



دوره ۳۲، شماره ۲، شماره پیاپی ۱۳۳، تابستان ۱۳۹۸، صفحات ۱۸-۲  
شناسه‌ی دیجیتال: 10.22092/wmej.2018.123630.1157

# پژوهش‌های آبخیزداری

## ارزیابی کارکرد مدل‌های برنامه‌ریزی ژنتیک و خودهمبسته‌ی میانگین متحرک در پیش‌بینی آب‌دهی روزانه در آبخیز امامه

محبوبه معتمدنیا

(نویسنده‌ی مسئول)\* دکترای علوم و مهندسی آبخیزداری

کمال کریمی‌زارچی

دانشجوی کارشناسی‌ارشد کنترل و مدیریت بیابان، دانشکده‌ی منابع طبیعی، دانشگاه یزد

احمد نوحه‌گر

استاد گروه آموزش، برنامه‌ریزی و مدیریت محیط زیست، دانشکده‌ی محیط زیست، دانشگاه تهران، کرج

مریم صابری‌اناری

مدرس دانشگاه فنی و حرفه‌یی، یزد

آرش ملکیان

دانشیار گروه احیای مناطق خشک و کوهستانی، دانشکده‌ی منابع طبیعی، دانشگاه تهران، کرج

\*رایانامه‌ی نویسنده‌ی مسئول: mmoatamednia@yahoo.com

تاریخ دریافت: ۱۶ مهر ۱۳۹۷ تاریخ پذیرش: ۶ آذر ۱۳۹۷

### چکیده

کم‌بود منابع آب و توجه به توسعه‌ی پایدار، تأمین آب را برای همه‌ی نیازهای موجود ناممکن کرده است. از آن‌جا که پیش‌بینی دقیق جریان رودها در مدیریت منابع آب اهمیت بسزایی دارد، آب‌دهی رود با کاربرد مدل‌های برنامه‌ریزی ژنتیک و خودهمبسته‌ی میانگین متحرک در آبخیز امامه، استان تهران مدل‌سازی و پیش‌بینی شد. از داده‌های درازمدت باران، دما، آب‌دهی، رطوبت نسبی و تبخیر استفاده شد. نتایج نشان داد که برنامه‌ریزی ژنتیک خطای کم‌تری دارد و توانسته‌است به‌خوبی آب‌دهی مشاهده‌یی را تخمین بزند. مدل ۵۴ با ورودی‌های دما، باران، و تأخیرهای باران تا دو روز، و رطوبت نسبی و تبخیر و تأخیر جریان تا دو روز، بهترین مدل با خطای ۰/۰۰۱، ۰/۰۳۱، و ۰/۰۰۹ در مرحله‌ی آموزش، و ۰/۰۰۱، ۰/۰۳۲، و ۰/۰۰۹ در مرحله‌ی آزمایش بود. علاوه بر این، خطای مدل‌های خطی خودهمبسته‌ی میانگین متحرک بسیار بیش‌تر است، و نه‌تنها در آب‌دهی‌های بیش‌تر، بل که در آب‌دهی‌های کم هم کارکرد مناسبی ندارد، و نتوانسته است نتیجه‌ی رضایت‌بخشی به‌دست دهد. استفاده از مدل برنامه‌ریزی ژنتیک به‌دلیل دقت بسیار زیاد با عمل‌گرهای اصلی و داده‌های به‌معیار شده توصیه می‌شود.

واژگان کلیدی: برنامه‌ریزی ژنتیک، آبخیز امامه، مدل‌سازی جریان رود، مدل‌های خودهمبسته‌ی میانگین متحرک

