

**EXTENDED ABSTRACT**

**Evaluating the Performance of Wavelet Neural Network Models in Estimation of Daily Discharge**

H. R. Baba Ali<sup>1</sup> and R. Dehghani<sup>2\*</sup>

1- Assistant Professor of Civil Engineering, Islamic Azad University, Khorramabad.

2\* - Corresponding Author, Ph.D. Student of Water Structure, Faculty of Agric., University of Lorestan, Khorramabad, Iran.([reza.dehghani67@yahoo.com](mailto:reza.dehghani67@yahoo.com)).

Received: 15 May 2017

Revised: 22 October 2017

Accepted: 30 October 2017

**Keywords:** Estimation, Flood, Artificial Neural Network, Nourabad. **DOI:** 10.22055/jise.2017.22047.1580.

**Introduction**

River flow prediction is one of the most important key issues in the management and planning of water resources, in particular the adoption of proper decisions in the event of floods and the occurrence of droughts. In order to predict the flow rate of rivers, various approaches have been introduced in hydrology, in which intelligent models are the most important ones. The application of artificial neural networks (ANNs) to various aspects of hydrological modeling has undergone much investigation in recent years. This interest has been motivated by the complex nature of hydrological systems and the ability of ANNs to model non-linear relationships. ANNs are essentially semi-parametric regression estimators and well suited for hydrological modeling, as they can approximate virtually any (measurable) function up to an arbitrary degree of accuracy (Hornik et al., 1989). A significant advantage of the ANN approach in system modeling is that one need not have a well-defined process for algorithmically converting an input to an output.

**Materials and Methods**

In this study, daily data from Badavar watershed in Lorestan Province was used to evaluate the accuracy of models in river flow prediction. Wavelet neural network and artificial neural network were used to model the daily flow of Badavar River and the results were compared with each other for the accuracy of the studied models. In a few studies, each of the models presented in the prediction of daily flow has been studied, but the purpose of this study is to simultaneously examine these models in a basin to predict the daily flow of the river. In this research, the Badavar River in Lorestan Province was selected as the study area and the daily flow of observations of this basin was used at Badavar hydrometric station to calibrate and validate the models. For this purpose, at first 80% of the daily flow data (2002-2010) was selected for calibration of the models and 20% of the data (2010-2012) were used to validate the models. For this purpose, precipitation different time daily rate at daily scale as input and flood peak discharge as output parameters were selected. The criteria of the correlation coefficient, root mean square error, and of mean absolute error were used to evaluate and compare the performance of models.

Wavenet, called wavelet-based neural network, combined with wavelet theory and neural networks have been created. It also has the support of the benefits and features of neural networks and charm, flexibility, and strong mathematical foundations and analysis of multi-scale wavelet. A combination of wavelet theory with neural network concepts with the creation of wavelet neural network and feedforward neural shock can be a good alternative for estimating approximate

nonlinear functions. Feedforward neural network with the sigmoid activation function is in the hidden layer. While at the nerve shocked wavelet, wavelet functions as activation function of hidden layer feedforward networks are considered in both of these networks, and scale wavelet transformation parameters are optimized with their weight.

Artificial neural networks inspired by the brain's information processing systems were designed and emerged to help the learning process, and with the use of processors called neurons are used to understand the inherent relationships in data mapping between input space and optimal space. Hidden layer or layers, the information received from the input layer and output layer, are the processing and disposal. Based on the artificial neural network structure, its major features are high processing speed, the ability to learn the pattern, the ability to extend the model after learning, flexibility against unwanted errors, and no disruption to an error on the part of the connection due to weight distribution network. The first practical application of synthetic networks with the introduction of the multilayer perceptron network was consultants. for training this network, backpropagation algorithm is used. The basis of this algorithm is based on error correction learning rule that consists of two main routes, which by adjusting the parameters in the MLP model error signal and input signal occurs. Determining the number of layers and neurons is the most important issue in a simulation with an artificial neural network.

### Results

The results showed that both models have better results in structures of 1 to 5 daily times than the other specified structures. In addition, according to the evaluation criteria, it was found that between the models used, the wavelet neural network model has the highest accuracy of  $R = 0.920$ , the lowest root mean square error of  $RMSE=0.005m^3/s$ , and the lowest absolute error value of  $MAE=0.003m^3/s$  at the verification stage.

### Conclusions

The results showed that an increase in the number of effective parameters in different models for simulations results in better performance in the discharge estimation. In addition, the results showed that the wavelet neural network model has a better performance than the artificial neural network.

### Acknowledgments

The authors are very grateful of Lorestan Regional Water Company, because of their efforts in finalizing and gathering the data necessary for performing this study.

### Refereces

Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feed forward networks are universal approximators, *Neural Networks*, 2(3), pp.359– 366.



© 2019 by the authors. Licensee SCU, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>).



## بررسی عملکرد مدل شبکه عصبی موجک در تخمین دبی روزانه

حمیدرضا باباعلی<sup>۱</sup> و رضا دهقانی<sup>۲\*</sup>

۱- استادیار گروه مهندسی عمران، دانشگاه آزاد خرم آباد.

