

## پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی - موجکی (مطالعه موردی: رودخانه باراندوزچای)

صفر معروفی<sup>1\*</sup>، کیمیا امیرمراذی<sup>2</sup> و نصرالدین پارسافر<sup>3</sup>

تاریخ دریافت: 91/10/16 تاریخ پذیرش: 91/12/02

<sup>1</sup> - استادا، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا

<sup>2</sup> - دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا

<sup>3</sup> - دانشجوی دکتری، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا

\* مسئول مکاتبات، پست الکترونیکی: [marofi@basu.ac.ir](mailto:marofi@basu.ac.ir)

### چکیده

پیش‌بینی دقیق جریان در رودخانه‌ها یکی از مهمترین ارکان در مدیریت منابع آبهای سطحی به ویژه جهت اتخاذ تدابیر مناسب در مواقع سیلاب و بروز خشکسالی‌ها است. به دلیل اهمیت پیش‌بینی جریان رودخانه، در این تحقیق جریان روزانه رودخانه‌ی باراندوزچای در دو ایستگاه بی‌بکران و دیزج طی یک دوره‌ی آماری 20 ساله با استفاده از مدل عصبی - موجکی (WNN) که تلفیق آنالیز موجک و شبکه عصبی مصنوعی (ANN) می‌باشد، پیش‌بینی گردید. سپس نتایج حاصله از مدل WNN با مدل ANN مقایسه گردید. داده‌های مربوط به سال‌های 1384-1369 به منظور آموزش شبکه‌ها و داده‌های سال‌های 1388-1385 نیز جهت صحت‌سنجی شبکه‌ها استفاده گردیدند. عملکرد این دو مدل توسط شاخص‌های آماری ضریب همبستگی ( $r$ )، ریشه مربع میانگین خطا (RMSE) و میانگین قدر مطلق خطا (MAE) ارزیابی گردید. نتایج این پژوهش نشان داد که مدل WNN با ضرایب همبستگی 0/972 و 0/976 که به ترتیب مربوط به ایستگاه‌های بی‌بکران و دیزج می‌باشند، توانایی بیشتری در پیش‌بینی جریان روزانه رودخانه نسبت به مدل ANN دارد. بنابراین، نتایج حاکی از کارایی مناسب و دقت بالای مدل عصبی - موجکی در مقایسه با شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه است.

واژه‌های کلیدی: جریان روزانه، رودخانه باراندوزچای، شبکه عصبی مصنوعی، مدل عصبی - موجکی.

## River flow prediction using Artificial Neural Network and Wavelet Neural Network models (Case study: Barandozchay River)

S Marofi<sup>1\*</sup>, K Amir Moradi<sup>2</sup> and N Parsafar<sup>3</sup>

Received: 5 January 2013 Accepted: 20 February 2012

<sup>1</sup>- Prof., Dept. of Water Eng., Faculty of Agric., Bu-Ali Sina Univ., Hamedan, Iran

<sup>2</sup>- M.Sc. Student, Dept of Water Eng., Faculty of Agric, Bu-Ali Sina Univ., Hamedan, Iran

<sup>3</sup>- Ph.D. Student, Dept. of Water Eng., Faculty of Agric., Bu-Ali Sina Univ., Hamedan, Iran

\* Corresponding Author Email: [marofi@basu.ac.ir](mailto:marofi@basu.ac.ir)

### Abstract

Accurate forecasting of river flow is one of the most important factors in surface water resources management especially during flood and drought periods. Because of the importance of river flow forecasting, in this study, daily flow of Barandozchay river in two stations (Bibakran and Dizaj) for a period of 20 years using Wavelet Neural Network (WNN) which is a combination of wavelet analysis and Artificial Neural Network (ANN) has been predicted. The results of ANN model have been compared with WNN model. Data of the years 1990-2005 and 2006-2009 were used for training and verification of the networks, respectively. The performance of the two models was evaluated by statistics: r, RMSE and MAE. The results showed that the WNN model with a correlation coefficient of 0.972 and 0.976 (for stations of Dizaj and Bibkran, respectively) was able to forecast daily river flows better than the ANN model. Therefore, the results indicated that the proposed WNN method performed quite well compared to Artificial Neural Network method and could be applicable for river flow forecasting.

**Keywords:** Artificial neural networks, Barandozchay river, Daily flow, Wavelet neural network

آماري<sup>1</sup> طبقه‌بندی کرد. مدل‌های آماری کاربردی‌تر از مدل‌های مفهومی می‌باشند. زیرا درک ساختار داخلی آنها از فرآیندهای فیزیکی مدل‌سازی مستقل است. در طی چهار دهه گذشته مدل‌های سری زمانی کاربرد گسترده‌ای در پیش‌بینی جریان رودخانه پیدا کرده‌اند (الشفیق و همکاران 2007).