## مقدمه

و همکاران (۲۰۰۳) با استفاده از همین مدل نشان داد که برنامه‌ریزی ژنتیک نسبت به شبکه‌ی عصبی برتری چشم‌گیری در پیش‌بینی بارش روان‌آب در حوزه‌های شهری دارد. نتایج جایاواردنا و همکاران (۲۰۰۵) نشان داد که این مدل به‌خوبی توانسته است میزان روان‌آب خروجی در دو آبخیز نسبتاً بزرگ در چین را پیش‌بینی کند. نتایج آن با داده‌های واقعی اختلاف کمی دارد، و روان‌آب هر روز به روزهای قبل و بازندگی وابستگی بیش‌تری دارد. نتایج آیتک و همکاران (۲۰۰۸) در مدل‌سازی بارش-روان‌آب رودخانه‌یی در ایالت پنسیلوانیای امریکا در مقیاس روزانه با استفاده از مدل‌های شبکه‌ی عصبی و برنامه‌ریزی ژنتیک نشان‌دهنده‌ی برتری برنامه‌ریزی ژنتیک به مدل شبکه‌ی عصبی است. گوون (۲۰۰۹) برای پیش‌بینی آب‌دهی جریان روزانه‌ی رود شویلیکیل در ایالات متحده از همین مدل استفاده، و نتایج حاصل را با مدل‌های شبکه‌ی عصبی مقایسه کرد. هر دو مدل نتایج پذیرفتنی داشت، اما دقت مدل برنامه‌ریزی ژنتیک بیش‌تر بود. از بین مدل‌های شبکه‌ی عصبی-فازی تطبیقی، برنامه‌ریزی ژنتیکی، و بردار پشتیبان از خودهمبسته‌ی میانگین متحرک، شبکه‌ی عصبی مصنوعی عمل‌کرد بهتری در پیش‌بینی جریان رودخانه در مقیاس ماهانه داشت (وانگ و همکاران ۲۰۰۹). نتایج قربانی و همکاران (۲۰۱۰) در روندیابی سیلاب رودخانه‌ی قزل ایرماق ترکیه نشان داد که از میان سه مدل برنامه‌ریزی ژنتیک، شبکه‌ی عصبی مصنوعی، و نروفازی، مدل برنامه‌ریزی ژنتیک با دقت بیش‌تری آب‌سنجی خروجی را شبیه‌سازی می‌کند. نتایج بشری و وفاخواه (۲۰۱۱) در پیش‌بینی آب‌دهی ماهانه‌ی آبخیز کرخه نشان داد که تحلیل روند بهترین پیش‌بینی است و پس از آن مدل‌های مختلف خودهمبسته با میانگین متحرک با اختلاف جزئی در اولویت بعدی است. ظهیری و همکاران (۲۰۱۲) نشان دادند که عمل‌کرد تخمین آب‌دهی جریان رودخانه‌های سیلابی با مدل برنامه‌ریزی ژنتیک زیاد است و آب‌دهی‌های محاسبه‌شده با آب‌دهی‌های مشاهده‌شده مطابقت خوبی دارد، و ضریب تبیین برای مراحل واسنجی و صحت‌سنجی ۰/۹۹ و ۰/۹۶ است. ولی‌پور و همکاران (۲۰۱۳) در پیش‌بینی جریان ورودی به مخزن سد دز، افزایش دقت پیش‌بینی سنج‌ها و مقایسه‌ی آن‌ها با مدل شبکه‌ی عصبی مصنوعی پویای آماری، نشان دادند که شبکه‌ی عصبی بهترین مدل برای پیش‌بینی