۲- نویسنده مسئول، دانشجوی دکتری سازه های آبی، دانشگاه لرستان reza.dehghani67@yahoo.com

پذیرش: ۱۳۹۶/۸/۸

بازنگری: ۱۳۹۶/۷/۳۰

دریافت: ۱۳۹۶/۲/۲۵

### چکیده

سیل یکی از بلاهای طبیعی مهمی است که همه ساله باعث ایجاد خسارت های مالی و جانی فراوانی به جوامع مختلف می گردد. به همین دلیل محققین سعی نموده اند که تغییرات کمی این پدیده را حتی المقدور به طور دقیق مورد بررسی قرار دهند. در این پژوهش برای تخمین دبی روزانه ایستگاه بادآور نورآباد واقع در استان لرستان از مدل شبکه عصبی موجک استفاده شد و نتایج آن با سایر روش های هوشمند از جمله شبکه عصبی مصنوعی مقایسه گردید. برای این منظور از پارامتر حداکثر بارش ۲۴ ساعته یک تا چهار روز قبل در مقیاس زمانی روزانه در طی دوره آماری (۱۳۹۱-۱۳۸۱) به عنوان ورودی و دبی حداکثر روزانه به عنوان پارامتر خروجی مدل ها انتخاب گردید. معیارهای ضریب تعیین، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و عملکرد مدل ها مورد استفاده قرار گرفت. نتایج نشان داد هر دو مدل قابلیت خوبی در تخمین دبی روزانه دارند، مقایسه نتایج نشان داد مدل شبکه عصبی موجک عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی در مدل سازی دارد، به گونه ای که مدل شبکه عصبی موجک با بالاترین ضریب تعیین (۰/۹۲۰)، جذر میانگین مربعات خطا (۰/۰۰۵) و نیز میانگین قدر مطلق خطا (۰/۰۰۳) در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد استفاده از مدل شبکه عصبی موجک می تواند در زمینه تخمین دبی روزانه مفید باشد.

کلید واژه ها: تخمین، سیل، شبکه عصبی مصنوعی، نورآباد.

### مقدمه

سیل از عمده ترین سوانح طبیعی است که به دلیل تحمیل خسارت سنگین بر جوامع بشری و حیات طبیعی، همیشه مورد توجه مدیران و برنامه ریزان برای کاهش اثرات آن بوده است. یکی از راهکارهای کاهش خسارت ها، پهنه بندی میزان پتانسیل سیل خیزی اراضی می باشد. به عبارت دیگر تفکیک نواحی سیل خیز و تعیین سهم عوامل مؤثر در آن، می تواند در تدوین مدیریت مناسب برای سیاست گذاری های میان مدت و کوتاه مدت در بهره برداری بهینه از اراضی، نقش ویژه ای داشته باشد. برای برآورد دبی روزانه در حوضه های فاقد آمار، از مدل های تجربی مختلفی از جمله روش تحلیل منطقه ای سیلاب، استفاده می شود. اما به دلیل آنکه هر حوضه آبریز ویژگی های خاص خود را دارا می باشد، لازم است روش هایی استفاده شود که بتوان بر اساس خصوصیات ذاتی هر حوضه، دبی روزانه آن را شبیه سازی نماید. امروزه سیستم های هوشمند به طور گسترده برای پیش بینی پدیده های غیرخطی مورد استفاده قرار می گیرد، که روش شبکه عصبی موجک و شبکه عصبی مصنوعی از جمله ای این مدل ها است. در سال های اخیر استفاده از روش های هوشمند مورد بررسی در مطالعات پیش بینی دبی روزانه مورد توجه محققین قرار گرفته است، که

از جمله می تواند به موارد ذیل اشاره نمود: Khosravi et al (2011) شبکه عصبی مصنوعی و رگرسیون چند متغیره را برای پیش بینی سیل در حوضه طالقان بکار بردند نتایج نشان داد شبکه عصبی مصنوعی نسبت به رگرسیون چند متغیره دقت بالایی دارد. Marofi et al (2011) کاربرد شبکه های عصبی مصنوعی و عصبی موجکی را برای پیش بینی جریان روزانه رودخانه ی باراندوزچای در دو ایستگاه بی بکران و دیزج طی یک دوره ی آماری ۲۰ ساله مورد بررسی قرار دادند و نتایج نشان داد مدل شبکه عصبی موجکی در پیش بینی جریان روزانه رودخانه نسبت به مدل عصبی مصنوعی توانایی بیشتر دارد. Alijani و Panahi (2012) در پژوهشی برای پیش بینی دبی اوج سیلاب حوضه مادرسو در استان گلستان از شبکه عصبی مصنوعی و رگرسیون چند متغیره استفاده نمودند نتایج نشان داد مدل شبکه عصبی مصنوعی در مرحله آموزش به تعداد لایه میانه حساس نبوده و از عملکرد بهتری نسبت به روش رگرسیون چند متغیره برخوردار است. Negareh et al (2012) در پژوهشی دیگر برای پیش بینی سیلاب رودخانه سرباز از شبکه عصبی مصنوعی و داده های روزانه اقلیمی و هیدرولوژیکی سه ایستگاه سرباز، ایرانشهر و پیردان طی یک دوره ی ۲۸ ساله بهره گرفتند و نشان

متوسط روزانه در این شهرستان به منظور افزایش کارایی اقدامات مدیریت هیدرولوژیک منطقه ضروری است. بنابراین در این پژوهش دبی رودخانه واقع در دشت نورآباد با توجه حداکثر بارش‌هایی که در طول روز رخ داده است، مورد تجزیه و تحلیل قرار گرفته و در مواقع سیلابی و کم‌آبی نتایج مدل مذکور (شبکه عصبی موجک) برای پوشش مناسب نقاط حداقل و حداکثر مورد بررسی قرار گرفت. هدف از این پژوهش تخمین میزان جریان روزانه ایستگاه بادآور نورآباد با استفاده از شبکه عصبی موجک، به طوری که با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود (Wang et al 2000) می‌باشد.

