

## پیش‌بینی مقدار آبدهی رودخانه در شرایط کم‌آبی و پرآبی با استفاده از یک مدل استوکستیک و هوش مصنوعی

حسین شریفان<sup>۱</sup>، فائقه پژوهش<sup>۲\*</sup>، امیراحمد دهقانی<sup>۳</sup>

تاریخ دریافت: ۱۳۹۲/۹/۱۷ تاریخ پذیرش: ۱۳۹۳/۶/۱۹

### چکیده

با توجه به برنامه‌ریزی منابع آب، به‌خصوص در مناطقی که منابع آب سطحی به عنوان اصلی‌ترین منبع در امور شرب و کشاورزی به حساب می‌آیند، برآورد میزان آب رودخانه‌ها در دوره‌های کم‌آبی و پرآبی اهمیت پیدا می‌کند. در این تحقیق با استفاده از یک مدل‌سازی سری زمانی، میزان و زمان وقوع کم‌آبی و پرآبی رودخانه گرگانرود، بر اساس مدل سری زمانی متداول میانگین متحرک تجمعی خود بازگشت (ARIMA) برآورد شده است و در ادامه از شبکه عصبی، به‌عنوان مدلی از خانواده هوش مصنوعی، در برآورد میزان و زمان وقوع کم‌آبی و پرآبی رودخانه، استفاده شده است. مقدار کم‌آبی و پرآبی هر ماه، با استفاده از مقدار میانگین متحرک یک، سه، پنج و هفت روزهی دبی جریان در هر ماه، در نظر گرفته شده است. در پایان، این نتیجه حاصل شد که سری‌های زمانی کم‌آبی، نسبت به سری‌های زمانی پرآبی، در استفاده از مدل استوکستیک و شبکه عصبی نتایج بهتری ارائه می‌دهند، هم‌چنین با توجه به آماره میانگین خطای مطلق (MAE) و در سری‌های زمانی کم‌آبی (۷ و ۵ روزه، مدل استوکستیک ARIMA، نسبت به مدل شبکه عصبی نتیجه بهتری ارائه می‌دهد، شبکه عصبی نیز در سری‌های زمانی کم‌آبی، ۵ و ۳ روزه، نتایج بهتری را ارائه می‌دهد و با توجه به آماره میانگین خطای مطلق (MAE) در پرآبی‌ها، مدل ARIMA در سری زمانی یک روزه و ANN در سری زمانی ۳ و ۵ و ۷ روزه نتایج مناسب‌تری ارائه داده است.

**واژه‌های کلیدی:** آبدهی ماهانه، کم‌آبی، پرآبی، مدل‌سازی سری زمانی، ARIMA، شبکه عصبی

### مقدمه

منابع آب برای زندگی همه موجودات از اهمیت ویژه‌ای برخوردار است. پیش‌بینی جریان رودخانه‌ها می‌تواند در بحران کمبود آب، سیل و هم‌چنین در مدیریت کشاورزی مؤثر باشد. به‌طوری‌که، پیش‌بینی آورد در یک رودخانه، از ضروریات برنامه‌ریزی‌های مدیریتی می‌باشد (Bhattacharya, Solomatine, 2000) و شناسایی مدل مناسب برای پیش‌بینی جریان رودخانه از جمله شرایط مهم به جهت موفقیت در برنامه ریزی و مدیریت منابع آب است (Keskin and Taylan, 2010).

مدل‌های مختلفی برای پیش‌بینی جریان رودخانه‌ها پیشنهاد شده است، مانند مدل‌های خودبازگشت و شبکه عصبی، که در انواع پیش‌بینی‌ها استفاده می‌شوند. انتخاب یک مدل مناسب برای پیش‌بینی یک فرایند، بسیار پیچیده و دشوار می‌باشد (Baareh et

al., 2006). در پیش‌بینی جریان رودخانه ارائه اطلاعات اولیه گسترده‌ای از مشکلات مربوط به طراحی و بهره‌برداری از سیستم رودخانه، نیاز می‌باشد (Dibike and Solomatine, 2001). هم‌چنین در این انتخاب عواملی چون، در دسترس بودن داده‌ها، اندازه حوضه، ابزار مختلف سنجش و اندازه‌گیری مورد استفاده قرار گرفته، را می‌توان اشاره نمود (Baareh et al., 2006).

مطالعات بسیاری در زمینه کم‌آبی‌ها و پرآبی‌های رودخانه‌ها صورت گرفته است، که می‌توان به‌مواردی از این مطالعات اشاره نمود، برآورد جریان با استفاده از شبکه عصبی (شبکه چند لایه<sup>۴</sup> و شبکه شعاعی<sup>۵</sup>) و روش‌های استوکستیک و مقایسه این روش‌ها در تحقیق صورت گرفته بر رودخانه آپیور توسط دیبیک و سالاماتین، نشان دهنده برتری روش‌های مربوط به شبکه عصبی در این زمینه می‌باشد (Dibike and Solomatine, 2001)، در تحقیق دیگری، باتاچریا و سالاماتین، با استفاده از داده‌های برداشت شده در ایستگاه سواراپگانج در هند، پیش‌بینی آورد رودخانه با استفاده از روش‌های استوکستیک و شبکه عصبی، انجام دادند و در نتایج خود به مناسب