مقدمه

جهت طراحی بهینه و قابل اعتماد سیستم‌هایی مانند مخازن سدها و برنامه‌ریزی کارآمد در مدیریت منابع آب، تخمین صحیح آبدهی رودخانه اهمیت زیادی دارد (سیواکومار و همکاران 2002). به منظور پیش‌بینی جریان رودخانه در طی سالیان گذشته روش‌های مختلفی ابداع شده است، که به‌طور کلی می‌توان به دو دسته مدل‌های مفهومی و مدل‌های مبتنی بر داده یا

<sup>1</sup> Data- driven method

حاصله از شبکه MLP را کاهش می‌دهد، ولی استفاده از تاخیر زمانی دبی باعث افزایش عملکرد شبکه مذکور می‌گردد.

اکبرپور و همکاران (1385) جهت پیش‌بینی جریان ورودی به مخزن سد دز از الگوریتم شبکه عصبی MLP استفاده نمودند. نتایج مطالعه حاکی از عملکرد مطلوب MLP در پیش‌بینی متغیر مذکور بود. ساتیاجی راو و کریشنا (2009) در شبه‌جزیره هند به مقایسه عملکرد شبکه‌های عصبی مصنوعی و عصبی-موجکی در پیش‌بینی دبی رودخانه و سطح آب زیرزمینی پرداختند. نتایج مطالعات ایشان نشان‌دهنده دقت بالای شبکه عصبی-موجکی نسبت به شبکه عصبی مصنوعی می‌باشد. نوری و همکاران (1388) جهت پیش‌بینی دبی رودخانه صوفی‌چای در ارومیه از سه مدل ANN، PCA-ANN و WNN استفاده نمودند. نتایج بیانگر آن است که مدل PCA-ANN از ساختاری ساده‌تر، سرعت آموزش بیشتر و دقت بیشتری نسبت به دو مدل دیگر برخوردار می‌باشد.

هدف از این پژوهش مقایسه عملکرد شبکه عصبی-موجکی در شبیه‌سازی دبی روزانه رودخانه باراندوزچای ارومیه با استفاده از تاخیرهای زمانی دبی با شبکه عصبی مصنوعی می‌باشد. بدین منظور فرض گردید که تاخیر زمانی دبی به عنوان ورودی به شبکه‌های مذکور، نتایج بهتر با ساختاری ساده‌تر ارائه می‌دهد.

#### مواد و روش‌ها

شبکه عصبی مصنوعی پرسپترون چند لایه: شبکه‌های عصبی مصنوعی در حقیقت مدل ساده شده-ای از سیستم عصبی مرکزی می‌باشند و کارکردی شبیه به مغز انسان دارند. مغز به عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به نام

در سال‌های اخیر مدل‌های غیرخطی مانند شبکه عصبی مصنوعی (ANN)<sup>1</sup> به طور گسترده‌ای برای مدل‌سازی سری زمانی استفاده گردیده‌اند. در این راستا شبکه‌های عصبی مصنوعی برای غلبه بر مشکلات موجود در مدل‌سازی سری‌زمانی متغیرهای هیدرولوژیکی استفاده شده‌اند (Anonymouse, 2000 a و b). همچنین در برخی مطالعات گزارش شده که مدل ANN از دقت بسیار زیادی برخوردار نیست. زیرا این مدل‌ها فقط برخی از رفتار سری زمانی را شامل می‌شوند (ونشینگ و جینگ 2003). لذا به منظور رفع این مشکل، از آنالیز موجک<sup>2</sup> همراه با شبکه‌های عصبی استفاده شده است. اساس روش موجک این است که یک فرآیند ریاضی را جهت تجزیه یک سیگنال به سطوح مختلفی از جزئیات و آنالیز آماده می‌کند. در سال‌های اخیر نظریه-ی موجک در زمینه هیدرولوژی مورد استفاده قرار گرفته است (اسمیت و همکاران 1998، لابات و همکاران 2000). شباهت بین تجزیه موجک و شبکه‌های عصبی موجب پیدایش ترکیب موجک و شبکه‌های عصبی به نام شبکه عصبی-موجکی (WNN)<sup>3</sup> در زمینه‌های مختلف شده است.

از جمله تحقیقات انجام شده در رابطه با پیش-بینی جریان رودخانه، می‌توان به مطالعه آنکتیل و رات (2005) در پیش‌بینی جریان رودخانه در 47 حوضه در فرانسه و ایالات متحده با استفاده از الگوریتم شبکه عصبی پرسپترون چند لایه (MLP)<sup>4</sup> اشاره کرد. نتایج نشان می‌دهد که پیش‌بینی دبی رودخانه با استفاده از شبکه عصبی پرسپترون چند لایه ساده که بردارهای ورودی آن صرفاً شامل آخرین دبی ثبت شده و مقدار بارش مشاهده شده باشد، عملکرد مطلوبی خواهد داشت. این در حالی است که استفاده از تبخیر- تعرق پتانسیل به عنوان ورودی در اکثر موارد دقت پیش‌بینی