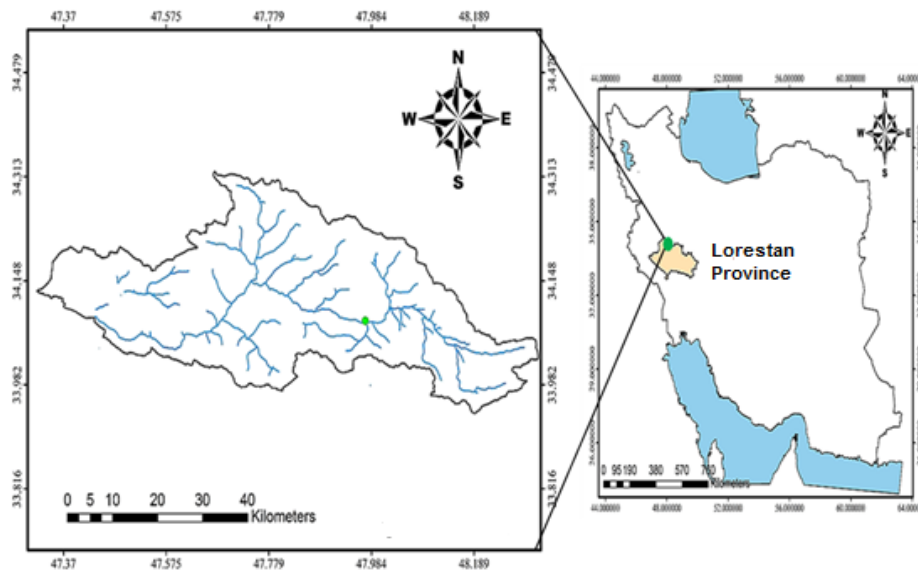
در پژوهش‌هایی که تاکنون در زمینه هیدرولوژیکی با استفاده از شبکه عصبی موجک صورت گرفته از ترکیب تبدیل موجک و شبکه عصبی مصنوعی مطالعات گسترده تری انجام شده است. لذا، استفاده از مدل شبکه عصبی موجک با استفاده از توابع موجک در لایه پنهان روش جدیدی به شمار می‌آید. بنابراین در این پژوهش با استفاده از مدل شبکه عصبی موجک، اقدام به پیش بینی دبی رودخانه بادآور شهرستان نورآباد واقع در استان لرستان و مقایسه آن با مدل شبکه عصبی مصنوعی شده است که افزایش دقت پیش بینی مدل جدید مشخص شود.

## مواد و روش‌ها

### منطقه مورد مطالعه

منطقه مورد مطالعه شهرستان نورآباد واقع در استان لرستان می‌باشد. این منطقه بین طول‌های "۴۸' ۴۴" شرقی و عرض‌های "۱۲' ۵۸" ۴۷" شمالی واقع شده است. محدوده مطالعاتی نورآباد دارای ۸۱۱ کیلومتر مربع مساحت است که از این مقدار ۱۵۹ کیلومتر مربع دشت با ارتفاع متوسط ۱۶۲۰ متر و ۶۵۲ کیلومتر مربع با ارتفاع متوسط ۲۲۴۰ متر می‌باشد. این دشت دارای یک سفره زیرزمینی آبرفتی می‌باشد و دارای وضعیت آب سطحی و زیرزمینی نسبتاً خوبی است. در شکل (۱) موقعیت ایستگاه مطالعاتی بادآور نورآباد با طول جغرافیایی "۵۶' ۳۴" و عرض جغرافیایی "۱۹' ۵۸" ۴۷" با مساحتی بالغ بر ۶۱۵ کیلومتر مربع نشان داده شده است. بدین منظور برای مدل‌سازی از پارامترهای بارش  $P(t-1)$ ،  $P(t)$ ،  $P(t-2)$ ،  $P(t-3)$  و  $P(t-4)$  (به ترتیب حداکثر بارش روزانه در یک تا چهار روز قبل) به عنوان ورودی و  $Q(t)$  (حداکثر دبی روزانه در زمان  $t$ ) به عنوان خروجی مدل‌ها در طی سال آماری ۱۳۸۱-۱۳۹۱ برای دشت نورآباد لرستان به کار برده شد.

دادند مدل شبکه عصبی پیش‌بینی بهتری نسبت به روش رگرسیونی از سیلاب رودخانه‌ی سرباز ارایه می‌دهد. Najafi et al (2014) به شبیه‌سازی دبی حداکثر لحظه‌ای در ایستگاه‌های هیدرومتری هفت حوض، سولقان، قلاک و مقصودییک در کلان‌شهر تهران با استفاده از شبکه عصبی مصنوعی پرداختند و نشان دادند در همه ایستگاه‌های مورد بررسی، استفاده از شبکه عصبی مصنوعی برای شبیه‌سازی دبی‌های حداکثر لحظه‌ای با استفاده از داده‌های دبی حداکثر روزانه و ماهانه از کارایی بالایی برخوردار است. Noury و Rahnama (2008) برای پیش‌بینی جریان حوضه رودخانه هلیل از داده‌های روزانه بارندگی و رواناب به منظور آموزش مدل هیبریدی عصبی موجکی و عصبی مصنوعی استفاده نمودند نتایج نشان داد که مدل هیبریدی به طور معنی‌داری توانایی پیش‌بینی جریان روزانه رودخانه هلیل را افزایش می‌دهد. Okkan (2012) مدل شبکه عصبی موجکی برای پیش‌بینی جریان ورودی به مخزن سد کمیر در ترکیه مورد بررسی قرار داده و برای پیش‌بینی جریان ورودی مخزن سد از مقیاس زمانی ماهانه با ترکیب موجک گسسته و بهینه‌سازی الگوریتم‌های مبتنی بر لوبنرگ - مارکوارت استفاده نمود. نتایج حاصله نشان داد شبکه عصبی موجکی یک مدل مناسب برای پیش‌بینی جریان ورودی به مخزن سد بوده و می‌تواند نسبت به مدل رگرسیون چندگانه عملکرد قابل‌قبولی داشته باشد. Krishna et al (2011) به پیش‌بینی دبی روزانه رودخانه مالاراپها هند با استفاده از شبکه عصبی موجک پرداختند و به این نتیجه رسیدند که مدل شبکه عصبی موجک نسبت به شبکه عصبی مصنوعی و مدل‌های خود همبسته AR از عملکرد بهتری برخوردار است. نتایج حاصل Elsafi (2014) در مورد پیش‌بینی سیل در ایستگاه دانگلا سودان با استفاده از شبکه عصبی مصنوعی، نشان داد شبکه عصبی مصنوعی مدلی مناسب و قابل‌اعتماد برای پیش‌بینی دبی سیل است. Aichouri et al (2015) دقت مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره را در پیش‌بینی جریان ایستگاه میربک الجزایر مورد بررسی قرار دادند و نتایج بر اساس معیار ضریب تعیین نشان داد، مدل شبکه عصبی مصنوعی عملکرد بهتری در مقایسه با رگرسیون خطی چند متغیره داشته است. Kasiviswanathana et al (2016) کارایی شبکه عصبی موجک را برای پیش‌بینی دبی روزانه رودخانه آلبرتا در کانادا مورد بررسی قرار دادند که نتایج نشان داد مدل شبکه عصبی موجک خطایی ناچیز در تخمین دبی داشته و نیز نسبت به روش شبکه عصبی مصنوعی در تخمین اکثر مقادیر دقت بالایی دارد. در مجموع با توجه به پژوهش‌های انجام‌شده و ذکر این نکته که دشت نورآباد به عنوان مهم‌ترین منبع تأمین‌کننده آب بخش‌های مختلف و نواحی مجاور خود می‌باشد. و نیز از جمله منابع تأمین‌کننده محصولات کشاورزی استان لرستان می‌باشد، بنابراین اهمیت تخمین دبی روزانه و اقدامات مدیریتی برای جلوگیری خشک‌سالی ضروری است. ، از اینرو مدل‌سازی دقیق دمای