۱- دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان  
۲- دانش‌آموخته کارشناسی ارشد مهندسی منابع آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

\*- نویسنده مسئول: (Email: f.pazhoohesh.f@gmail.com)

۳- دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی منابع طبیعی گرگان

4- Multuy Layer Program (MLP)

5- Radial B F (RBF)

در انجام این تحقیق یافتن روشی مناسب برای پیش‌بینی با دقت بیشتر، برای تعیین میزان کم‌آبی و پرآبی جریان رودخانه، مورد نظر می‌باشد. در این تحقیق از مقدار کمینه یا مینیمم یک روزه و همچنین مقدارهای کمینه برای مینیمم‌های میانگین متحرک ۳، ۵ و ۷ روزه داده‌های ایستگاه مورد بررسی استفاده شده است و همچنین از مقدار بیشینه و یا ماکزیمم یک روزه و ماکزیمم‌های ۳، ۵ و ۷ روزه برای تعیین داده‌های مورد استفاده در پرآبی‌ها استفاده شده است سپس برای تأمین این هدف از داده‌های حاصل برای سری‌های زمانی مورد بررسی آورد رودخانه با استفاده از دو مدل متداول در برآورد رودخانه‌ها، یک مدل استوکستیک پارامتر خطی (ARIMA) و مدل دیگر مبتنی بر روابط غیرخطی هوش مصنوعی با استفاده از شبکه عصبی مصنوعی، مورد مطالعه واقع شده‌اند. آمار برداشت شده در ایستگاه ارازکوسه، بر روی رودخانه گرگانرود در استان گلستان، در ارزیابی دو مدل مطرح شده، استفاده می‌شود.

## مواد و روش‌ها

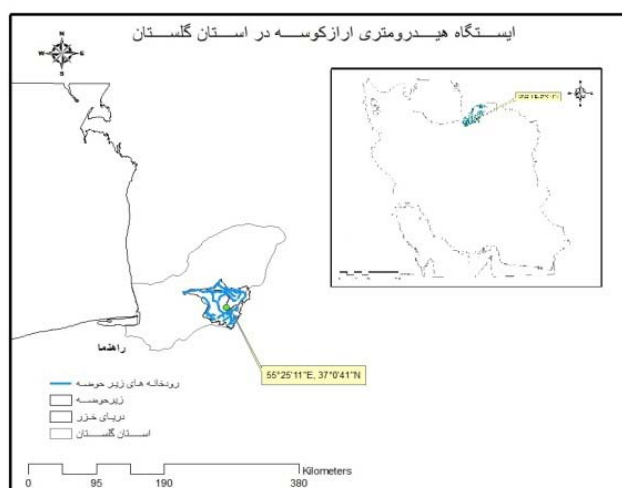
### منطقه مورد مطالعه

در این تحقیق از داده‌های روزانه، برداشت شده در حوضه گرگانرود، ایستگاه ارازکوسه، رودخانه قره‌سو در استان گلستان، در طول شرقی ۱۱-۲۵-۵۵ و عرض شمالی ۴۱-۰۰-۳۷ در ارتفاع ۱۲۵۰ متر در طی سال‌های آبی ۷۷-۱۳۴۴ به مدت ۳۳ سال استفاده شده است. ۸۰٪ داده‌ها (۴۵-۱۳۴۴ الی ۷۰-۱۳۶۹) جهت اعتبار سنجی و ۲۰٪ داده‌ها (۷۱-۱۳۷۰ الی ۷۷-۱۳۷۶) جهت واسنجی و مقایسه عملکرد مدل‌ها به کار رفته است.

بودن شبکه عصبی، در برآورد دبی در این رودخانه رسیدند (Bhattacharya and Solomatine, 2000). کیسی، در تحقیقی با استفاده از شبکه‌های عصبی مصنوعی به پیش‌بینی جریان متوسط ماهانه پرداخته است، در این تحقیق از روش استوکستیک خودبازگشت (AR) نیز استفاده شده است. در پایان نتایج حاصل از شبکه عصبی و روش AR با استفاده از پارامترهای آماری در محدوده‌های مختلف مورد بررسی قرار گرفتند و شبکه عصبی مناسب‌تر عنوان شده است (Kisi, 2004). باره و همکاران در تحقیقی بر روی برآورد دبی دو رودخانه در امریکا برتری روش شبکه عصبی (NN) در مقابل روش استوکستیک AR را نشان داده‌اند (Baareh et al, 2006) و فراستو و همکاران، در مطالعه‌ای که در پیش‌یابی کوتاه مدت جریان ماهانه در رودخانه مکزیکن، صورت گرفته است؛ میزان خطای پیش‌بینی مدل ARIMA نسبت به ANN کم‌تر بوده است (Frausto et al, 2008). در ادامه می‌توان به تحقیقات سیگیزاگلو (Cigizoglu, 2003)، برای مقایسه شبکه عصبی و مدل خودبازگشت نیز اشاره نمود.

در مقایسه مدل‌های استوکستیک و هوش مصنوعی بر روی بیش‌تر رودخانه‌ها، پاسخگویی روش‌های مربوط به هوش مصنوعی، به دلیل روابط غیر خطی حاکم، مناسب‌تر می‌باشد (Zhou et al, 2008).