<sup>1</sup> Artificial Neural Network

<sup>2</sup> Wavelet

<sup>3</sup> Wavelet Neural Network

<sup>4</sup> Multi-Layer Perceptron

باشد ارائه می‌دهند. شکل 2 (الف) یک نمونه‌ی موجک است که به نام موجک مورلت معروف است. عبارت موجک به معنای موج کوچک می‌باشد که دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است که شرط مقبولیت<sup>3</sup> نامیده می‌شود و به شکل رابطه 6 بیان می‌شود:

$$\int j(t) dt = 0 \quad [6]$$

که در آن  $j(t)$  تابع تبدیل موجک (موجک مادر) می‌باشد. عبارت مادر به این دلیل به کار رفته است که توابع (موجک‌های) متفاوت به وجود آمده بر اساس پارامترهای مقیاس و انتقال همگی از تابع پایه (موجک مادر) ناشی می‌شوند (طوفانی و همکاران 1390). تبدیل موجک عملگری می‌باشد که یک تابع را به مجموعه‌ای از تبدیل موجک‌های مادر اصلاح شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح شده همان تبدیل موجک دختر می‌باشند. شکل 2 (ب-د) موجک‌های متفاوت دختر را نشان می‌دهد که  $a$  فاکتور فشردگی و  $b$  فاکتور انتقال متناظر با هر موجک مادر می‌باشد. امروزه مدل موجک در منابع آب و هواشناسی کاربرد زیادی پیدا کرده است (یان و همکاران 2004، کوچوک 2004).

نرون<sup>1</sup> تشکیل شده است. اجتماعی از نرون‌های بهم مرتبط، بافت‌هایی که عصب نامیده می‌شوند را می‌سازند، که اطلاعات و پیام‌ها را از یک قسمت بدن به قسمت دیگر بدن منتقل می‌کند. ساختار ANNs که به آن، معماری اطلاق می‌گردد، به شکلی است که نرون‌ها در دسته‌هایی که لایه نام دارند، مرتب می‌شوند. معماری معمول ANNs متشکل از سه لایه است: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌کند و لایه خروجی که نتایج را به‌ازای ورودی‌های مشخص، استخراج می‌کند. شکل 1 ساختار شبکه عصبی MLP را نشان می‌دهد. در شبکه سه لایه با اتصال کامل با  $n_1$  نرون در لایه میانی، خروجی نرون  $k$ ام لایه آخر از رابطه 1 محاسبه می‌شود.

$$Z_{pk} = g(I_{pk}) \quad [1]$$

$$Y_{pi} = g(I_{pi}) \quad [2]$$

$$I_{pi} = \sum_{j=1}^{n_0} W_{ij} Y_{pj} + W_{io} \quad [3]$$

$g$  نشان‌دهنده تابع محرک سیگموئیدی،  $n_0$ : تعداد نرون-های لایه ورودی،  $W_{ij}$  وزن اتصال نرون ورودی  $j$ ام به نرون  $i$ ام لایه میانی و  $W_{io}$  مقدار بایاس نرون  $i$ ام.

$$Y_{pi} = g(I_{pi}) \quad [4]$$

$$I_{pi} = \sum_{k=1}^{n_1} W_{ki} Y_{pk} + W_{ko} \quad [5]$$

$I_{pi}$  ورودی وزن‌دار به نرون  $k$ ام در لایه آخر برای زوج  $p$ ام،  $n_1$  تعداد نرون‌های لایه میانی،  $W_{ki}$  وزن اتصال نرون میانی  $k$ ام به خروجی  $i$ ام،  $W_{ko}$  مقدار بایاس نرون  $k$ ام. در این تحقیق از یک شبکه پرسپترون سه لایه با الگوریتم آموزش پس انتشارخطا<sup>2</sup> استفاده گردید.


#### الگوریتم موجک

موجک‌ها توابع ریاضی هستند که شکل مقیاس-زمان از سری‌های زمانی و روابط آنها را جهت تحلیل سری‌های زمانی که شامل متغیرها و غیرثابت‌ها می-

<sup>3</sup> Acceptability

<sup>1</sup> Neuron

<sup>2</sup> Back propagation



شکل 2- موجک مورلت.

از تبدیل پیوسته موجکی می‌باشد، زیرا داده‌های تبدیل یافته با DWT اجزای اضافی نداشته و لذا تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-بسامد به کار برد.

با اعمال تبدیل گسسته، داده‌های اولیه موجکی شده و به دو دسته تقسیم می‌شوند. دسته اول که تقریب نامیده می‌شوند، دارای فرکانس کم بوده و نشان‌دهنده روند کلی داده‌های موجود است که در محاسبات نقش بسیار مهمی ایفا می‌کند. دسته دوم جزئیات نام دارد که دارای فرکانس بالاست و بیانگر تغییرات محدوده در داده‌هاست. فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چند مرحله-ای، موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد. در علوم منابع آب، بیشتر از موجک‌های هار<sup>4</sup>، دابچی<sup>5</sup> و سیملت<sup>6</sup> استفاده شده است (کاناس و همکاران 2006).