شکل ۱- موقعیت ایستگاه مورد مطالعه  
Fig. 1- Location of the station under study

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته‌ی تابع  $f(t)$  به صورت روابط (۱) و (۲) تعریف می‌شود (Vapnik, 1988).

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

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

رابطه‌ی (۲) یک رابطه با دو متغیر  $s$  و  $\tau$  است که  $s$  پارامتر مقیاس (عکس فرکانس) و  $\tau$  پارامتر انتقال می‌باشند. علامت \* نیز نشان‌دهنده‌ی مزدوج مختلط است.  $\psi$  تابع پنجره یا موجک مادر و  $\frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right)$  موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند (Wang et al, 2000). واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان‌دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است.

#### الگوریتم ویولت

تلفیق تئوری موجک با مفاهیم شبکه عصبی منجر به ایجاد شبکه عصبی موجک می‌گردد و به کارگیری آن می‌تواند جایگزین مناسبی در شبکه‌های عصبی پیش‌خور برای تخمین و تقریب توابع غیرخطی اختیاری باشد. در شبکه‌های عصبی پیش‌خور، دارای تابع فعال‌سازی سیگموئید در لایه پنهان می‌باشد درحالی‌که در شبکه‌های عصبی موجک، توابع موجک به‌عنوان تابع فعال‌سازی


#### شبکه عصبی موجک

تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه‌ی زمان کوتاه ارایه شده است و هدف از ارایه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه‌ی زمان کوتاه، سیگنال موردنظر به پنجره‌هایی تقسیم‌شده و تبدیل موجک بر روی هر کدام از این پنجره‌ها به‌صورت جداگانه انجام می‌گیرد (Vapnik, 1988). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به‌عبارت‌دیگر، در تبدیل موجک به‌جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان - مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط‌شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض‌شده و کلیات سیگنال قابل بررسی می‌باشد (Wang et al, 2000). یک موجک به معنای موج کوچک، بخشی یا پنجره‌ای از سیگنال اصلی است که انرژی آن در زمان متمرکز شده است. 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. بنابراین موجک‌ها نمونه‌های انتقال یافته و مقیاس شده‌ی سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانا و گذرا را به‌صورت موضعی مورد تجزیه و تحلیل قرارداد (Shin et al, 2005). تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.


**شبکه عصبی مصنوعی**

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani et al, 2009). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا با ساختار شبکه پیش‌خور و تعداد سه لایه به‌طور رضایت‌بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al, 2011). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌تواند توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (Tokar and Johnson, 1999). نمونه ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل (۳) نشان داده شده است.

لایه پنهان شبکه پیش‌خور در نظر گرفته می‌شوند در این شبکه‌ها هر دو پارامتر انتقال و تغییر مقیاس موجک‌ها در کنار وزن‌هایشان بهینه می‌گردند. در مجموع گام‌های مهم در آموزش و صحت سنجی شبکه عصبی موجک به‌صورت زیر است.  
 الف- داده‌های ورودی به دو دسته برای آموزش شبکه و صحت سنجی مورداستفاده قرار می‌گیرند.  
 ب- موجک مادر با اعزاز شرایط یادشده پس از اعمال ضرایب انتقال و مقیاس مناسب به موجک دختر تبدیل می‌شود.  
 ج- توابع فعال‌سازی نرون‌های لایه پنهان شبکه عصبی با انواع موجک‌های فرزند جایگزین می‌شود.  
 د- شبکه عصبی ویولت ایجادشده با استفاده از مجموعه داده‌های مربوط به آموزش شبکه، آموزش داده می‌شود.  
 ه- عملکرد کلی شبکه موجک با تجزیه و تحلیل روش تخمین داده‌های صحت سنجی موردبررسی قرار می‌گیرد. و با رضایت‌بخش بودن عملکرد شبکه مرحله آموزش به اتمام می‌رسد. در غیر اینصورت مراحل قبل تا دستیابی به بهترین حالت مورد ارزیابی قرار می‌گیرد (Kaveh and Iranmanesh, 2004). نمونه ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل (۲) نشان داده شده است.