شبکه عصبی مصنوعی روشی با ساختار ریاضی انعطاف‌پذیری است که قابلیت شناخت روابط غیرخطی بین ورودی‌ها و خروجی‌ها را دارد. ویژگی مهم شبکه عصبی مصنوعی بی‌نیازی آن برای تعیین روش صریحی در مورد پیش‌بینی است (Frausto et al, 2008). همچنین استفاده و اعمال شبکه عصبی مصنوعی در زمینه‌های مختلف از جمله منابع آب با موفقیت همراه بوده است (Kisi, 2007).



شکل ۱- نمایی از منطقه مورد مطالعه

### مدل میانگین متحرک تجمعی خود بازگشت (ARIMA)

داده‌هایی که از مشاهدات یک پدیده در طول زمان به دست می‌آیند، بسیار متداول هستند. هدف از تجزیه و تحلیل سری زمانی، درک و یا به مدل در آوردن مکانیسم تصادفی که منجر به مشاهده سری می‌شود و پیش‌بینی مقادیر آینده سری بر مبنای گذشته است (شریفان و قهرمان، ۱۳۸۵).

به جهت مدل‌سازی سری زمانی، در اغلب موارد متخصصان از انواع مدل‌های ریاضی و آماری برای بیان همبستگی موجود بین زمان و مشاهدات موجود استفاده می‌کنند. یکی از این مدل‌ها، مدل میانگین متحرک تجمعی خودبازگشت  $(ARIMA(p,d,q)*(P,D,Q))$  می‌باشد، که  $P$ ،  $D$  و  $Q$  عبارتند از مرتبه خود بازگشت، مرتبه تفاضلی و مرتبه میانگین متحرک به صورت فصلی و  $p$ ،  $d$  و  $q$  در صورت غیرفصلی می‌باشند (Sharifan, 2006).

$$Y_t = \Phi_p Y_{t-1} + \Phi_p Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta - \epsilon_t \quad (1)$$

که در آن  $Y_t$  متغیر در زمان  $t$  از سری زمانی با میانگین صفر و واریانس ۱ است؛  $Y_{t-p}$  ارزش‌های قبلی متغیر  $Y_t$  هستند و  $\epsilon_t$  یک عدد تصادفی در زمان  $t$  است، پارامتر خودبازگشت می‌باشد. (Box and Jenkins, 1976).

### مناسب‌ترین مدل میانگین متحرک تجمعی خود بازگشت (ARIMA)

در این تحقیق با استفاده از نرم افزار minitab به برآزش یک مدل مناسب استوکستیک بر داده‌های موجود پرداخته شده است. در این راستا در ابتدا مقادیر میانگین متحرک ۱، ۳، ۵ و ۷ روزه داده‌های موجود به صورت سری زمانی مرتب شده اند، از آنجا که داده‌ها بایستی داده‌های مثبت و غیر صفر باشند، تغییرات لازم - یعنی افزودن مقدار مثبت (c) به سری زمانی - صورت می‌گیرد، افزودن مقدار ثابت مثبت به تمام سری زمانی تغییری در واریانس سری زمانی ایجاد نمی‌کند، پس از آن با استفاده از تبدیل باکس - کاکس و با توجه به مقدار  $\lambda$  و با استفاده از روابط موجود مقادیر سری زمانی را تبدیل نموده و سپس آزمون بارتلت و لون جهت بررسی همگنی واریانس و نرمال بودن داده‌ها با در نظر گرفتن خطای نوع اول  $(\alpha)$  به میزان ۵٪ و ضریب اطمینان ۹۵٪ انجام می‌شود؛ در ادامه برای ایست کردن سری زمانی از روش تفاضلی استفاده می‌شود و بدین ترتیب مراتب تفاضلی فصلی (D) و غیرفصلی (d) با استفاده از کم‌ترین واریانس سری تفاضلی حاصل  $(\sigma^2_z)$ ، تعیین می‌شود یعنی مقادیر  $d$  و  $D$  طوری انتخاب می‌شوند که واریانس سری تفاضلی دارای کم‌ترین مقدار خود باشد. در

تعیین مرتبه‌های  $P$ ،  $Q$  و  $p$  و  $q$  و شناسایی الگو، از نمودارهای همبستگی‌نگار (SAC) و همبستگی‌نگار جزئی (SPAC) سری تفاضلی و راهنمای انتخاب مدل باکس-جنکینز، استفاده شده است و در مراحل بعدی مقادیر پیشنهادی ارزیابی می‌شود. در ارزیابی الگوهای مختلف بزرگ‌تر بودن مقدار  $t$  و  $P$ -Value هر یک از مرتبه‌ها بایستی به ترتیب از  $1/96$  و  $0/05$  بزرگ‌تر باشد، همچنین در اجرای برخی الگوها، خطایی براساس رد الگو ارائه شده است. در ارزیابی‌هایی که صورت می‌گیرد، مقادیر  $SS$  و  $MS$  هر یک از الگوها، مورد بررسی قرار گرفته‌اند و الگوی مناسب، الگویی است که دارای  $SS$  و  $MS$  کم‌تری باشد، که در مورد الگوهای مناسب بر هریک از سری‌ها نیز چنین می‌باشد (شریفان و قهرمان، ۱۳۸۶). پس از ارزیابی الگوها و تعیین مناسب‌ترین الگو پیش‌بینی سری‌های موجود در نرم افزار minitab-15 صورت گرفته است.

