurrent Neural Network - RNN) می‌گویند. در شبکه عصبی بازگشتی مطابق شکل ۳، لایه پنهان دارای ارتباط با خودش است. شبکه‌های عصبی بازگشتی را می‌توان به صورت چند واحد تکرارشونده یکسان از یک شبکه عصبی در نظر گرفت که هر کدام اطلاعاتش را به شبکه بعدی منتقل می‌کند [۲۷]. در شکل ۳ وضعیت شبکه عصبی بازگشتی در صورت باز کردن حلقه نمایش داده شده است. این شبکه‌ها از نظر معماری، ساختاری مانند یک شبکه عمیق کوتاه دارند؛ اما رفتار زمانی شبکه‌های بازگشتی مانند یک شبکه عمیق با لایه‌های نامحدود است؛ بنابراین شبکه‌های بازگشتی از نظر زمان به طور ذاتی عمیق هستند و حالت پنهان آن تابعی از حالت‌های پنهان در زمان‌های قبل است [۲۸، ۲۹].

خروجی مدل توسط داده‌های آموزش با داده‌های مشاهداتی برای تعیین بهتر پارامترهای شبکه مورد نظر استفاده شده است. در نهایت با استفاده از داده‌های صحت سنجی شبکه آموزش دیده، مورد ارزیابی قرار گرفته است.


۲-۵- شبکه عصبی مصنوعی پیشرو (Feed Forward Neural Network - FFNN)

شبکه‌های عصبی مصنوعی، سیستم‌ها و روش‌های محاسباتی نوینی برای یادگیری ماشین، یادگیری عمیق، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سیستم‌های پیچیده هستند. از شبکه‌های عصبی مصنوعی می‌توان در هر موردی که نیاز به یادگیری نگاشت خطی و یا غیرخطی است، استفاده کرد. معروف‌ترین نوع شبکه‌های عصبی شبکه‌های عصبی روبه جلو (Feed Forward Neural Network - FFNN) هستند. شبکه‌های FFNN دارای سه لایه اصلی هستند. این شبکه‌ها توسط لایه ورودی و یک لایه مخفی و در نهایت یک لایه خروجی قادر هستند هر نوع تابع غیرخطی را تقریب بزنند [۲۶].



شکل ۳. شبکه عصبی بازگشتی [۳۰].

Fig. 3. Recurrent Neural Network [30].



شکل ۴. سلول RNN ساده [۳۰].

Fig. 4. Simple RNN Cell [30].

یک سلول RNN ساده، توالی $X = (X_1, X_2, \dots, X_t)$ با طول متغیر را به عنوان ورودی دریافت می کند و در هر گام زمانی، حالت مخفی خود را توسط معادله (۳) به روزرسانی می کند [۳۱].

$$h_t = \begin{cases} 0 & t=0 \\ \varphi(h_{t-1}, x_t) & otherwise \end{cases} \quad (3)$$

که در آن φ تابع غیرخطی مانند \tanh ، x_t ورودی در زمان t و h_{t-1} حالت مخفی در زمان قبلی است. شکل ۴ یک سلول RNN ساده را با تابع فعالساز \tanh نشان می دهد.

در شبکه های عصبی FFNN، آموزش وزن ها از طریق الگوریتم پس انتشار (Back Propagation -BP) انجام می شود. این فرآیند شامل دو مسیر رفت و برگشت است: در مسیر رفت، ورودی به شبکه اعمال می شود و خروجی محاسبه می گردد، بدون تغییر در وزن ها. در مسیر برگشتی، خطا محاسبه شده و وزن ها با استفاده از انتشار خطا به سمت عقب تنظیم می شوند تا خطا به حداقل برسد. برای شبکه های عصبی بازگشتی (RNN)، از الگوریتم انتشار به عقب در طول زمان (BPTT) استفاده می شود که توسعه یافته الگوریتم BP است. این الگوریتم با هدف کاهش خطا در طی دو مرحله جلو و عقب، مشابه BP عمل می کند. با افزایش لایه ها در RNN، مشکل محوشدگی یا انفجار گرادیان رخ می دهد که باعث کاهش دقت در یادگیری می شود [۳۲-۳۴]. برای غلبه بر مسئله محوشدگی گرادیان که محدودیت اصلی در آموزش RNN محسوب می شود، روش های مختلفی وجود دارد که می توان آنها را در چهار گروه بیان کرد [۳۵].

- استفاده از روش های غیر مبتنی بر گرادیان.
- نگه داشتن گرادیان در حد بالا برای جلوگیری از محوشدگی سریع.
- استفاده از شبکه های عصبی مرتبه بالاتر.
- به کارگیری ساختارهای خاص مانند شبکه های حافظه بلند-کوتاه مدت.
- در ادامه به معرفی شبکه های بازگشتی حافظه بلند - کوتاه مدت (LSTM) پرداخته شده است.