**Fig. 2- View of a triangular wavelet neural network**  
 شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای



**Fig. 3- General view of a three-layer artificial neural network**  
 شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

## معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب تبیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) طبق روابط زیر استفاده گردید (Ghorbani and Dehghani, 2016). بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر می‌باشد.

$$R^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (4)$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad (5)$$

در روابط بالا،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $i$ ،  $N$  تعداد گام‌های زمانی،  $\bar{x}$  و  $\bar{y}$  نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز برای تحلیل بیشتر نتایج استفاده شده است.

## نتایج و بحث

یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. از این رو ابتدا تبیین متقابل بین متغیرهای ورودی و خروجی محاسبه گردید و پارامترهای ورودی به منظور دستیابی به مدل بهینه برای تخمین میزان دبی روزانه ایستگاه نورآباد انتخاب و در جدول (۱) ارائه شد.

در این جدول  $P(t)$ ،  $P(t-1)$ ،  $P(t-2)$ ،  $P(t-3)$  و  $P(t-4)$  (به ترتیب حداکثر بارش روزانه در یک تا چهار روز قبل) به عنوان ورودی و  $Q(t)$  (حداکثر دبی روزانه در زمان  $t$ ) به عنوان خروجی مدل در نظر گرفته شد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آن‌ها در طبیعت کاری دشوار با عدم قطعیت بالا است. جریان روزانه از پارامترهای مهم هیدرولوژی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در برای کاهش خطا و همچنین برآورد پارامتر جریان روزانه با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکر شده مورداستفاده قرار گرفت که در مقایسه با روش‌های تقریبی به مراتب عملکرد بهتری را ارائه خواهد داد. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هیدرولوژیکی برای پیش‌بینی در آینده است و از آنجایی که دبی روزانه از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر به عنوان متغیر هدف انتخاب شد. با توجه به تبیین متقابل و معنی‌دار بین داده‌های ورودی و

خروجی، ترکیب‌های مختلفی از پارامترهای ورودی به منظور دستیابی به مدل بهینه برای تخمین دبی روزانه استفاده شد که در جدول (۲) آمده است. بدین منظور از داده‌های ایستگاه هیدرومتری و باران‌سنجی بادآور واقع در دشت نورآباد که دارای ۳۶۵۰ رکورد ثبت‌شده طی بازه زمانی (۱۳۸۱-۱۳۹۱)، در مقیاس زمانی روزانه می‌باشد، استفاده شد. همچنین در جدول (۳) خصوصیات آماری پارامترهای استفاده‌شده در هر دو مدل، مشاهده می‌شود. لازم به ذکر است برای مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده برای تست، به صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (Kisi et al, 2006 و Nagy et al, 2002). در ادامه نتایج مدل مورداستفاده ارائه می‌گردد. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (Zhu et al, 2007). برای نرمال‌سازی داده‌های تحقیق از رابطه زیر استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (6)$$

که در آن  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{\max}$  و  $X_{\min}$  به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

## نتایج شبکه عصبی موجک

به منظور مدل‌سازی دبی روزانه ایستگاه نورآباد از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی، ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آن‌ها استخراج گردید و داده‌ها به وسیله تابع موجک کلاسه مکزیکی به عنوان توابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. برای آموزش شبکه از الگوریتم گرادیان نزولی که در یادگیری شبکه‌های عصبی و حداقل‌سازی مقدار خطای و تنظیم پارامترهای شبکه استفاده می‌شود، بکار گرفته شد. همان‌طور که در جدول (۴) مشاهده می‌شود ساختار شماره ۵ با ضریب تبیین ۰/۹۲۰ و کمترین ریشه میانگین مربعات خطا ۰/۰۰۵ متر و کمترین میانگین قدر مطلق خطا ۰/۰۰۳ متر در مرحله صحت‌سنجی نسبت به سایر ساختارها برای مدل‌سازی دبی روزانه در مقیاس زمانی روزانه مناسب‌تر خواهد بود. در شکل (۴) نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است. همان‌طور که مشاهده می‌شود مدل شبکه عصبی موجکی در تخمین اکثر مقادیر عملکرد قابل قبولی داشته بگونه‌ای که در تخمین اکثر مقادیر کمینه و بیشینه عملکرد خوبی از خود نشان داده است.

جدول ۱- تبیین متقابل بین پارامترهای ورودی و خروجی

Table 1- Interpretation between input and output parameters

	P(t)	P(t-1)	P(t-2)	P(t-3)	P(t-4)
Q(t)	0.400	0.320	0.250	0.100	0.100

جدول ۲- ترکیب‌های منتخب پارامترهای ورودی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

Table 2- Selected Combinations of Input Parameters of Wavelet Neural Network Models and Artificial Neural Network

Number	Input	Output
1	P(t)	Q(t)
2	P(t),P(t-1)	Q(t)
3	P(t),P(t-1),P(t-2)	Q(t)
4	P(t),P(t-1),P(t-2),P(t-3)	Q(t)
5	P(t),P(t-1),P(t-2),P(t-3),P(t-4)	Q(t)

جدول ۳- محدوده پارامترهای مورداستفاده در مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

Table 3- Range of parameters used in wavelet network and artificial neural network models

Parameter	Minimum	Mean	Maximum	Standard deviation	Skidding
P(t),mm	0	1.618	77.500	8.804	5.614
Q(t), m3/s	0.038	1.958	50.200	2.792	7.419

جدول ۴- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی موجک و شاخص‌های آماری در مراحل آموزش و

صحت سنجی

Table 4- Optimal stimulus structure and functions in modeling of wavelet neural networks and statistical indices in training and verification phases.