افزایش جمعیت کره‌ی زمین و محدودیت منابع طبیعی انسان را به چاره‌اندیشی و گزینش راه‌کارهایی برای صرفه‌جویی، بهره‌برداری بهینه و آینده‌نگری در این منابع سوق داده است. آب یکی از نیازهای ضروری و حیاتی انسان است که دو سوم سطح کره‌ی زمین را گرفته است، اما به دلیل محدودیت‌های زمانی و مکانی آن، و حجم ناچیز آب شیرین دست‌رس، مدیریت و برنامه‌ریزی در این زمینه گریزناپذیر است. ضرورت استفاده‌ی بهینه از منابع محدود آب و کاربرد مدیریت‌های صحیح با توجه به جدیدترین مدل‌های علمی و مهندسی کاملاً احساس می‌شود. این موضوع در کشورهای خشک و نیمه‌خشکی همچون ایران که محدودیت زیادی در منابع آبی دارند حیاتی‌تر است (مسعودیان ۲۰۰۳؛ گلنارکار و همکاران ۲۰۱۷). نیاز به الگوهای مناسب تبدیل بارش به روان‌آب در جوامع پیشرفته‌ی امروزی در کشاورزی، آب‌خانگی، بهره‌برداری از مخزن‌سدها، پیش‌بینی، و سامانه‌های هشدار و مهار سیلاب برای کاهش آسیب‌های مالی و جانی مشهود است. بنابراین داشتن مدلی برای پیش‌بینی برای آینده در تمامی علوم و از جمله در مهندسی آب همواره در نظر بوده است. یکی از راه‌های بررسی دقیق فرآیند بارش-روان‌آب استفاده از مدل‌های هوشمند در یافتن رابطه‌ی بین داده‌های ورودی و خروجی است (دربندی و همکاران، ۲۰۱۴). پیش‌بینی روان‌آب رودخانه پژوهش‌گران را در جهت استفاده از سامانه‌های هوشمند به دلیل کارکرد خوب و نیازنداشتن به رابطه‌های پیچیده ترغیب کرده است (معمدنی و همکاران ۲۰۱۷). یکی از مدل‌های پرکاربرد از بین مدل‌های هوشمند، برنامه‌ریزی ژنتیک (GP)<sup>۱</sup> است؛ که به دلیل دادن مدلی صریح بین ورودی‌ها و خروجی توسعه‌یافته و در زمینه‌های گوناگون کاربردهای موفقی داشته است. در حقیقت، برنامه‌ریزی ژنتیک تعمیم‌یافته‌ی الگوریتم ژنتیک است؛ این مدل شاخه‌یی از الگوریتم گردشی است، و مبنای آن نظریه‌ی تکاملی داروین است (آیتک و همکاران ۲۰۰۸؛ سلطانی و همکاران ۲۰۱۰؛ مسعودی و همکاران ۲۰۱۲). نتایج پیش‌بینی روان‌آب ساعتی حوزه‌ی اروگلد فرانسه با استفاده از مدل برنامه‌ریزی ژنتیک (خو و همکاران ۲۰۰۱) نشان داد که برنامه‌ریزی ژنتیک توانایی پیش‌بینی دقیق روان‌آب را در تمام فاصله‌های زمانی و به‌ویژه فاصله‌های زمانی کوتاه‌تر از زمان تمرکز حوزه دارد. تحقیقات دورادو

1- genetic programming (GP)

این است که موضوع اصلی را به زیرموضوع‌هایی حل‌شدنی تقسیم می‌کند، به طوری که دشواری مساله را در هنگام برخورد با مجموعه‌های داده‌ی پرنوسان و پربارش کاهش می‌دهد. مقایسه‌ی نتایج این الگوریتم با دیگر الگوریتم‌های یادگیری ماشینی مانند برنامه‌ریزی ژنتیک بی‌الگوریتم، ماشین بردار پشتیبان، شبکه‌ی عصبی تابع پایه‌ی شعاعی، و مدل شاخه‌ی درختی M5 برتری این مدل با این نوع الگوریتم را تایید کرد. پژوهشگران نشان داده‌اند که دقت و عمل‌کرد برنامه‌ریزی ژنتیک خوب است و می‌تواند تا حد زیادی رابطه‌ی بارش و روان‌آب را تخمین بزند، اما هیچ‌کدام این مدل را با مدل آماری مقایسه نکرده‌اند. در این تحقیق سعی شد برای پیش‌بینی جریان رودخانه و مدل‌سازی آبخیز امامه (استان تهران، به نمایندگی مناطق جنوبی رشته‌کوه البرز)، مدل هوشمند (نسبتاً جدید) و آماری (قدیمی و سنتی) یعنی دو مدل برنامه‌ریزی ژنتیک و آماری خودهمبسته‌ی میانگین متحرک مقایسه شود. حجم زیادی از ساختارهای پیشنهادشده با دقت و در نظر گرفتن روزهای متوالی متغیرهای مختلف هواشناسی و آب‌سنجی به کار گرفته شد، که از نوآوری‌ها و نقطه‌ی قوت این پژوهش است.