۲-۷- شبکه های بازگشتی حافظه بلند - کوتاه مدت (Long Short-Term Memory-LSTM)

شبکه های بازگشتی LSTM نوعی از شبکه های عصبی بازگشتی هستند که برای یادگیری وابستگی های بلندمدت طراحی شده اند و اولین

$$f_t = \sigma(W_f [h_{t-1}, X_t] + b_f)$$

$$i_t = \sigma(W_i [h_{t-1}, X_t] + b_i)$$


$$\tilde{C}_t = \tanh(W_c [h_{t-1}, X_t] + b_c)$$

$$C_t = i_t * \tilde{C}_t + f_t * C_{t-1}$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * C_t$$

(۴)

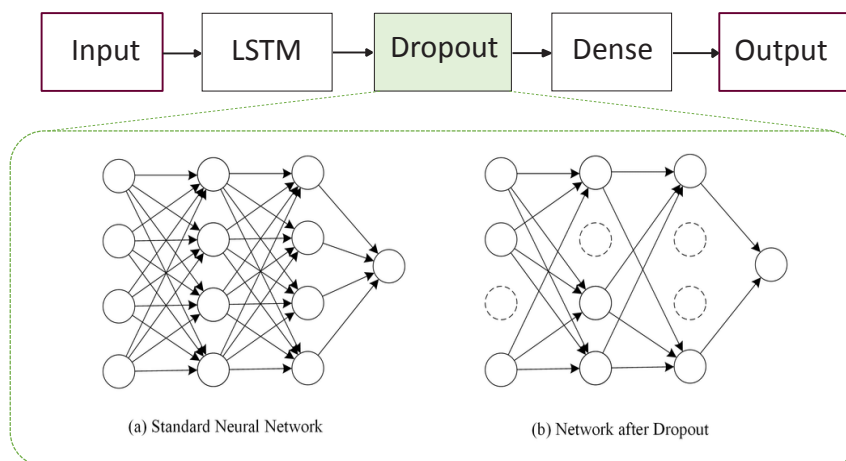


شکل ۵. سلول LSTM [۳۰]

Fig. 5. LSTM Cell [30]

، W_f ، W_c ، W_j و W_o ماتریس‌های وزنی قابل یادگیری b_f ، b_c ، b_j و b_o با f_t خروجی دروازه فراموشی، C_t خروجی دروازه ورودی، o_t حاصل دروازه خروجی، C_t سلول حالت زمان t و h_t خروجی نهایی شبکه است. در شکل ۶ مدل ساخته شده توسط شبکه LSTM نشان داده شده است که در آن لایه Dence یک لایه تماماً متصل است و برای جلوگیری از پدیده بیش برآزش از تکنیک حذف تصادفی (Dropout) استفاده شده است. در این روش، برخی از اتصالات بین لایه‌ها به صورت تصادفی در طول

بار در سال ۱۹۹۷ معرفی شدند. [۳۳]. LSTM دارای چهار دروازه می‌باشد. دروازه سلول (Cell state) که اطلاعات را از ابتدا تا انتهای LSTM حفظ می‌کند، دروازه فراموشی (Forget gate) که تعیین می‌کند چه اطلاعاتی حذف شود، دروازه ورودی (Input gate) که میزان استفاده از اطلاعات ورودی را مشخص می‌کند، و دروازه خروجی (Output gate) که خروجی نهایی و سلول حالت جدید را تولید می‌کند. سلول LSTM را می‌توان توسط شکل ۵ و معادلات (۴-۱) تا (۴-۶) توصیف کرد [۳۰].



شکل ۶. معماری مدل LSTM

Fig. 6. Architecture of the LSTM Model.

بهبود مرحله آموزش و در نتیجه افزایش دقت مدل‌سازی کمک کند [۱۳]. یکی از نکات حائز اهمیت در استفاده از این تبدیل، انتخاب موجک مادر می‌باشد. انتخاب موجک مناسب موضوعی مهم در مدل‌های ترکیبی موجک - شبکه عصبی است که می‌تواند تأثیر قابل توجهی در نتایج مدل‌سازی داشته باشد. ماهیت موجک مادر، کشف شباهت میان سری زمانی تحلیل شده و نمونه موجک استفاده شده می‌باشد [۳۸]. از آنجایی که سریهای زمانی مورد مطالعه تغییرات آرامی داشتند، در این مطالعه برای تجزیه داده‌ها از موجک هار استفاده شده است. تابع موجک هار از اولین و ساده‌ترین موجک‌ها بشمار می‌آید. موجک هار موجکی گسسته بوده و مشابه تابع پله‌ای است. موجک هار علی‌رغم سادگی از خواص مفیدی برخوردار می‌باشد [۳۹]. در روش پیشنهادی WLSTM، سری‌های زمانی ورودی ابتدا به زیرسیگنال‌های مختلف در مقیاس‌های مختلف تجزیه می‌شوند، به طوری که یک زیرسیگنال بزرگ‌مقیاس و چندین زیرسیگنال کوچک‌مقیاس برای به‌دست‌آوردن ویژگی‌های زمانی سیگنال ورودی استخراج می‌شود. اجزای سالانه یا فصلی به زیرسیگنال‌های بزرگ‌مقیاس و نوسانات روزانه، ماهانه و هفتگی به زیرسیگنال‌های کوچک‌مقیاس تجزیه می‌شوند. پس از تجزیه سری‌های زمانی با استفاده از تبدیل موجک، زیرسری‌های به‌دست‌آمده به عنوان ورودی به شبکه LSTM داده می‌شوند [۱۳].