به طور کلی دو نوع تبدیل موجکی وجود دارد: 1- تبدیل موجکی پیوسته (CWT)<sup>1</sup> و 2- تبدیل موجکی گسسته (DWT)<sup>2</sup>. تبدیل موجکی پیوسته برای تابع  $f(t)$  به صورت روابط 7 و 8 تعریف می‌شود:

$$CWT(Scale, Position) = \int_{-\infty}^{+\infty} f(t) j(scale, position) dt \quad [7]$$

$$CWT_s^j(s, t) = \frac{1}{\sqrt{|s|}} \int s(t) j_{s,t}^*(t) dt \quad [8]$$

$s$  و  $\tau$  به ترتیب نشان‌دهنده انتقال و مقیاس و \* نشان‌دهنده مزدوج مختلط<sup>3</sup> می‌باشد. پارامترهای  $s$  و  $\tau$  همیشه اعداد حقیقی و  $s$  مثبت است.  $s$  و  $\tau$  در تبدیل موجکی پیوسته دارای مقادیر پیوسته و در تبدیل گسسته دارای مقادیر گسسته هستند. کلیه توابع پنجره  $j_{s,t}^*$  که از موجک مادر ساخته می‌شوند (موجک‌های دختر) از رابطه 9 حاصل می‌شوند:

$$j_{s,t}^* = j\left(\frac{t-t}{s}\right) \quad [9]$$


مقیاس به معنای کشیده شدن یا فشرده شدن موجک می‌باشد. انتقال موجک به مفهوم به تاخیر انداختن یا جلو انداختن موجک و بیان‌کننده موقعیت موجک روی محور زمان است. تبدیل گسسته موجکی جهت پیش پردازش و تحلیل سری‌های زمانی مناسب‌تر

<sup>4</sup> Haar<sup>5</sup> Daubechies<sup>6</sup> Symlet<sup>1</sup> Continues wavelet transform<sup>2</sup> Discrete wavelet transform<sup>3</sup> Complex conjugate

## منطقه مطالعاتی

در این مطالعه به پیش‌بینی دبی با استفاده از داده‌های دبی روزانه ثبت شده دو ایستگاه هیدرومتری دیزج و بی‌بکران بر روی رودخانه باراندوزچای واقع در دریاچه ارومیه پرداخته شد. مشخصات جغرافیایی ایستگاه‌های مورد مطالعه در جدول 1 ارائه شده است. قبل از انجام تجزیه و تحلیل داده‌ها، بررسی همگنی (ران تست) و پرت بودن (نمودار باکس‌پلات) داده‌ها انجام شد. محاسبات توسط نرم‌افزار SPSS انجام گردید. پس از آماده‌سازی داده‌ها، مدل‌های ANN و WNN اجرا شدند. در جدول 2 مقادیر حدی و انحراف استاندارد دبی روزانه رودخانه باراندوزچای ارائه شده است.

متوسط آورد سالانه رودخانه باراندوزچای 360 میلیون مترمکعب است. سرشاخه باراندوزچای از ارتفاعات مرزی ایران و ترکیه و از دامنه‌های غربی کوه‌های بناد بنجول سرچشمه می‌گیرد. این شاخه از دشت زیوه عبور کرده و در طی مسیر خود، تغییر جهت‌های متعددی می‌دهد. سرشاخه بالانچ‌چای که از ارتفاعات کشوگزان و احمد والی در شمال اشنویه سرچشمه گرفته و در امتداد شمال در کنار جاده اشنویه به ارومیه ادامه مسیر داده و پس از طی مسافتی و دریافت شاخه‌های متعدد در حاشیه غربی این جاده به سرشاخه باراندوز می‌ریزد. این رودخانه پس از ورود به دشت ارومیه به شاخه‌های مختلف تقسیم شده و در انتها در شمال آبادی جیران به باتلاق‌های شور ساحل دریاچه ارومیه می‌ریزد. شکل 3 موقعیت ایستگاه‌های بی‌بکران و دیزج بر روی رودخانه مذکور را نشان می‌دهد.



شکل 1- ساختار شبکه عصبی مصنوعی سه لایه.

## معیار ارزیابی

برای ارزیابی مدل‌ها از شاخص‌های جذر میانگین مربعات خطا (RMSE)، ضریب تعیین ( $R^2$ ) و میانگین قدر مطلق خطا (MAE) استفاده گردید (چِن و همکاران 2003):

$$R^2 = \frac{\left( \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad [10]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad [11]$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad [12]$$

$X_i$  و  $Y_i$  آمین داده واقعی و برآورد شده،  $\bar{X}$  و  $\bar{Y}$  میانگین داده‌های  $X_i$  و  $Y_i$  و  $n$  تعداد مشاهدات است. کم بودن میزان RMSE و MAE و بالا بودن ضریب  $R^2$  بیانگر دقت قابل قبول مدل و ملاک برتری آن خواهد بود.

جدول 1- مشخصات جغرافیایی ایستگاه‌های هیدرومتری مورد مطالعه.