### مدل مبتنی بر شبکه عصبی

شبکه عصبی مصنوعی (ANN) الگوی پردازش اطلاعاتی است که از شبکه عصبی زیستی مانند پردازش اطلاعاتی مغز الهام گرفته شده است. عنصر راهنمای این الگو، ساختار جدیدی از سیستم پردازش اطلاعات است. این شبکه ترکیبی از تعداد بسیار زیادی از عناصر پردازشی بهم پیوسته (یاخته‌های عصبی) است که به صورت یکپارچه برای حل یک مسئله عمل می‌کنند. شبکه عصبی می‌تواند نتایج را از داده‌های پیچیده و مبهم به دست آورد. انواع مختلفی از شبکه عصبی وجود دارد اما شبکه مصنوعی پس‌انتشار از معروف‌ترین انواع شبکه عصبی می‌باشد. به طور کلی در شبکه عصبی مصنوعی سه لایه متفاوت وجود دارد. لایه اول، لایه ورودی خوانده می‌شود و داده‌های ورودی را از جهان بیرون دریافت می‌کند. تعداد نرون‌های این لایه برابر تعداد مدل‌های ورودی است. لایه بعدی، لایه پنهان خوانده می‌شود. این لایه داده‌های ورودی را از لایه پردازشی اول دریافت می‌کند. لایه پایانی شبکه نیز لایه خروجی است. یاخته موجود در این لایه، خروجی شبکه را نمایش می‌دهند. یاخته‌ها در هر لایه به طور کامل به یاخته‌های لایه بعدی متصل هستند، اما یاخته‌های یک لایه به دیگر یاخته‌های همان لایه متصل نیستند. مجموع وزن‌های یک یاخته ورودی با توجه به عملکرد تابع تعیین می‌شود (Baareh et al, 2006). وزن‌ها از گره‌های ورودی به گره (های) پنهان، و گره (های) پنهان به گره‌های خروجی - تغییر می‌کنند (از سمت لایه خروجی به لایه (های) پنهان و به سمت لایه

- 1- neuron
- 2- Input layer
- 3- Hidden layer
- 4- Output layer

استفاده شده است. در اجرای شبکه عصبی از تعداد ورودی‌های مختلف با تعداد تاخیرهای متفاوت استفاده شده است.

$$f_{non}(x(t), x(t-1), \dots, x(t-n_a)) + e(t) \quad (3)$$

که در آن:  $f_{non}$ ، تابع غیر خطی،  $e(t)$ ، خطا ناشناخته،  $n_a$  تعداد ورودی‌های با تاخیر(گذشته) است (Dibike, Solomatine, 2001).

### معیارهای ارزیابی


در ارزیابی نتایج به‌دست آمده از مدل‌های منطبق شده بر داده‌های مورد استفاده از معیارهایی چون میانگین خطای مطلق (MAE)، مجذور خطای مربعات (RMSE) و تغییرات نسبت به خط ایده‌آل (۱:۱)، استفاده شده است.

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_t - \hat{x}_t| \quad (4)$$

$$RMSE = \left[ \frac{1}{N} \sum_{i=1}^N (x_t - \hat{x}_t)^2 \right]^{1/2} \quad (5)$$

که در آن،  $x_t$  مقادیر مشاهده‌ای و  $\hat{x}_t$  مقادیر پیش‌بینی شده می‌باشند و  $N$  تعداد داده‌ها در هریک از دسته‌بندی‌ها می‌باشد (Frausto-Solis et al, 2008 ; Mustafa et al, 2011).

ورودی) و از آن‌جایی که شبکه پس‌انتشار از خروجی واقعی، استفاده می‌کند به عنوان یک روش آموزش تحت نظارت می‌باشد (Danh et al, 1999).



شکل ۲- نمایی از شبکه عصبی

### مناسب‌ترین مدل شبکه عصبی

در پیش‌بینی با استفاده از شبکه عصبی داده‌های روزانه موجود به صورت سری‌های زمانی میانگین متحرک ۱، ۳، ۵ و ۷ روزه مرتب شده‌اند. سپس نرمال‌سازی داده‌ها با استفاده از معادله (۳) صورت گرفته است (Kisi, 2007) و با استفاده از نرم افزار matlab2010 مدل شبکه‌های عصبی برازش داده شده‌اند.

$$x_{normal} = x_i / x_{max} \quad (2)$$

سپس داده‌ها به‌صورت سه دسته ۶۰ و ۲۰ و ۲۰ تقسیم شده‌اند که ۶۰٪ اولیه داده‌ها جهت آموزش شبکه عصبی و ۲۰٪ بعدی جهت اعتبارسنجی و ۲۰٪ پایانی برای تست انتخاب شده‌اند. شبکه عصبی جهت برآورد جریان با استفاده از جریان‌های گذشته