۲-۹- معیارهای ارزیابی

در این پژوهش از شاخص‌های آماری متداول نظیر جذر میانگین مربعات خطا (Error Square Mean Root -RMSE)، ضریب تبیین (Determination Coefficient -DC) و خطای میانگین قدر مطلق (Mean Absolute Error -MAE) استفاده شده است. RMSE به دلیل توانایی در اندازه‌گیری دقیق خطاهای پیش‌بینی و DC به دلیل قابلیت تشریح واریانس داده‌ها و MAE به دلیل ساده بودن و عدم حساسیت به مقادیر دورافتاده، برای ارزیابی عملکرد مدل‌های مورد استفاده در این تحقیق انتخاب شده‌اند. این معیارها کمک می‌کنند تا عملکرد مدل‌ها را به طور مؤثری در هر دو مرحله آموزش و صحت‌سنجی مورد ارزیابی قرار داد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{N}} \quad 0 < RMSE < \infty \quad (6)$$

آموزش غیرفعال می‌شوند تا از یادگیری تنها یک مسیر خاص جلوگیری شود و شبکه مجبور به یادگیری ویژگی‌های متنوع‌تری شود. [۳۵، ۳۶]. در سال‌های اخیر شبکه‌های عمیق در زمینه یادگیری ماشین و یادگیری عمیق، بسیار مورد توجه قرار گرفته‌اند. شبکه‌های عمیق را می‌توان دنباله‌ای از لایه‌های پردازشی دانست که در آن هر لایه قبل از انتقال اطلاعات به لایه دیگر، اطلاعات را پردازش کرده و بخشی از مسئله را حل می‌کند تا زمانی که خروجی توسط آخرین لایه تولید شود؛ بنابراین هرچقدر شبکه عمیق‌تر باشد و تعداد لایه‌های بیشتری داشته باشد، ویژگی‌های غیرخطی بیشتری استخراج می‌شود و مدل‌سازی با دقت بیشتری انجام شود [۳۴، ۳۶].

۲-۸- تبدیل موجک

تبدیل موجک یکی از بهترین روش‌های پردازش سیگنال است. به‌منظور ساده‌کردن بررسی سری زمانی اصلی، پس از تجزیه آن، هر کدام از دوره‌های تناوب به طور جداگانه مورد تحلیل قرار می‌گیرند. با توجه به ساختار گسسته سری‌های زمانی هیدرولوژیکی فرم گسسته تبدیل موجک (DWT) مورد استفاده واقع می‌شود. در تبدیل موجک گسسته پارامترهای انتقال و مقیاس به صورت $a = 2m$ و $b = 2m$ انتخاب می‌شوند. به طوری که m و n اعداد صحیح هستند. برای سری گسسته x_i تبدیل دودویی موجک به صورت رابطه (۵) است [۳۷]:

$$T_{m,n} = 2^{-\frac{m}{n}} \sum_{i=0}^{N-1} \psi(2^{-m}i - n)x_i \quad (5)$$

در رابطه ۵ $\psi(x)$ تابع موجک، N طول سری زمانی و $T_{m,n}$ ضریب موجک برای a و b می‌باشد که با اعمال تبدیل موجک گسسته در هر مرحله، سیگنال به دو مؤلفه جزء و تقریب تجزیه می‌شود. یکی از قابلیت‌های اصلی تبدیل موجک گسسته، توانایی آن در تجزیه سری زمانی اصلی به چندین زیرسری زمانی است. هر یک از زیرسری‌های به‌دست‌آمده ویژگی خاصی دارند که نمایانگر فرکانس خاص یا دوره فصلی خاصی است. برای کاهش پیچیدگی سری زمانی اصلی، از تجزیه بر اساس موجک استفاده می‌شود تا ویژگی‌های فصلی زیرسری‌های به‌دست‌آمده به طور جداگانه تحلیل شوند. تجزیه سری زمانی اصلی به زیرسری‌ها باعث می‌شود که شبکه وزن‌های خاصی به هر زیرسری اختصاص دهد و در واقع، با تجزیه سری زمانی، ویژگی‌های سری زمانی به طور مؤثری استخراج می‌شود و این می‌تواند به

جدول ۲. نتایج مدل‌سازی سناریو ۱ با استفاده از شبکه‌های عصبی پیشرو و بازگشتی.

Table 2. Results of Scenario 1 modeling using Feedforward and Recurrent Neural Networks.

DC	MAE		RMSE		ساختار شبکه				شبکه	پیزومتر
	آموزش	صحت سنجی	آموزش	صحت سنجی	گام زمانی	تعداد دسته‌ها	تعداد تکرار	واحد پنهان		
صحت سنجی	۰/۹۴	۰/۰۳	۰/۰۴	۰/۷۸	۰/۶۵	-	۱۰۰	۵	FFNN	
	۰/۸۷	۰/۹۲	۰/۰۳	۰/۹۵	۰/۸۰	۵	۱۲	۱۰۰۰	Simple RNN	۲۱۲
	۰/۹۳	۰/۹۷	۰/۰۳	۰/۶۸	۰/۵۰	۸	۳۲	۱۰۰۰	LSTM	
	۰/۹۶	۰/۹۸	۰/۰۲	۰/۴۹	۰/۳۵	۸	۳۲	۱۰۰۰	WLSTM	
	۰/۸۲	۱/۰۰	۰/۰۳	۰/۰۱	۰/۰۱	-	۱۰۰	۵	FFNN	
	۰/۸۳	۰/۹۹	۰/۰۳	۰/۰۱	۰/۰۱	۸	۶۴	۵۰۰	Simple RNN	۲۱۸
	۰/۸۶	۱/۰۰	۰/۰۳	۰/۰۱	۰/۰۱	۸	۳۲	۵۰۰	LSTM	
	۰/۸۸	۰/۹۹	۰/۰۳	۰/۰۱	۰/۰۱	۸	۳۲	۵۰۰	WLSTM	