نام ایستگاه	طول جغرافیایی (درجه شرقی)	عرض جغرافیایی (درجه شمالی)	ارتفاع از سطح دریا (m)
بی بکران	44° 54'	37° 17'	1570
دیزج	45° 04'	37° 23'	1320

### شکل 3- موقعیت جغرافیایی ایستگاه بی‌بکران و دیزج.

جدول 2- مقادیر حدی دبی ثبت شده ایستگاه‌های مورد مطالعه رودخانه باراندوزچای در دوره آماری 1369-1388.

ایستگاه	حداقل	حداکثر	میانگین	انحراف
بی بکران	0	132/96	7/50	9/45
دیزج	0/023	142/97	7/58	9/87

در جدول عددها بر حسب مترمکعب بر ثانیه می‌باشند.

### نتایج و بحث

به علت اثر متفاوت داده‌های ورودی بر نرون‌ها، ابتدا داده‌های ورودی به شبکه بی‌بعدسازی شدند، یعنی بین یک دامنه عددی، که معمولاً (0 و 1) می‌باشد، قرار گرفتند. در این تحقیق با توجه به استفاده از تابع سیگموئید در لایه مخفی، رابطه 13 (قرار دادن داده‌ها بین 0/1 و 0/9) برای بی‌بعدسازی استفاده شد (داوسون و ویلیبی 1998).

$$N = 0.8 \frac{(X_i - MIN_{x_i})}{(MAX_{x_i} - MIN_{x_i})} + 0.1 \quad [13]$$

که در  $X_i$ : آن متغیر نام،  $MIN_{x_i}$ : حداقل مقدار متغیر،  $MAX_{x_i}$ : حداکثر مقدار متغیر و  $N$ : مقادیر استاندارد شده، می‌باشند.

به منظور مدل‌سازی جریان رودخانه باراندوزچای، داده‌های روزانه مربوط به 16 سال (1369-1385) برای آموزش شبکه‌ها و 4 سال (1385-1388) برای صحت‌سنجی شبکه‌ها استفاده گردید. ورودی‌های مدل WNN و ANN در جدول 3 ارائه شده‌اند. ساتیاجی راو و کریشنا (2009) نیز برای پیش‌بینی دبی از ورودی‌هایی مطابق با جدول 3 استفاده نمودند البته آنها دبی تا 5 روز قبل را نیز به عنوان ورودی در نظر گرفتند. برای دو ایستگاه مورد بررسی، دبی تا 4

1000 اپاک<sup>1</sup> اجرا گردید. پیش‌بینی توسط مدل WNN با استفاده از نرم‌افزار MATLAB انجام گردید.

جدول 3- مدل‌های ورودی برای ANN و WNN

مدل	ساختار مدل
1	$Q(t) = f(Q[t-1])$
2	$Q(t) = f(Q[t-1], Q[t-2])$
3	$Q(t) = f(Q[t-1], Q[t-2], Q[t-3])$
4	$Q(t) = f(Q[t-1], Q[t-2], Q[t-3], Q[t-4])$

عملکرد این دو مدل برای هر 4 ورودی با استفاده از شاخص‌های آماری مربوطه در دوره صحت‌سنجی در جدول 4 آورده شده است. با توجه به این جدول، مقدار RMSE برای مدل WNN در مقایسه با مدل ANN در دو ایستگاه مربوطه در دوره‌ی تست کمتر می‌باشد. مقدار RMSE در مدل WNN (1/8) تا 3/92 مترمکعب بر ثانیه) برای هر دو ایستگاه در مرحله تست در مقایسه با مدل ANN (2/64 تا 4/89 مترمکعب بر ثانیه) کمتر می‌باشد. در مورد ضریب همبستگی نیز مدل WNN (0/95 تا 0/98) در مرحله تست در مقایسه با مدل ANN (0/86 تا 0/96) برای هر دو ایستگاه مقادیر بیشتری را به خود اختصاص داده است. در هر دو مدل WNN و ANN و برای هر دو ایستگاه مدل ورودی شماره 4 بهترین جواب را داشته است. شبکه WNN در ایستگاه دیزج در مدل ورودی شماره 4 بیشترین ضریب همبستگی (0/98) و همچنین کمترین مقدار RMSE (1/80) را داشت. بنابراین مدل، WNN به عنوان بهترین مدل برای پیش‌بینی جریان رودخانه مورد مطالعه نسبت به مدل ANN انتخاب شد.

در شکل 4 عملکرد دو مدل شبکه عصبی مصنوعی و شبکه عصبی - موجکی نشان داده شده است. برای هر یک از نمودارها مقدار ضریب تعیین ( $R^2$ ) و معادله رگرسیونی بین نقاط مشخص گردید. بالا بودن مقدار ضریب همبستگی ( $r$ ) نشان دهنده نزدیک بودن

روز قبل به عنوان ورودی شبکه‌های مورد استفاده، نتایج خوبی را ارائه داد (جدول 3).