Number	Structure	Function	Training			Testing		
			R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)	R <sup>2</sup> (m <sup>3</sup> /s)	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)
1	1-5-1	Mexican hat	0.837	0.031	0.015	0.821	0.031	0.017
2	2-7-1	Mexican hat	0.856	0.023	0.011	0.847	0.020	0.012
3	3-4-1	Mexican hat	0.870	0.012	0.006	0.864	0.015	0.009
4	4-6-1	Mexican hat	0.901	0.007	0.004	0.882	0.009	0.005
5	5-8-1	Mexican hat	0.941	0.003	0.002	0.920	0.005	0.003

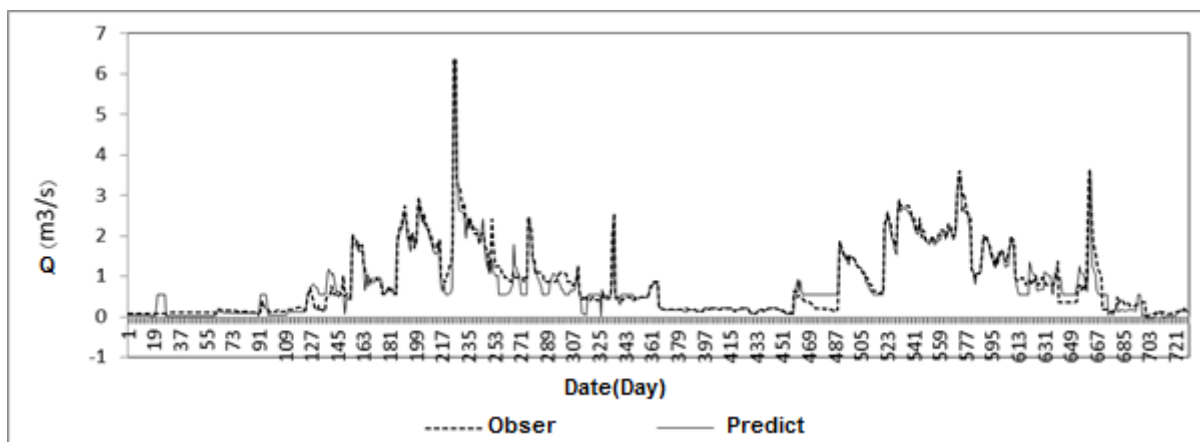


Figure 4- Graph of calculated and observational values relative to the time of the wavelet neural network model for the training and verification stage data

شکل ۴- نمودار حاصل از مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه عصبی موجک برای داده‌های مرحله آموزش و صحت سنجی



## نتایج شبکه عصبی مصنوعی

مقایسه عملکرد ساختارهای مختلف به کاررفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت سنجی ارائه شده است. همان‌طور که در جدول (۵) مشاهده می‌شود ساختار شماره ۵ با بیشترین ضریب تبیین  $0/۸۹۰$  و کمترین ریشه میانگین مربعات خطا  $0/۰۰۶$  متر و کمترین میانگین قدر مطلق خطا  $0/۰۰۳$  متر در مرحله صحت سنجی نسبت به سایر ساختارها برای مدل‌سازی دبی حداکثر روزانه مناسب‌تر خواهد بود. در شکل (۵) نمودار مقادیر مشاهداتی و محاسباتی و نمودار پراکنش نشان داده شده است همان‌طور که در شکل (۵) مشخص است تطابق مقادیر محاسباتی دبی حداکثر روزانه مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی در برخی نقاط وجود دارد. به گونه‌ای که در شکل (۵) این امر مشهود است که مدل مذکور در تخمین نقاط بیشینه و کمینه ضعیف عمل کرده است که این نقاط را نزدیک به مقداری واقعی‌شان تخمین زده است. این نتایج با نتایج پژوهش Abasi et al (2011) مطابقت دارد در تبیین این نتایج می‌توان بیان نمود با توجه به ساختار شبکه‌های عصبی مصنوعی، ویژگی عمده آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است.

همچنین برای مقایسه نتایج شبکه عصبی مویک به منظور مدل‌سازی دبی روزانه دشت نورآباد واقع در استان لرستان از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونبرگ - مارکواریت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه  $۱۰۰۰$  در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص شده، حال آنکه تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در برای کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشد، که شبکه‌ای با ۵ نرون در لایه پنهان اول به عنوان بهترین شبکه در فرآیند مدل‌سازی حاصل شد. در جدول (۵) نتایج حاصل از

جدول ۵- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و

## صحت سنجی

Table 5- Optimal structure and functions in artificial neural networks modeling and statistical indices in educational and verification phases.

Number	Structure	Function	Training			Testing		
			R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)	R <sup>2</sup>	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)
1	1-7-1	hyperbolic tangent	0.821	0.033	0.016	0.817	0.034	0.017
2	2-6-1	hyperbolic tangent	0.848	0.024	0.013	0.836	0.025	0.012
3	3-8-1	hyperbolic tangent	0.867	0.015	0.007	0.853	0.018	0.009
4	4-9-1	hyperbolic tangent	0.890	0.008	0.005	0.875	0.011	0.005
5	5-5-1	hyperbolic tangent	0.910	0.005	0.003	0.890	0.006	0.003

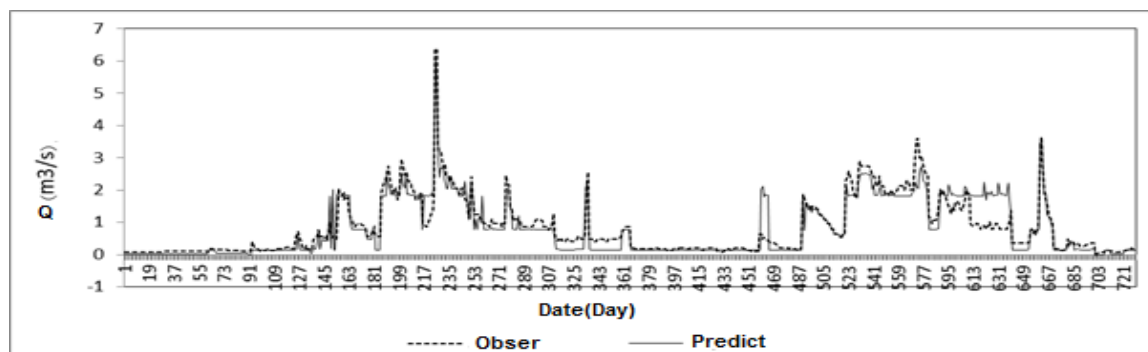


Figure 5- Graph of calculated and observational values relative to the time of artificial neural network model for the data of the training stage and verification