پارامترها، مدل به‌وسیله داده‌های آموزشی مورد ارزیابی قرار گرفت. پس از اینکه مقدار بهینه پارامترها تعیین شد برای پیش‌بینی از داده‌های صحت سنجی استفاده شد و مدل‌های تعریف شده با استفاده از معیارهای ارزیابی تعیین شده صحت سنجی شدند. مقادیر DC و RMSE مدل‌سازی‌های انجام شده در سناریو ۱ برای هر دو پیزومتر در جدول ۲ نشان داده شده است. در مرحله اول ارتفاع پیزومترهای ۲۱۲ و ۲۱۸ توسط شبکه عصبی پیشرو با الگوریتم آموزش پس انتشار تخمین زده شدند. در مدل‌سازی توسط شبکه عصبی پیشرو برای تعیین ورودی‌های مؤثر از ضریب همبستگی استفاده شد و در نهایت از ارتفاع پیزومتر i در یک‌زمان قبل و تراز آب بالادست سد در زمان t و $t-1$ استفاده شد. برای به‌دست‌آوردن ساختار بهینه، تعداد نرون‌ها در لایه میانی و تعداد تکرار مرحله آموزش متغیر در نظر گرفته شده و در نهایت ساختار بهینه انتخاب شد. باتوجه‌به نتایج در مدل‌سازی با شبکه‌های عصبی پیشرو مقدار DC برای پیزومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۱ و ۰/۸۲ به دست آمد.

در مرحله بعد مدل‌سازی با شبکه‌های عصبی بازگشتی RNN و LSTM و الگوریتم بهینه‌ساز BBTT با گام‌های زمانی مختلف، تعداد تکرار و دسته متفاوت انجام شد که برای هر دو مدل گام زمانی ۸، تعداد تکرار ۱۰۰۰ و ۵۰۰، اندازه دسته ۳۲، ۱۲ و ۶۴ نتایج بهتری ارائه دادند. در مدل‌سازی با روش‌های هوش مصنوعی خروجی مدل، علاوه بر داده‌های

$$DC = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad -\infty < DC < 1 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |x_i - y_i| \quad 0 < MAE < \infty \quad (8)$$

در روابط (۶)، (۷) و (۸)، x_i داده‌های مشاهداتی و y_i داده‌های محاسباتی توسط مدل، n تعداد داده‌ها و \bar{x}_i میانگین داده‌های مشاهداتی است. در هر دو مرحله آموزش و صحت سنجی مقادیر DC، RMSE و MAE باید در محدوده مطلوب قرار گیرد. هرچه میزان MAE و RMSE به صفر نزدیک‌تر باشد، مدل خطای کمتری دارد و هرچه میزان DC به یک نزدیک‌تر باشد به این معنی است که مدل برای نمونه مورد نظر مناسب است.

۳- نتایج و بحث

برای انجام مدل‌سازی بعد از انتخاب داده‌های ورودی، ابتدا پیش‌پردازش داده‌ها انجام شد؛ سپس با تعریف نوع سلول بازگشتی و تعداد واحدهای حافظه معماری شبکه مورد نظر تعریف شد و با تعیین تابع هزینه و الگوریتم بهینه‌ساز، شبکه تعریف شده باتوجه‌به تعداد تکرارها و دسته‌های تعیین شده برای هر تکرار، بروی داده‌های آموزشی برازش داده شد. برای تعیین بهینه

دوره تناوب بلند) هستند که نشان‌دهنده تغییرات آرام و اجزای پایین‌تر دارای فرکانس بالا (دوره تناوب کوتاه) هستند که نشان‌دهنده تغییرات سریع هستند. باتوجه به نتایج جدول ۲ بعد از انتخاب ساختار بهینه توسط آزمون و خطا برای مدل WLSTM مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۶ و ۰/۸۸ به دست آمد. مقادیر مشاهده و محاسبه شده در مرحله صحت‌سنجی توسط مدل‌ها بر اساس سناریو ۱ برای پیژومتر ۲۱۲ در شکل ۸ و برای پیژومتر ۲۱۸ در شکل ۹ نشان داده شده است باتوجه به شکل‌های ۸ و ۹ در هر دو پیژومتر شبکه‌های بازگشتی به دلیل داشتن ساختار بازگشتی، در شناسایی و تخمین پدیده تراوش که وابسته به زمان است نسبت به شبکه‌های پیشرو عملکرد بهتری دارند.


در سناریو دوم از ضریب همبستگی برای تعیین ۲ پیژومتر مؤثر در مدل‌سازی استفاده شد. نمودار راداری شکل ۱۰ ضریب همبستگی پیژومترهای ۲۱۲ و ۲۱۸ را با سایر پیژومترهای موجود در بدنه سد ستارخان را نشان می‌دهد که در آن پیژومتر ۲۱۲ با پیژومتر ۲۱۱ و ۲۱۳ و پیژومتر ۲۱۸ با دو پیژومتر ۲۱۵ و ۲۱۷ بیشترین همبستگی را دارد. بعد از تعیین ورودی‌ها در سناریو ۲ مراحل مدل‌سازی مانند سناریو ۱ انجام شد. نتایج مدل‌سازی سناریو ۲ با شبکه‌های عصبی پیشرو و بازگشتی برای هر دو پیژومتر در جدول ۳ نشان داده شده است.

در مرحله اول سناریو ۲ در مدل‌سازی با شبکه‌های عصبی پیشرو مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ به ترتیب ۰/۹۱ و ۰/۷۰ به دست آمده است. در مدل‌سازی با شبکه‌های عصبی بازگشتی RNN و LSTM و الگوریتم بهینه‌ساز BBTT برای هر دو مدل تعداد تکرار ۵۰۰ و اندازه دسته ۳۲ و ۱۲ نتایج بهتری ارائه دادند. در مدل‌سازی با شبکه RNN مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۲ به ترتیب ۰/۹۶ و ۰/۷۱ و در مدل‌سازی با شبکه LSTM مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۲ به ترتیب ۰/۹۷ و ۰/۷۴ به دست آمد. در گام بعدی و مدل‌سازی توسط مدل ترکیبی موجک - شبکه عمیق ارتفاع پیژومتریک پیژومترهای ۲۱۲ و ۲۱۸ با دقت ۰/۷۷ و ۰/۷۸ تخمین زده شد.