جهت تعیین تعداد گره‌های لایه‌ی مخفی در دو شبکه مورد بررسی معمولاً از آزمون سعی و خطا استفاده می‌شود. یکی از این روابط محدوده مقادیر گره‌های لایه‌ی مخفی را بین  $2n+1$  و  $2n^{1/2} + m$  تخمین می‌زند (گوانگ مینگ و همکاران 2005). این فرمول فرمول تجربی بوده و محدودیت خاصی به همراه ندارد. در این روابط  $m$  تعداد گره‌های خروجی و  $n$  تعداد گره‌های ورودی است. بر اساس این روابط نهایتاً مدل‌های انتخابی شبکه عصبی مصنوعی و عصبی - موجکی انتخاب گردیدند. همچنین برای ایجاد شبکه عصبی و انجام فرآیندهای آموزش، صحت‌سنجی و انتخاب بهترین الگو، از جعبه ابزار برازش شبکه عصبی در نرم‌افزار MATLAB (نسخه 2011) استفاده گردید. این جعبه ابزار بر اساس آخرین نتایج کاربردهای شبکه عصبی مصنوعی، معماری شبکه عصبی را برای حل مسائل برازش چند بعدی، شبکه دو لایه پیش‌خور با الگوریتم آموزشی پس انتشار خطا با یک نرون و تابع انتقال خطی در لایه خروجی و تابع انتقال سیگموئید در لایه مخفی پیشنهاد می‌نماید. تعداد بهینه گره‌های لایه مخفی با استفاده از آزمون سعی و خطا مشخص شد که تعداد پارامترهای ورودی و خروجی بر انتخاب گره لایه مخفی موثر بودند. جهت انتخاب بهترین ساختار شبکه برای هر الگو می‌توان از تغییر در تعداد نرون‌های لایه مخفی و یا آموزش مجدد شبکه بهره جست.

در مدل عصبی - موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزییات آنها استخراج گردید و داده‌ها موجکی شدند. مرحله بعد مدل مناسب شبکه عصبی تعیین گردید. ساختار شبکه عصبی موجکی استفاده شده در این قسمت همانند ساختاری است که در قسمت شبکه عصبی مصنوعی ذکر گردید. مدل با

<sup>1</sup> Epoch



دارد ولی مقادیر تخمینی از خط برازش داده شده فاصله زیادی دارد. در حالیکه در شبکه عصبی- موجکی مقادیر تخمینی تقریباً بر خط برازش داده شده منطبق است. ضریب  $a_0$  در مدل WNN نسبت به مدل ANN به مقدار عددی 1 نزدیک‌تر می‌باشد، این مسئله حاکی از بالا بودن دقت شبکه عصبی- موجکی می‌باشد.

مقادیر تخمین‌زده شده به مقادیر مشاهده شده می‌باشد. معادله برازش خطی برای هر نمودار به صورت معادله  $y=a_0x+a_1$  تعریف شد. ضریب  $a_0$  اگر به سمت 1 میل کند، نشان‌دهنده عملکرد بهتر مدل مربوطه می‌باشد. در تخمین پارامتر دبی رودخانه باراندوزچای، شبکه عصبی مصنوعی مقدار ضریب همبستگی نسبتاً بالایی

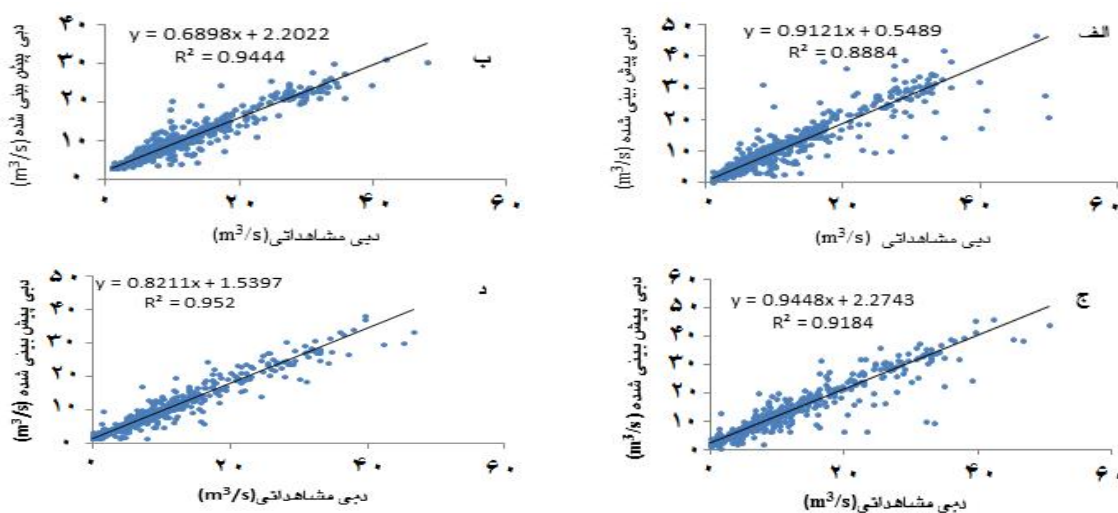
جدول 4- عملکرد شبکه‌های عصبی مصنوعی و عصبی- موجکی در شبیه‌سازی جریان رودخانه ( $m^3s^{-1}$ ) در مرحله صحت‌سنجی.