شکل ۵- نمودار حاصل از مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه عصبی مصنوعی برای داده‌های مرحله آموزش و صحت سنجی

## مقایسه عملکرد مدل‌ها

در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می‌توانند دبی روزانه را شبیه‌سازی کنند. که از بین مدل‌های به کاررفته مدل شبکه عصبی موجک، بیشترین دقت  $R=0.920$  و کمترین ریشه میانگین مربعات خطا  $RMSE=0.005$  m و کمترین میانگین قدر مطلق خطا  $MAE=0.003$  در مرحله صحت سنجی را دارد. همان‌طور که در شکل (۶) نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است مدل شبکه عصبی موجک در تخمین اکثر مقادیر عملکرد قابل قبولی دارد به گونه‌ای که کلیه مقادیر را نزدیک به مقدار واقعی تخمین زده است. و همچنین نتایج حاکی از برتری کامل مدل پیش‌بینی شبکه عصبی-موجکی نسبت به مدل شبکه عصبی در پیش‌بینی دبی روزانه می‌باشد. با اینکه مدل ANN به خاطر در اختیار داشتن کرنل غیرخطی توانایی مدل‌سازی رفتارهای غیرخطی را داراست، ولی با

توجه به ویژگی‌های نا ایستائی و غیرخطی بودن سری جریان حداکثر روزانه، به‌منظور پیش‌بینی و شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی- موجکی می‌باشیم. چراکه شبکه عصبی به تنهایی قادر به غلبه بر نا ایستائی سیگنال نمی‌باشد. درحالی‌که تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. همچنین این نتایج با پژوهش‌های Rostami et al (2016) Kasiviswanathana et al (2011) و Marofi et al (2011) همخوانی دارد در تبیین این نتایج می‌تواند بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی، بالا می‌برد. سیگنال‌های بالا گذر و پائین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد.

## جدول ۶- نتایج نهایی حاصل از آموزش و صحت سنجی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

Table 6 - Final results of training and verification of wavelet neural network and artificial neural network models

Model	Training			Testing		
	R2	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)	R2	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)
Wavelet Neural network	0.941	0.003	0.002	0.920	0.005	0.003
Artificial Neural Network	0.910	0.005	0.003	0.890	0.006	0.003

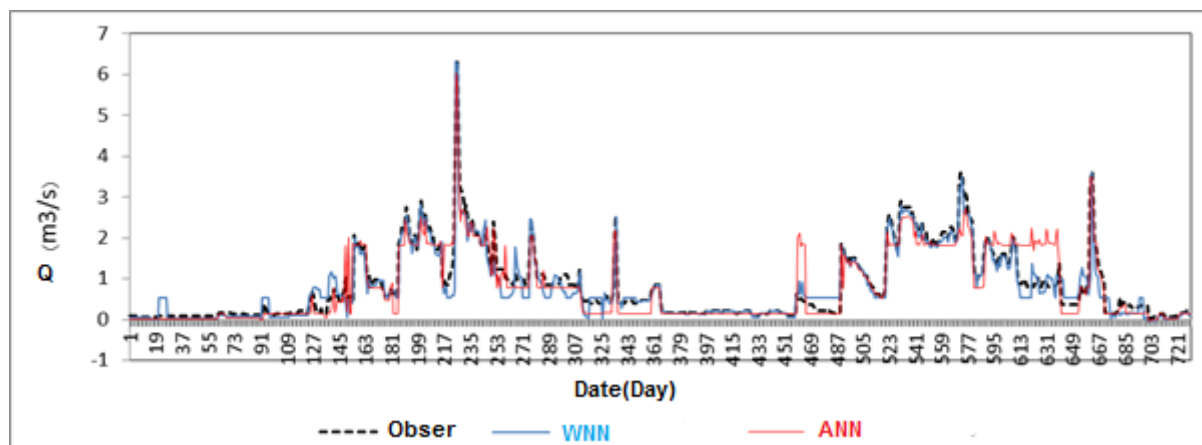


Fig 6- Distribution and observational diagrams - Calculations of optimal values of wavelet neural network model and artificial neural network for recorded data. Training and verification stage.

شکل ۶- نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه عصبی موجک و شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله آموزش و صحت سنجی

### نتیجه گیری

پرهزینه و زمان بر هستند، می باشد. همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده تر شدن این سیگنال ها شده و باعث ایجاد برتری محسوس نسبت به مدل شبکه عصبی مصنوعی می باشد. در مجموع این تحقیق نشان می دهد استفاده از مدل شبکه عصبی موجک می تواند در زمینه تخمین دبی روزانه مؤثر باشد. و همچنین این مدل می تواند در نوبه خود برای تسهیل توسعه و پیاده سازی استراتژی های مدیریت منابع آب مفید باشد.

### تقدیر و تشکر

نویسندگان مقاله از شرکت آب منطقه ای استان لرستان قدردانی می نمایند زیرا مساعدت لازم را در ارائه آمار و اطلاعات این پژوهش عنایت نمودند.