باتوجه به نتایج به دست آمده در مدل‌سازی سری‌های زمانی هیدرولوژی مانند تراوش شبکه‌های بازگشتی نسبت به شبکه‌های پیشرو دقت تخمین بالاتری دارند و برای پیش‌بینی سیستم‌های دینامیکی مناسب هستند. استفاده از شبکه‌های با ساختار خاص مانند LSTM با غلبه بر مشکل محوشدگی گرادیان، دقت بیشتری نسبت به شبکه بازگشتی ساده دارند. اگرچه استفاده از انواع مختلف شبکه‌های عصبی مصنوعی در مدل‌سازی‌های غیرخطی مسائل

ورودی به درست تنظیم نمودن پارامترها نیز وابسته است؛ برای این منظور، با استفاده از آزمون و خطا پارامترهای سیستم به دست آمده است. در این پژوهش، پارامترهای گام زمانی، تعداد تکرار، دسته‌های تکرار و واحدهای پنهان با استفاده از روش سعی و خطا انتخاب شد. ساخت دنباله ورودی توسط پارامتر گام زمانی انجام شده و مقدار بهینه آن توسط آزمون و خطا انتخاب شد بطوریکه در مدل‌های بازگشتی مورد استفاده با افزایش گام زمانی ابتدا دقت مدل افزایش یافته است ولی با بیشتر شدن گام زمانی و در نتیجه افزایش طول دنباله ورودی از کارایی مدل کاسته می‌شود. در نهایت برای هر دو پیژومتر گام زمانی ۵ و ۸ انتخاب شد. روند آموزش شبکه در تکرارها و دسته‌های مشخص انجام می‌شود. مقدار این تکرارها و دسته‌ها می‌تواند هر مقدار دلخواهی باشد. برای تعیین مقدار بهینه آن‌ها نیز از روش آزمون و خطا استفاده شده است. مقدار بهینه هر پارامتر، مقدار است که بیشترین DC و کمترین RMSE و MAE را داشته باشد. مقایسه خطای داده‌های آموزش و تست برای تکرارهای متفاوت، نشان داد که با افزایش تعداد تکرارها شبکه کم‌کم قدرت تعمیم خود را از دست می‌دهد و دچار بیش‌برازش می‌شود. در نهایت تعداد ۵۰۰ و ۱۰۰۰ تکرار برای آموزش مدل‌های مورد استفاده انتخاب شد. با افزایش تعداد واحدهای پنهان، ظرفیت شبکه بازگشتی افزایش پیدا می‌کند و شبکه پیچیده‌تر می‌شود. برای انتخاب مقدار مناسب این پارامتر همانند پارامترهای قبلی مطابق جدول (۲)، از روش آزمون و خطا استفاده شد. باتوجه به نتایج در مدل‌سازی با شبکه بازگشتی ساده مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۸۷ و ۰/۸۳ به دست آمد. همچنین در مدل‌سازی با شبکه LSTM نیز در حالت بهینه مقدار DC برای پیژومتر ۲۱۲ و ۲۱۸ در سناریو ۱ به ترتیب ۰/۹۳ و ۰/۸۶ به دست آمد.

در گام بعدی مدل‌سازی توسط مدل ترکیبی موجک - شبکه عمیق استفاده شد. بدین منظور ابتدا سری‌های زمانی توسط تبدیل موجک گسسته به زیرسری‌هایی تجزیه شدند. باتوجه به اینکه که سری‌های زمانی مورد مطالعه تغییرات آرامی داشتند، در این مطالعه برای تجزیه داده‌ها از موجک هار استفاده شد. از تجزیه یک سیگنال توسط تبدیل موجک گسسته ضرایب جزئی تقریب حاصل می‌شوند. به عنوان نمونه شکل ۷ تجزیه سری زمانی ارتفاع پیژومتریک مربوط به پیژومتر ۲۱۲ را نشان می‌دهد ضرایب تقریب (a) نشانگر ضرایب تبدیل موجک با وضوح درشت هستند که روندهای صاف و هموار را در سری نشان می‌دهند و Di ضرایب جزء هستند که اطلاعات جزئی از روندها و تناوب‌های خاصی از سری زمانی را ارائه می‌کنند. باتوجه به شکل ۷ مشاهده می‌شود که اجزای بالاتر دارای فرکانس پایین




شکل ۷. زیرسری‌های تجزیه شده سری زمانی پیزومتر ۲۱۲ توسط موجک هار درجه سه.

Fig. 7. Decomposed subseries of piezometer 212 time series using third-order Haar wavelet.


بیشتری با سری زمانی ارتفاع آب بالادست دارد. در مقابل پیزومتر ۲۱۸ فاصله بیشتری با بالادست سد دارد و به علت اینکه حرکت آب در خاک آهسته است و عبور آب از خاک باعث کاهش نوسانات موجود در بالادست سد می‌شود، از این رو سری زمانی پیزومتر ۲۱۸ همبستگی کمتری با سری زمانی بالادست سد دارد. به علت استفاده از سری‌های زمانی بالادست سد و خود پیزومتر در مدل‌سازی‌ها در نهایت نتایج بهتری برای پیزومتر ۲۱۲ به دست آمده است. با اینکه که در سناریو ۲ از خود پیزومتر در مدل‌سازی استفاده نشده؛ ولی نتایج حاصل از سناریو ۲ مانند سناریو ۱ دارای دقت بالایی است. این امر به این دلیل است که از داده‌های هم‌زمان با داده‌های هدف و همین‌طور از ۲ پیزومتر برای مدل‌سازی استفاده شده است. روش پیشنهادی