شبکه عصبی مصنوعی			شبکه عصبی- موجکی			شماره مدل	ایستگاه
MAE ( $m^3/s$ )	RMSE ( $m^3/s$ )	r	MAE ( $m^3/s$ )	RMSE ( $m^3/s$ )	r		
1/25	3/43	/888	2/95	3/13	0/962	1	بی‌بکران
2/91	3/77	/934	2/00	2/99	0/967	2	
3/51	3/82	/938	2/74	3/80	0/969	3	
0/90	2/64	/943	1/71	2/40	0/972	4	
2/99	4/89	/859	2/98	3/92	0/954	1	دیزج
2/62	3/62	/933	2/62	3/37	0/974	2	
0/88	3/23	/933	1/35	1/93	0/975	3	
2/31	2/82	/958	1/23	1/80	0/976	4	


روزانه و ماهانه رودخانه‌های گوسو در ژاپن، بلک واتر و گیلا در آمریکا و فلیوس در ترکیه نشان داد که مدل ANN در مقایسه با روش‌های سری زمانی از دقت بالاتری برخوردار است. نتایج اکبرپور و همکاران (1385) در پیش‌بینی دبی روزانه رودخانه دز با استفاده از مدل شبکه عصبی مصنوعی و مدل HEC-HMC بیانگر عملکرد مناسب شبکه عصبی در پیش‌بینی متغیر مذکور بود. فربودنام و همکاران (1388) نتیجه گرفتند که برای مدل شبکه عصبی مصنوعی حافظه تا دبی چهار روز قبل رو به بهبود بوده و بعد از آن نزول می‌کند. نخعی و صابری (1389) در پیش‌بینی نوسانات سطح آب زیرزمینی نشان دادند که روش WNN نسبت به روش عددی کارایی بهتری دارد. نوری و همکاران (1388) نیز در پیش‌بینی جریان ماهانه رودخانه صوفی‌چای نتایج مشابه تحقیق حاضر را گزارش کردند.

لذا می‌توان نتیجه‌گیری نمود که مدل عصبی- موجکی با توجه به مقدار بالای  $r$  و پایین بودن مقادیر RMSE و MAE نسبت به شبکه عصبی، از دقت بالایی برخوردار بوده و تخمین دقیق‌تری حاصل کرده است. این موضوع را می‌توان در شکل 5 که مقایسه بین داده- های اندازه‌گیری شده و تخمین زده شده توسط دو مدل را نشان می‌دهد، مشاهده کرد.

نمودار مقادیر اندازه‌گیری شده و داده‌های تخمین‌زده شده توسط مدل WNN در بیشتر نقاط نسبت به مدل ANN تقریباً انطباق بیشتری با هم دارند. این موضوع دلالت بر دقت بالای مدل WNN در تخمین پارامتر دبی نسبت به مدل ANN و نزدیکی به مقادیر اندازه‌گیری شده دارد. مطالعات ساتیاجی راو و کریشنا (2009) نیز بر بالا بودن دقت مدل عصبی- موجکی نسبت به شبکه عصبی برای جریان رودخانه، تأکید کرده‌اند. نتایج کیسی (2005) در پیش‌بینی جریان‌های



شکل 4- مقادیر مشاهداتی و پیش‌بینی شده جریان روزانه رودخانه (مرحله‌ی تست): الف) مدل ANN برای ایستگاه بی‌بکران، ب) مدل WNN برای ایستگاه بی‌بکران، ج) مدل ANN برای ایستگاه دیزج و د) مدل WNN برای ایستگاه دیزج.



شکل 5- مقادیر حاصل از روش‌های ANN، WNN و اندازه‌گیری شده دبی: الف) ایستگاه دیزج و ب) ایستگاه بی‌بکران.

### نتیجه‌گیری کلی

مدل WNN عملکرد بهتری در شبیه‌سازی جریان رودخانه دارد که به موثر بودن قابلیت موجک در تجزیه کردن سری زمانی به دو دسته تقریب و جزئیات اشاره دارد. همچنین بهترین کارایی در تاخیر تا چهار روز مشاهده گردید. با توجه به کارایی بهتر شبکه عصبی-موجکی پیشنهاد می‌گردد از موجک‌های دایچی و هار نیز برای تجزیه موجک استفاده گردد و نتایج آنها با هم مقایسه شود. همچنین می‌توان با استفاده از پارامترهای هواشناسی دبی روزانه رودخانه را از مدل WNN پیش-بینی کرد. نتایج این تحقیق می‌تواند در مدیریت منابع آب مفید واقع شود.