جدول ۱- مدل‌های برازش شده با استفاده از مدل SARIMA

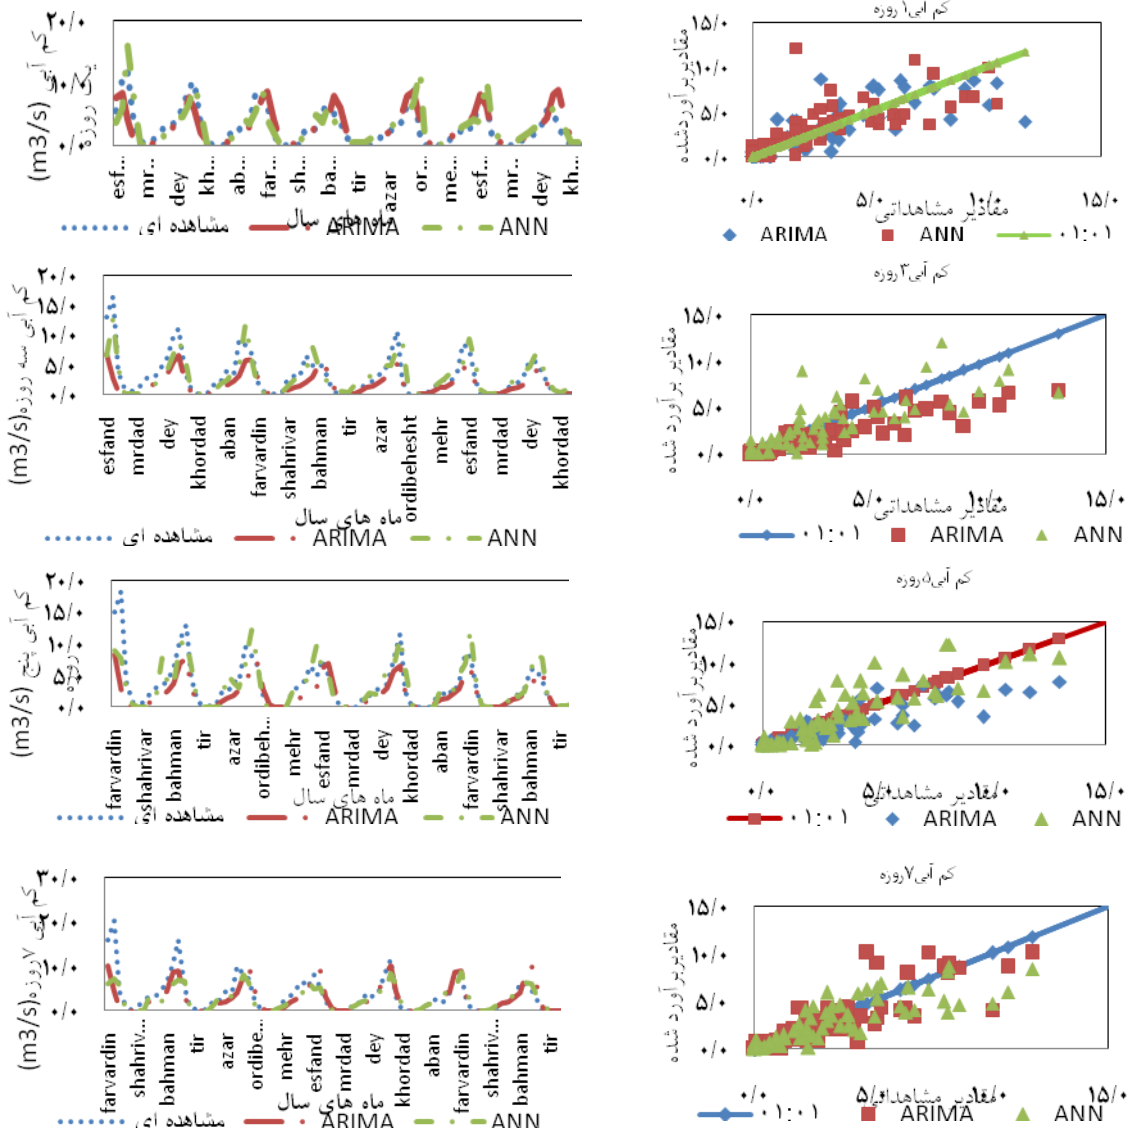
| سری زمانی | کم آبی            | پرآبی             |
|-----------|-------------------|-------------------|
| ۱         | (۲,۰,۱) * (۱,۱,۲) | (۲,۱,۲) * (۲,۱,۲) |
| ۳         | (۲,۱,۲) * (۲,۱,۲) | (۲,۱,۲) * (۲,۰,۱) |
| ۵         | (۲,۱,۲) * (۱,۱,۱) | (۲,۱,۲) * (۱,۰,۱) |
| ۷         | (۲,۰,۲) * (۱,۱,۲) | (۲,۱,۲) * (۱,۰,۱) |