هیدرولیکی و هیدرولوژیکی کاربرد فراوانی دارد، در مدل‌سازی سری‌های زمانی که دارای تغییرات شدید بوده و یا نا ایستا باشند بازده مدل‌های شبکه عصبی مصنوعی کم خواهد شد و استفاده از تبدیل موجک به‌عنوان پیش‌پردازش زمانی داده‌ها باعث رفع این نقصان و افزایش دقت مدل‌سازی می‌شود. با توجه به نتایج استفاده از مدل ترکیبی شبکه بازگشتی - موجک باعث افزایش عملکرد مدل‌سازی شده به‌طوری که دقت مدل‌سازی در پیزومتر ۲۱۲ و ۲۱۸ به ترتیب ۳ و ۴٪ نسبت به مدل‌سازی با شبکه‌های بازگشتی عمیق و به ترتیب ۸ و ۱۰٪ نسبت به شبکه عصبی پیشرو افزایش یافت. برای پیزومتر ۲۱۲ نتایج دقیق‌تری نسبت به پیزومتر ۲۱۸ به دست آمده است؛ چون پیزومتر ۲۱۲ به بالادست سد نزدیک‌تر است در نتیجه همبستگی




شکل ۸. مقادیر مشاهده و محاسبه شده مرحله صحت سنجی پیزومتر ۲۱۲.

Fig. 8. Observed and computed values for the validation stage of piezometer 212.



شکل ۹. مقادیر مشاهده و محاسبه شده مرحله صحت سنجی پیزومتر ۲۱۸.

Fig. 9. Observed and computed values for the validation stage of piezometer 218.



شکل ۱۰. ضریب همبستگی پیزومترهای ۲۱۲ و ۲۱۸ با سایر پیزومترها.

Fig. 10. Correlation coefficient of piezometers 212 and 218 with other piezometers.

جدول ۳. نتایج مدل‌سازی سناریو ۲ با استفاده از شبکه‌های عصبی پیشرو و بازگشتی.

Table 3. Results of Scenario 2 modeling using Feedforward and Recurrent Neural Network.

DC	MAE		RMSE		ساختار شبکه					پیزومتر	
	آموزش	صحت سنجی	آموزش	صحت سنجی	گام زمانی	تعداد دسته‌ها	تعداد تکرار	واحد پنهان	شبکه		
صحت سنجی	۰/۹۱	۰/۹۵	۰/۰۳	۰/۰۳	۰/۷۸	۰/۵۹	-	۱۰۰	۴	FFNN	۲۱۲
	۰/۹۶	۰/۹۶	۰/۰۲	۰/۰۱	۰/۵۵	۰/۵۳	۵	۱۲	۱۰۰۰	Simple RNN	
	۰/۹۷	۰/۹۹	۰/۰۲	۰/۰۱	۰/۴۴	۰/۲۹	۸	۳۲	۱۰۰۰	LSTM	
	۰/۹۸	۰/۹۹	۰/۰۲	۰/۰۱	۰/۳۶	۰/۲۳	۸	۳۲	۱۰۰۰	WLSTM	
	۰/۷۰	۱/۰۰	۰/۰۳	۰/۰۱	۰/۰۴	۰/۰۱	-	-	۱۰۰	FFNN	۲۱۸
	۰/۷۱	۰/۹۶	۰/۰۲	۰/۰۱	۰/۰۴	۰/۰۳	۸	۳۲	۵۰۰	Simple RNN	
	۰/۷۴	۱/۰۰	۰/۰۲	۰/۰۱	۰/۰۴	۰/۰۱	۸	۳۲	۵۰۰	LSTM	
	۰/۷۷	۰/۹۴	۰/۰۲	۰/۰۱	۰/۰۴	۰/۰۳	۵	۳۲	۵۰۰	WLSTM	

تغییرات بلندمدت و پیچیده در تراوش و سایر پارامترهای هیدرولوژیکی، به برنامه‌ریزی و مدیریت بلندمدت سد کمک می‌کند و می‌تواند استراتژی‌های بهینه‌تری برای تنظیم جریان آب و افزایش عمر مفید سد ارائه دهد. همچنین این مدل قادر است الگوهای غیرعادی یا ناگهانی در تراوش را که ممکن است نشان‌دهنده مشکلات ساختاری یا عملکردی در سد باشند، شناسایی کند. از آنجا که در سناریوی دوم این تحقیق، تراز آب پیزومترها بدون استفاده از مقادیر مشاهده‌شده قبلی و با بهره‌گیری از داده‌های پیزومترهای دیگر تخمین زده شده است، این مدل در شرایط بحرانی و از کارافتادگی پیزومترها

در این تحقیق با بهبود دقت پیش‌بینی تراز آب و تراوش در پیزومترها نسبت به روش‌های سنتی و شبکه‌های عصبی پیشرو، به مدیران سدها امکان می‌دهد تا تصمیم‌گیری‌های دقیق‌تری انجام دهند و در مواقع بحرانی مانند خشکسالی یا بارندگی‌های شدید، از وقوع بحران‌های جدی جلوگیری کنند. همچنین، این مدل به دلیل توانایی استفاده از داده‌های پیزومترهای همبسته به‌جای داده‌های معیوب، در شرایط خرابی یا نقص فنی تجهیزات، همچنان دقت پیش‌بینی‌ها را حفظ کرده و عملکرد مطمئن سد را تضمین می‌کند. علاوه بر این، روش ترکیبی شبکه بازگشتی-موجک با قابلیت تشخیص

and scheduling perspective, in: 5th international Congress on civil engineering, architecture and urban development, 2017. (in Persian)