در تحقیق حاضر عملکرد مدل عصبی-موجکی (WNN) و شبکه عصبی مصنوعی (ANN) برای شبیه‌سازی جریان روزانه رودخانه باراندوزچای در دو ایستگاه بی‌بکران و دیزج در استان آذربایجان غربی مورد ارزیابی قرار گرفت. نتایج نشان داد که شبیه‌سازی جریان روزانه رودخانه با استفاده از شبکه عصبی-موجکی امکان‌پذیر است. از داده‌های روزانه دبی رودخانه با تاخیر تا چهار روز قبل برای تخمین جریان استفاده شد و نتایج حاصل از شبکه عصبی-موجکی با مقدار دبی مشاهداتی مقایسه گردید. نتایج نشان داد که

## منابع مورد استفاده

- اکبرپور م، رهنما م و بارانی ب، 1382. مقایسه‌ی شبکه عصبی مصنوعی و مدل HEC-HMS در فرآیند بارندگی - رواناب. صفحه‌های 1025 تا 1031، مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، دانشگاه شیراز.
- طوفانی پ، مساعدی ا و فاخری فرد ا، 1390. پیش‌بینی بارندگی با استفاده مستقیم از نظریه موجک. نشریه آب و خاک، جلد 25 شماره 5 صفحه‌های 1226 تا 1217.
- فرهودنام ن، محمدعلی قربانی مع و اعلمی مت، 1388. پیش‌بینی جریان رودخانه با استفاده از برنامه‌ریزی ژنتیک (مطالعه موردی: حوضه آبریز رودخانه ليقوان). مجله دانش آب و خاک، جلد 19 شماره 1. صفحه‌های 107 تا 123.
- نخعی م و صابری‌نصر ن، 1389. پیش‌بینی نوسانات سطح آب زیرزمینی دشت قروه با استفاده از شبکه عصبی-موجکی و مقایسه آن با مدل عددی MODFLOW، بیست و نهمین گردهمایی علوم زمین، سازمان زمین شناسی و اکتشافات معدنی کشور. 26 و 27 بهمن، تهران.
- نوری ر، فرخ‌نیا، مرید س و ریاحی مدواح، 1388. تاثیر پیش‌پردازش‌های متغیرهای ورودی به شبکه عصبی برای پیش-بینی جریان ماهانه با آنالیز مولفه‌های اصلی و موجک. نشریه آب و فاضلاب. شماره 1 صفحه‌های 13 تا 22.
- Ancil A, and Rat A, 2005. Evaluation of neural network streamflow forecasting on 47 watersheds. *Journal of Hydrologic Engineering* 10(1): 85-88.
- Anonymous, 2000a. Artificial neural networks in hydrology-I: Preliminary concepts. *Journal of Hydrologic Engineering ASCE* 5(2): 115-123.
- Anonymous, 2000b. Artificial neural networks in hydrology-II: Hydrologic applications. *Journal of Hydrologic Engineering ASCE* 5(2): 124-137.
- Cannas B, Fanni A, See L and Sias G, 2006. Data preprocessing for river flow forecasting using neural networks, Wavelet transforms and data partitioning. *Physics and Chemistry of the Earth* 31(18): 1164-1171.
- Chen JC, Chang NB and Shieh WK, 2003. Assessing wastewater reclamation potential by neural network model. *Engineering Application of Artificial Intelligence* 16: 149-157.
- Dawson CW and Wilby R, 1998. An artificial neural network approach to rainfall-runoff modeling. *Hydrological Sciences Journal* 43: 14-66.
- El-Shafie A, RedaTaha M and Noureldin A, 2007. A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water Resources Management* 21: 533-55.
- Guang-ming Z, Hong-wei LU, Xiang-can JIN and Min XU, 2005. Assessment of the water quality and nutrition of the dongting Lake with wavelet neural network. *Journal of Hunan University (Natural Sciences)* 32(1): 91-94.
- Kisi O, 2005. Daily river flow forecasting using artificial neural networks and auto regressive models. *Turkish Journal of Environmental Engineering* 29: 9-20.
- Krishna B, Rao Y and Nayak P, 2011. Time series modeling of river flow using wavelet neural network. *Resource and Protection* 3: 50-59.
- Kucuk M, 2004. Modeling river flow series using wavelet transform. PhD Thesis, Istanbul Technical University. (inTurkish)
- Labat D, Ababou R, and Mangin A, 2000. Rainfall-runoff relations for karstic springs: Part II. Continuous wavelet and discrete orthogonal multi resolution analyses. *Journal of Hydrology* 238: 149-178.
- Satyaji Rao YR and Krishna B, 2009. Modelling hydrological time series data using wavelet neural network analysis. *New approaches to hydrological prediction in data-sparse regions. IAHS AISH.* 333: 101-111.
- Sivakumar B, Jayawardena AW and Fernando TMKG, 2002. River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *Journal of Hydrology* 265: 225-245.
- Smith LC, Turcotte D and Isacks BL, 1998. Stream flow characterization and feature detection using a discrete wavelet transform. *Hydrologic Processes* 12: 233-249.
- Wensheng W and Jing D, 2003. Wavelet network model and its application to the prediction of hydrology. *Nature and Science* 1(1): 67-71.
- Yan Z, Tsimplis MN and Woolf D, 2004. Analysis of the relationship between the North Atlantic Oscillation and sea level changes in northeast Europe. *International Journal of Climatology* 24: 743-758.