جدول ۲- مدل‌های ANN برازش شده بر سری‌های زمانی دبی رودخانه


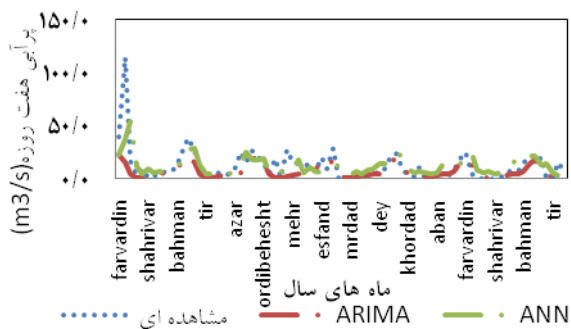


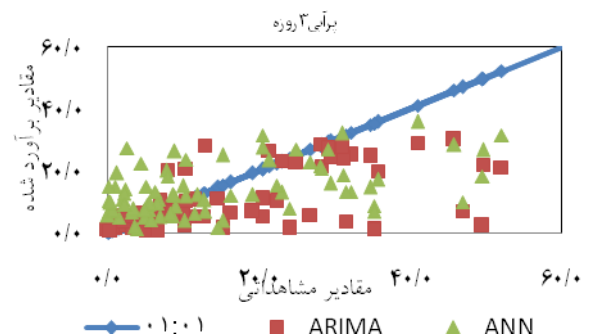


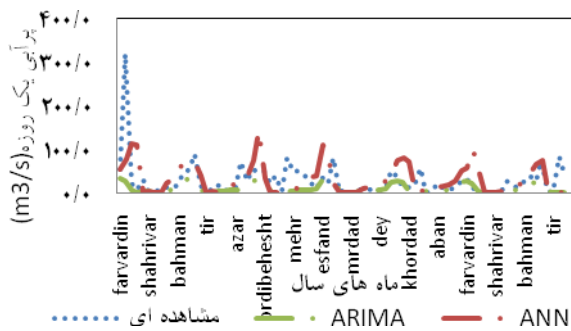
| نوع جریان | سری زمانی | تابع آستانه | تعداد نرون‌های ورودی | تعداد نرون‌های لایه پنهان | R      |
|-----------|-----------|-------------|----------------------|---------------------------|--------|
| کم آبی    | ۱روزه     | tgSig       | ۵                    | ۱۵                        | ۰/۸۰۱۲ |
|           | ۳روزه     | tgSig       | ۹                    | ۱۳                        | ۰/۸۴۵۰ |
|           | ۵روزه     | tgSig       | ۹                    | ۲۰                        | ۰/۸۳۱۵ |
|           | ۷روزه     | tgSig       | ۷                    | ۱۰                        | ۰/۸۰۹۵ |
| پرآبی     | ۱روزه     | tgSig       | ۵                    | ۱۸                        | ۰/۸۲۲۵ |
|           | ۳روزه     | tgSig       | ۹                    | ۱۵                        | ۰/۵۶۰۰ |
|           | ۵روزه     | tgSig       | ۹                    | ۱۵                        | ۰/۵۰۷۹ |
|           | ۷روزه     | tgSig       | ۷                    | ۱۵                        | ۰/۵۶۱۳ |

جدول ۳- نمایش تعداد نرون‌های ورودی در مدل‌های پیش‌بینی دبی رودخانه

| نوع جریان | سری زمانی | تعداد نرون های ورودی | توضیح                             |
|-----------|-----------|----------------------|-----------------------------------|
| کم آبی    | ۱روزه     | ۵                    | Qt-1,Qt-2,...,Qt-5                |
|           | ۳روزه     | ۹                    | Qt-1,Qt-2,Qt-3,Qt-4,Qt-5,...,Qt-9 |
|           | ۵روزه     | ۹                    | Qt-1,Qt-2,Qt-3,Qt-4,Qt-5,...,Qt-9 |
|           | ۷روزه     | ۷                    | Qt-1,Qt-2,Qt-3,...,Qt-7           |
| پرآبی     | ۱روزه     | ۵                    | Qt-1,Qt-2,...,Qt-5                |
|           | ۳روزه     | ۹                    | Qt-1,Qt-2,Qt-3,Qt-4,Qt-5,...,Qt-9 |
|           | ۵روزه     | ۹                    | Qt-1,Qt-2,Qt-3,Qt-4,Qt-5,...,Qt-9 |
|           | ۷روزه     | ۷                    | Qt-1,Qt-2,Qt-3,...,Qt-7           |



شکل ۳- نمودارهای پراکنده‌گی و مدل‌های برازش داده شده در سری کم آبی



شکل ۴- نمودارهای پراکنده و مدل‌های برازش داده شده در سری پرایم

بطوری که این نمودارها، داده‌های پیش‌بینی شده برای داده‌های جریان کم‌آبی و پرآبی، با شاخص‌های ۱، ۳، ۵ و ۷ روزه و پراکنش پیش‌بینی صورت گرفته نسبت به خط یک به یک می‌باشد.

نمودارهای مربوط به مقادیر مشاهده‌ای و پیش‌بینی شده با استفاده از مدل‌های ARIMA و ANN، در طول سری زمانی و نسبت به خط (۱:۱) در شکل‌های ۳ و ۴ نشان داده شده است.