در پژوهش حاضر عملکرد مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی را برای مدل سازی دبی حداکثر روزانه ایستگاه نورآباد واقع در استان لرستان با استفاده از پارامترهای بارش طی تأخیرهای متفاوت، در طی دوره آماری (۱۳۸۱-۱۳۹۱) مورد ارزیابی قرار گرفت. مقادیر دبی روزانه مشاهداتی با دبی روزانه تخمین زده شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج تحقیق نشان داد که مدل شبکه عصبی موجک دقت بالا و خطای ناچیز در تخمین دبی روزانه و قابلیت بسیار بالایی در تخمین برخی مقادیر کمینه، بیشینه و میانی نسبت به شبکه عصبی مصنوعی دارد. که با نتایج تحقیق et al Kasiviswanathana (2016) و Okkan (2012) و Marofi et al (2011) مطابقت دارد در تبیین این نتایج می توان بیان نمود شبکه عصبی موجک قادر به پیش بینی دبی سیلاب در حجم بالا، که احتیاج به اندازه گیری و کارهای آزمایشگاهی آنها

### References

- 1- Abasi, S.M., Orimi, M., Hosseini, A., Sharifi, M.B., 2011. Investigating the capability of cprecip parameter for estimating snow effect on daily river flow prediction by neural network and fuzzy neural network. *Journal of Irrigation Sciences and Engineering*, 35(1), pp.83-92 (In Persian).
- 2- Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H., Lallahem, S., 2015. River Flow Model Using Artificial Neural Networks. *Energy Procedia*, 74(2), pp.1007-1014.
- 3- Elsafi, H., 2014. Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan. *Alexandria Engineering Journal*, 53(2), pp. 655-662.
- 4- Ghorbani, M.A., Dehghani, R., 2016. Application of baysian neural networks, support vector machine and gene expression programming in rainfall-monthly runoff analysis (case study: kakarza river). *Journal of Irrigation Sciences and Engineering*, 39(2), pp.125-138 (In Persian).
- 5- Kasiviswanathana, K.S., Jianxun, H., Sudheer, K.P., Joo-Hwa, T., 2016. Potential application of wavelet neural network ensemble to forecast streamflow for flood management. *Journal of Hydrology*, 536(4), pp. 161-173.
- 6- Kaveh, A., Iranmanesh, A., 2004. Artificial neural network in optimizing structures. *Third Book. Publication of Building and Housing Research Center*. (In Persian).
- 7- Kisi, O., Karahan, M., and Sen, Z., 2006. River suspended sediment modeling using fuzzy logic approach. *Hydrological Process*. 20(2), pp. 4351-4362.
- 8- Khosravi, M., Salajegheh, A., Mahdavi, M., Saroy, M., 2011. Flood prediction using artificial neural network and nonlinear multivariate regression (case study: taleghan). *Pasture and Watershed Journal*, 65(3), pp.341-349 (In Persian).
- 9- Krishna, B., Satyaji Rao, Y.R., Nayak, P.C., 2011. Time Series Modeling of River Flow Using Wavelet Neural Networks. *Journal of Water Resource and Protection*, 3(3), pp. 350-59.
- 10- Marofi, S., Amirmoradi, K., Parsafar, N., 2011. Daily flow prediction using artificial neural network and wavelet neural network (case study: barandozchay river), *Journal of Water and Soil Science*, 33(3), pp.93-103 (In Persian).

- 11-Najafi, A., Safari, A., Ghanavati, A., Karam, A., 2014. Simulation and analysis of maximum instantaneous discharges using artificial neural network (case study: hydrometric stations, Sulaghan, Golak, and Maghdebik stations in Tehran metropolis). *Journal of Quantitative Geomorphology Research*, 4(1), pp. 90-103 (In Persian).
- 12-Nagy, H., Watanabe, K., and Hirano, M., 2002. Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulic Engineering*. 128(3),pp. 558-559.
- 13-Negareh, H., Moghadam, M., Armesh, M., 2012. Application of artificial neural network in simulation and prediction of flood in sarbaz watershed. *Geography and Development*, 11(31), pp. 15-28 (In Persian).
- 14-Nourani, V., Alami, M.T., Aminfar, M.H., 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(3), pp. 466–472.
- 15-Nourani, V., Kisi, Ö., Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall–runoff process. *Journal of Hydrology*, 402(3), pp. 41–59.
- 16-Okkan, U., 2012. Wavelet neural network model for reservoir inflow prediction . *Journal of Scientia Iranica*.December, 19(1), pp.1445–1455.
- 17-Panahi, A., Alikhani, B., 2012. Daily flare flow prediction using artificial neural network model and multivariate regression (case study: madarsow basin of golestan province). *Geography Journal*, 11(38), pp.113-132 (In Persian).
- 18-Rahnama, M.B., Noury, M., 2008. Developing of Halil River Rainfall-Runoff Model, Using Conjunction of Wavelet Transform and Artifical Neural Networks . *Research Journal of Environmental Sciences*, 2(5), pp. 385-392.
- 19-Rostami, M., Fakherifard, A., Ghorbani, M.A., Darbandi, S., Dinpajoh, Y., 2011. River flow forecasting using wavelet analysis. *Journal of Irrigation Science and Engineering*,35(2), pp.73-81 (In Persian).
- 20-Shin, S., Kyung, D., Lee, S., Taik & Kim, J., Hyun, J., 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(4), pp.127-135.
- 21-Tokar , A., Johnson, P., 1999. Rainfall-Runoff Modeling Using Artificial Neural Networks. *Journal of Hydrologic Engineering*, 4(2), pp. 232-239.
- 22-Vapnik, V.N., 1988. Statistical Learning Theory. *John Wiley, New York*.
- 23-Wang, D., Safavi, A.A., Romagnoli, J.A., 2000. Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*, 46(4), pp. 1607-1615.
- 24-Zhu, Y.M., Lu, X.X., Zhou, Y., 2007. Suspended sediment flux modeling with artificial neural network: An example of the longchuanjian river in the upper yangtze catchment. *Geomorphology*, 84(1), pp. 111-125.