- [3] B. Nemati, H. Shafiee, Numerical modeling of seepage in earth dams using numerical methods, in: Fourth Conference on New Research in Science and Technology, 2015. (in Persian)
- [4] L.N. Reddi, Seepage in soils: principles and applications, John Wiley & Sons, 2003.
- [5] E. Sharghi, V. Nourani, N. Behfar, Evaluation and Application of Ensemble AI-based Models for Estimating Piezometric Heads of Earth Fill Dam, Iran-Water Resources Research, 14(4) (2018) 160-169. (in Persian)
- [6] G. Tayfur, D. Swiatek, A. Wita, V.P. Singh, Case study: Finite element method and artificial neural network models for flow through Jeziorsko earthfill dam in Poland, Journal of Hydraulic Engineering, 131(6) (2005) 431-440.
- [7] D. Ersayın, Studying seepage in a body of earth-fill dam by (Artificial Neural Networks) ANNs, Izmir Institute of Technology, 2006.
- [8] X.Y. Miao, J.K. Chu, J. Qiao, L.H. Zhang, Predicting seepage of earth dams using neural network and genetic algorithm, in: Advanced Materials Research, Trans Tech Publ, 2012, pp. 3081-3085.
- [9] P. Coulibaly, C.K. Baldwin, Nonstationary hydrological time series forecasting using nonlinear dynamic methods, Journal of Hydrology, 307(1-4) (2005) 164-174.
- [10] S.J. Yoo, J.B. Park, Y.H. Choi, Stable predictive control of chaotic systems using self-recurrent wavelet neural network, international journal of control, automation, and systems, 3(1) (2005) 43-55.
- [11] S. Mirabedini, A review on deep learning, in: Third National Conference on Electrical and Computer Engineering, 2018. (in Persian)
- [12] A.U. Muhammad, X. Li, J. Feng, Using LSTM GRU and hybrid models for streamflow forecasting, in: International Conference on Machine Learning and Intelligent Communications, Springer, 2019, pp. 510-

نیز بسیار مفید خواهد بود. این ویژگی، به‌ویژه زمانی که تجهیزات پایش سد دچار نقص شده‌اند، از طریق استفاده از داده‌های جایگزین، به حفظ دقت و قابلیت اطمینان پیش‌بینی‌ها کمک می‌کند.

۴- نتیجه‌گیری

در این تحقیق، تراوش سد ستارخان با استفاده از شبکه‌های عصبی پیشرو و بازگشتی در دو سناریو مدل‌سازی شد. نتایج نشان داد که شبکه‌های بازگشتی نسبت به شبکه‌های عصبی پیشرو در مدل‌سازی پدیده‌های وابسته به زمان مانند تراوش، دقت بالاتری دارند. دارند به‌طوری که باعث افزایش دقت مدل‌سازی تا ۷٪ شده است. در ادامه، برای افزایش کارایی مدل‌سازی، از تبدیل موجک در پیش‌پردازش داده‌ها استفاده شد. این پیش‌پردازش داده‌ها منجر به بهبود نتایج مدل‌سازی شد، به طوری که در مدل ترکیبی شبکه عصبی بازگشتی - موجک، دقت مدل نسبت به مدل‌های بدون استفاده از تبدیل موجک به میزان تا ۱۰٪ افزایش داده است. همچنین، مقایسه نتایج دو سناریو نشان داد که استفاده از داده‌های هم‌زمان با داده‌های هدف در مدل‌سازی، دقت مدل‌سازی را به میزان ۴٫۱٪ در پیژومتر ۲۱۸ افزایش داده است. این نتیجه‌گیری حاکی از آن است که در صورت خرابی یک پیژومتر، می‌توان از داده‌های پیژومترهایی که همبستگی بالایی با پیژومتر مورد نظر دارند استفاده کرد. همچنین، در مدل‌سازی پیژومتر نزدیک‌تر به بالادست سد، به دلیل همبستگی بیشتر با سری زمانی بالادست، نتایج دقیق‌تری به دست آمد. پیشنهاد می‌شود برای سایر کمیت‌های سد مثل تراوش از پی اقدام به مدل‌سازی مشابه شود. با توجه به تعداد و اهمیت تنظیم‌های پارامترهای شبکه‌های عمیق و چالش‌های استفاده از روش آزمون و خطا پیشنهاد می‌شود برای تعیین مقدار این پارامترها از روش‌ها و الگوریتم‌های هوشمند استفاده شود. در مدل‌سازی با استفاده از شبکه‌های عمیق، استفاده از الگوریتم‌های هوشمند می‌تواند به کاهش زمان مورد نیاز برای تنظیم‌های پارامترها، افزایش دقت پیش‌بینی‌ها، و بهبود عملکرد کلی مدل کمک کند.