جدول ۴- آماره های برازش مدل های برازش داده شده برای پیش بینی دبی رودخانه

| نوع جریان | سری زمانی | RMSE   |        | MAE    |        |
|-----------|-----------|--------|--------|--------|--------|
|           |           | ANN    | ARIMA  | ANN    | ARIMA  |
| کم آبی    | روزه ۱    | ۱/۷۰۸  | ۱/۹۰۷  | ۱/۰۱۸  | ۱/۱۹۷  |
|           | روزه ۳    | ۲/۴۵۵  | ۱/۸۰۷  | ۱/۳۸۸  | ۱/۲۲۷  |
|           | روزه ۵    | ۲/۵۹۷  | ۲/۱۰۷  | ۱/۴۱۳  | ۱/۲۴۴  |
|           | روزه ۷    | ۲/۵۸۲  | ۲/۶۲۵  | ۱/۲۵۱  | ۱/۴۰۳  |
| پرآبی     | روزه ۱    | ۴۱/۰۵۹ | ۴۲/۴۰۰ | ۱۸/۴۳۲ | ۲۸/۰۸۸ |
|           | روزه ۳    | ۲۴/۶۳۶ | ۲۲/۲۳۲ | ۷/۹۶۰  | ۳/۹۵۷  |
|           | روزه ۵    | ۱۷/۹۸۳ | ۱۶/۷۳۰ | ۶/۹۶۹  | ۱/۳۵۰  |
|           | روزه ۷    | ۱۳/۰۸۳ | ۱۲/۱۴۴ | ۵/۲۵۲  | ۵/۱۶۰  |

## نتایج و بحث

در این تحقیق از داده‌ها با تقسیم بندی ۸۰-۲۰ مورد استفاده قرار گرفته است به گونه‌ای که ۸۰٪ داده‌ها (۴۵-۱۳۴۴ الی ۷۰-۱۳۶۹) جهت اعتبار سنجی و ۲۰٪ داده‌ها (۷۱-۱۳۷۰ الی ۷۷-۱۳۷۶) جهت واسنجی و مقایسه عملکرد مدل‌ها به کار رفته است. در جریان‌های کم‌آبی برازش داده شده بر ۸۰٪ داده‌ها، پیش‌بینی برای ۲۰٪ باقیمانده داده‌ها صورت گرفته است، بر روی برخی از داده‌ها بیش از یک مدل برازش داده شده تا مقایسه‌ای بین مدل‌های مختلف برازش داده شده بر داده‌ها نیز مورد توجه قرار گیرد اما در برخی از داده‌ها یکی از مدل‌ها به‌عنوان بهترین مدل پاسخگو بوده است. جدول (۱) مدل‌های برازش داده شده با استفاده از مدل SARIMA را نشان می‌دهد. شبکه عصبی با سه لایه - ورودی، پنهانی و خروجی - انتخاب شده است. لایه‌های ورودی شبکه‌های ایجاد شده شامل تعداد نرون‌های متغیری می‌باشد (۵، ۷، ۹ نرون) و لایه میانی نیز شامل تعداد نرون‌های متغیر بین ۱۰ تا ۲۰ نرون می‌باشد. در ایجاد و آموزش شبکه نیز از شبکه پیش‌روی پسانتشار استفاده شده است که مدل‌های برازش داده شده بر سری‌های زمانی در جدول (۲) ارائه شده‌اند و در توضیح جدول (۲) می‌توان تعداد نرون‌های ورودی در مدل را در جدول (۳) نشان داد.

## نتیجه گیری

در این مطالعه فقط از دبی رودخانه در برآورد استفاده شده است و باید در نظر داشت که علاوه بر دبی رودخانه و استفاده از تأثیر دبی رودخانه در روزهای قبل و بازم با توجه به چرخه هیدرولوژی عوامل دیگری چون بارندگی، مؤثر می‌باشد. با توجه به نتایج نشان داده شده در شکل (۳) مربوط به داده‌های جریان کم‌آبی و نیز با توجه به ضریب تبیین، پیش‌بینی در داده‌های مینیمم یک روزه بهترین پیش‌بینی را ارائه داده است و پس از آن سری‌های زمانی سه، پنج و هفت روزه، به‌ترتیب، بهترین پیش‌بینی را انجام داده‌اند. اما در پیش‌بینی پرآبی که

در شکل (۴) نشان داده شده‌اند، در برازش مدلی که بر سری‌های زمانی ۱، ۳، ۵ و ۷ روزه صورت گرفته است، پراکنش پیش‌بینی صورت گرفته نسبت به خط یک به یک ارائه شده است و بهترین برازش مربوط به دوره‌های ۵ روزه است.

با استفاده از آماره MAE و RMSE برای مقایسه مدل‌های برازش شده بر سری‌های زمانی ۱، ۳، ۵ و ۷ روزه نشان داده شده است که برای سری ۱ و ۷ روزه کم‌آبی‌ها مدل SARIMA مناسب‌تر از شبکه عصبی می‌باشد و برای سری ۳ و ۵ روزه کم‌آبی‌ها شبکه عصبی نسبت به مدل SARIMA مناسب‌تر است. در پرآبی‌ها نیز با استفاده از آماره MAE، مدل SARIMA در سری زمانی یک روزه و ANN در سری زمانی ۳ و ۵ و ۷ روزه نتایج مناسب‌تری ارائه داده است.

همان‌طور که در نمودارهای ۱ به ۱ نشان داده شده است، به‌طور چشمی نیز می‌توان به این نتیجه رسید که پراکندگی داده‌های جریان‌های کم‌آبی نسبت به خط ۱ به ۱، در مقایسه با داده‌های پرآبی کم‌تر می‌باشد که همان نتیجه مناسب‌تر و بهتر برآورد داده‌های جریان‌های کم‌آبی نسبت به پرآبی‌ها را که در نتایج R شبکه عصبی نیز نشان داده شده است، نمایش می‌دهد.

## منابع

نیرومند، ح.ع. ۱۳۷۶، تحلیل سری‌های زمانی، انتشارات دانشگاه فردوسی مشهد، ویرایش دوم، ۴۰۴ صفحه.

شریفان، ح. و ب. قهرمان، ۱۳۸۵. بررسی و ارزیابی پیش‌بینی باران با تکنیک سری‌های زمانی در استان گلستان. دومین کنفرانس مدیریت منابع آب ایران، اصفهان، بهمن ماه ۱۳۸۵.

Baareh, M.A.K., Sheta, A.F and Al Khnaifes, K.H. 2006. Forecasting river flow in the USA: A comparison between auto-regression and neural network non-parametric models. Proceedings of the 6th WSEAS International Conference on Simulation, Modelling

- Streamflow Forecasting: Arima vs Neural network, American conference on applied mathematics (MATH '08), Harvard, Massachusetts, USA.
- Keskin, M.E., Taylan, E.D. 2010. Artificial Intelligent Models For Flow Prediction: A Case Study On Alara Stream, Journal of Engineering Science and Design 1;1: 8-13.
- Kisi, O. 2004. River Flow Modeling Using Artificial Neural Networks. Journal of hydrologic engineering © ASCE. 60-63.
- Kisi, O. 2007. Development of Streamflow-Suspended Sediment Rating Curve Using a Range Dependent Neural Network, International Journal of Science and Technology. 2:1:49-61.
- Mustafa, M.R., Isa, M.H., Rezaur, R.B. 2011. A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River-A Case Study in Malaysia. Journal of World Academy of Science, Engineering and Technology . 81. 372-376.
- Sharifan, H., 2006, Optimization of Cropping Pattern and Intensification Under Uncertain Quantity and Quality of Irrigation Water, Ph.d thesis, Tarbiat Modarres University, 212p.
- Sharifan, H and Ghahraman, B. 2007. Evaluation of rainfall forecasting in Golestan province using time series, Journal of Agricultural Sciences and Natural Resources, vol.14:3:196-209.
- Zhou, H., Peng, Y., Liang, G. 2008. The Research of Monthly Discharge Predictor-corrector Model Based on Wavelet Decomposition. Earth and Environmental Science. Journal of Water Resources Management. 22:2: 217-227.
- and Optimization, (SMO'06), Stevens Point, Wisconsin, USA, pp:7-12.
- Box G.E.P., Jenkins, G.M. 1976, Time Series Analysis: Forecasting and Control. Holden Day Inc. San Francisco, CA., 2 edition, 575p.
- Box GEP, Jenkins, G.M. 1976, Time Series Analysis, Forecasting and Control. Holden Day Inc. San Francisco, CA.
- Bhattacharya, B., Solomatine, D.P. 2000, Application of artificial neural network in stage-discharge relationship, 4-th International Conference on Hydroinformatics, Iowa City, USA.
- Cigizoglu, H.K. 2003, a. Incorporation of ARMA models into flow forecasting by artificial neural networks. Journal of Environmetrics, 14. 417-427 .
- Cigizoglu, H.K. 2003, b. Estimation, forecasting and extrapolation of river flows by artificial neural networks. Hydrological Sciences-Journal-des Sciences Hydrologiques, 48:3:349-361.
- Danh, T.N., Phien, H.N., Gupta, A.D. 1999. Neural network models for river flow forecasting. <http://www.wrc.org.za>.
- Dibike, Y.B., Solomatine, D.P. 2001. River flow forecasting using artificial neural networks, Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere. 26:1: 1-7.
- Firat, M. 2008. Comparison of Artificial Intelligence Techniques for river flow Forecasting. Hydrology and Earth Syst. Sci., 12:123-139.
- Frausto-Solis, J., Pita, E., Lagunas, J. 2008. Short-term



## Forecasting Low and High Monthly Discharge Using a Stochastic Model and Artificial Intelligence

H. sharifan<sup>1</sup>, F. Pazhoohesh<sup>2\*</sup>, A.A. Dehghani<sup>3</sup>

Received: Dec.8, 2013 Accepted: Sep. 10, 2014

### Abstract

Forecasting the low and high flow of rivers is really important, especially in areas where surface water resources are considered as the main source of drinking and agricultural purposes. In this paper, the monthly low and high flow time series of Gorganrud river have been modeled and forecasted using a stochastic model (ARIMA) and Artificial Intelligence (ANN). For monthly Low and high flow, the moving average value of one, three, five and seven daily flow was considered. At the end, the low flow series had better result in Stochastic model and neural network. According to the mean absolute error (MAE), in 1 and 7 daily low flow series, Stochastic model, SARIMA, had better results, and in 3 and 5 daily low flow series, the artificial intelligence, ANN, show better results. In high flow series, in 1 daily time series, Stochastic model (SARIMA), and in ۳, ۵ and ۷ daily time series, ANN were appropriate.

**Key words:** Monthly low-flow, Monthly high flow, Time series models, ARIMA, Artificial Neural Network (ANN).

---

1- Associate Professor, Department of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources

2- former MSc. student of Water Resources Engineering, faculty of Soil and Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources

3- Associate Professor, Department of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources

(\*-Corresponding Author Email: [f.pazhoohesh.f@gmail.com](mailto:f.pazhoohesh.f@gmail.com))