منابع

- [1] V. Nourani, E. Sharghi, M.H. Aminfar, Integrated ANN model for earthfill dams seepage analysis: Sattarkhan Dam in Iran, Artif. Intell. Res., 1(2) (2012) 22-37.
- [2] A. Pourghasemzadeh, M. Mahdavi Adeli, A comparison of the construction of cut-off wall and grouting curtain in the foundation of Gotvand Aliya Dam from an economic

- [23] M.G. Zamani, M.R. Nikoo, F. Niknazar, G. Al-Rawas, M. Al-Wardy, A.H. Gandomi, A multi-model data fusion methodology for reservoir water quality based on machine learning algorithms and bayesian maximum entropy, *Journal of Cleaner Production*, 416 (2023) 137885.
- [24] Behavior monitoring report of the Sattar Khan dam project, in: B.C. Engineers (Ed.), 2003. (in Persian)
- [25] M. Ghabaei Sough, A. Mosaedi, M. Hesam, A. Hezarjaribi, Evaluation Effect of Input Parameters Preprocessing in Artificial Neural Networks (Anns) by Using Stepwise Regression and Gamma Test Techniques for Fast Estimation of Daily Evapotranspiration, *Water and Soil*, 24(3) (2010) -(in Persian)
- [26] V. Nourani, Fundamentals of hydroinformatics, University of Tabriz, 2015. (in Persian)
- [27] A. Graves, Supervised sequence labelling, in: Supervised sequence labelling with recurrent neural networks, Springer, 2012, pp. 5-13.
- [28] J. Brownlee, Long short-term memory networks with python: develop sequence prediction models with deep learning, *Machine Learning Mastery*, 2017.
- [29] A. Graves, A.-r. Mohamed, G. Hinton, Speech recognition with deep recurrent neural networks, in: 2013 IEEE international conference on acoustics, speech and signal processing, Ieee, 2013, pp. 6645-6649.
- [30] C. Olah, Understanding lstm networks–colah’s blog, Colah. github. io, (2015).
- [31] J. Chung, C. Gulcehre, K. Cho, Y. Bengio, Empirical evaluation of gated recurrent neural networks on sequence modeling, arXiv preprint arXiv:1412.3555, (2014).
- [32] Y. Bengio, P. Simard, P. Frasconi, Learning long-term dependencies with gradient descent is difficult, *IEEE transactions on neural networks*, 5(2) (1994) 157-166.
- [33] S. Hochreiter, J. Schmidhuber, Long short-term memory, *Neural computation*, 9(8) (1997) 1735-1780.
- [34] R. Pascanu, C. Gulcehre, K. Cho, Y. Bengio, How to construct deep recurrent neural networks, arXiv preprint arXiv:1312.6026, (2013).
- 524.
- [13] V. Nourani, N. Behfar, Multi-station runoff-sediment modeling using seasonal LSTM models, *Journal of Hydrology*, 601 (2021) 126672.
- [14] C. Park, I.-M. Chung, Evaluating the groundwater prediction using LSTM model, *Journal of Korea Water Resources Association*, 53(4) (2020) 273-283.
- [15] h. siasar, T. honar, Comparison of Performance of GLM, RF and DL Models in Estimation of Reference Evapotranspiration in Zabol Synoptic Station, *journal of watershed management research*, 11(22) (2020) 210-219.
- [16] M. Ishfaqe, Q. Dai, N.u. Haq, K. Jadoon, S.M. Shahzad, H.T. Janjuhah, Use of recurrent neural network with long short-term memory for seepage prediction at Tarbela Dam, KP, Pakistan, *Energies*, 15(9) (2022) 3123.
- [17] N. Farboudfam, V. Nourani, B. Aminnejad, Spatial-temporal disaggregation of rainfall time series using wavelet-artificial neural network hybrid model, *Iran-Water Resources Research*, 14(5) (2019) 490-495. (in Persian)
- [18] D.M. Hawkins, The problem of overfitting, *Journal of chemical information and computer sciences*, 44(1) (2004) 1-12.
- [19] B. Cannas, A. Fanni, G. Sias, S. Tronci, M. Zedda, River flow forecasting using neural networks and wavelet analysis, in: *Geophys. Res. Abstr*, 2005, pp. 08651.
- [20] V. Nourani, A.H. Baghanam, J. Adamowski, O. Kisi, Applications of hybrid wavelet-artificial intelligence models in hydrology: a review, *Journal of Hydrology*, 514 (2014) 358-377.
- [21] K. Roushangar, V. Nourani, M. Dolatshahi, Investigation and trend identification of groundwater level variations using discrete wavelet transform and non-parametric tests (case study: Azarshahr plain), *Iran-Water Resources Research*, 16(1) (2020) 102-115. (in Persian)
- [22] B. Fatehi-Nobarian, S. Fard Moradinia, Wavelet-ANN hybrid model evaluation in seepage prediction in nonhomogeneous earth dams, *Water Practice & Technology*, (2024) wpt2024152.

- and Wavelet Transform Method (Case Study: Ardabil Plain), Environment and Water Engineering, 4(3) (2018) 241-251. (in Persian)
- [38] J. Adamowski, H.F. Chan, A wavelet neural network conjunction model for groundwater level forecasting, Journal of Hydrology, 407(1-4) (2011) 28-40.
- [39] O.S. Jahromi, B.A. Francis, R.H. Kwong, Algebraic theory of optimal filterbanks, IEEE transactions on signal processing, 51(2) (2003) 442-457.
- [35] S. Hochreiter, Recurrent neural net learning and vanishing gradient, International Journal Of Uncertainty, Fuzziness and Knowledge-Based Systems, 6(2) (1998) 107-116.
- [36] M. Hermans, B. Schrauwen, Training and analysing deep recurrent neural networks, Advances in neural information processing systems, 26 (2013) 190-198.
- [37] F. Daneshvar Vousoughi, R. Shaker, Assessment of Trend in Groundwater Level using Hybrid Mann-Kendall

چگونه به این مقاله ارجاع دهیم

A. Hosseini Baghonam, V. Noorani, E. Sharghi, Z. Dadashpour, Estimation of seepage in earth fill dams using deep learning and wavelet transform, Amirkabir J. Civil Eng., 56(11) (2025) 1387-1406.

DOI: [10.22060/ceej.2024.22535.8007](https://doi.org/10.22060/ceej.2024.22535.8007)