#### مواد و روش‌ها منطقه‌ی پژوهش

آبخیز معرّف امامه در استان تهران با متوسط بارندگی ۷۵۶/۶۰ میلی‌متر و شیب ۴۸/۵ درصد در بین عرض‌های جغرافیایی ۳۵°۵۱'۰۰" تا ۳۵°۵۷'۰۰" شمالی و طول‌های جغرافیایی ۵۱°۳۲'۰۰" تا ۵۱°۳۹'۰۰" شرقی است. این آبخیز با مساحت ۳۷/۲ کیلومتر مربع یکی از سرشاخه‌های رود جاجرود در بالادست سد لتیان است، که از بلندی‌های جنوبی دره‌ی لار سرچشمه می‌گیرد (رحیمی‌خوب و محمودی ۲۰۱۲؛ معتمدنیا و همکاران ۲۰۱۷).

جریان ورودی به مخزن سد دز است. داننده‌مهر و همکاران (۲۰۱۴) در پیش‌بینی جریان در رودخانه‌ی در ترکیه از مدل‌های مختلف استفاده کردند. از میان این مدل‌ها به ترتیب برنامه‌ریزی ژنتیک، شبکه‌ی عصبی موجکی، و شبکه‌ی عصبی پرسپترون سه‌لایه عمل‌کرد خوبی داشت. ظهیری و عظمت الله (۲۰۱۴) برای پیش‌بینی آب‌دهی جریان در مقاطع مرکب از دو مدل برنامه‌ریزی ژنتیک و شاخه‌ی درختی M5 استفاده کردند. نتایج نشان داد که هرچند دقت هر دو زیاد بود، دقت برنامه‌ریزی ژنتیک بیش‌تر از مدل درختی بود. احمدی و همکاران (۲۰۱۵) برای پیش‌بینی جریان روزانه‌ی رود باراندوزچای در ارومیه از دو مدل برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان (SVM) استفاده کردند. بدین منظور از ۸۰ و ۲۰ درصد داده‌های جریان این رودخانه در ایستگاه دیزج به ترتیب برای آموزش و آزمایش در سال‌های آماری ۱۳۸۵ تا ۱۳۸۹ استفاده کردند. نتایج نشان داد که هر دو مدل جریان یک، دو و تا سه روز قبل بیش‌ترین دقت را در مرحله‌ی صحت‌سنجی داشت. دقت مدل‌ها با افزایش آب‌دهی کاهش یافت. دقت مدل GP با R و RMSE برابر با ۰/۹۷۸ و ۱/۶۶ اندکی بهتر از مدل SVM با اندازه‌های ۰/۹۷۶ و ۱/۸۰ بود، اما مدل SVM بسیار ساده‌تر از GP شناخته شد. حسینی و مهجوری (۲۰۱۶) برای مدل‌سازی بارش روان‌آب در استان قم از مدل‌های مختلف سامانه‌های هوشمند استفاده کردند. نتایج نشان داد که مدل ترکیبی رگرسیون بردار پشتیبان و شبکه‌ی عصبی زمین‌ریخت‌شناسی عمل‌کرد بهتری از مدل‌های مبتنی بر شبکه‌ی عصبی مصنوعی دارد. کرامر و همکاران (۲۰۱۸) از الگوریتم DGP<sup>۲</sup> استفاده و آن را در پیش‌بینی بارش ۴۲ شهر مختلف اروپا و آمریکا آزمایش کردند. آنان معتقد بودند بارش مثال بسیار خوبی برای امتحان کردن این الگوریتم است، زیرا ویژگی‌های منحصربه‌فردی از نوسان‌های زیاد و الگوهای آشفته را نشان می‌دهد، به طوری که چنین خصوصیتی در داده‌های گروه زمانی دیگر وجود ندارد. اساس این الگوریتم



شکل ۱- نمایی از ایستگاه به ترتیب آبسنجی کمرخانی (الف) و ایستگاه‌های هواشناسی امامه (ب)، کلوکان (ج) و راحت آباد (د) در آبخیز معرف امامه.

### روش کار

برای این پژوهش داده‌های آبسنجی و هواشناسی بارندگی، دما، تبخیر، رطوبت نسبی، و آب‌دهی، و در مقیاس روزانه ایستگاه هواشناسی امامه در مرکز حوزه و ایستگاه آبسنجی کمرخانی در خروجی آبخیز امامه به کار گرفته شد (شکل ۱). اندازه‌گیری تبخیر در این حوزه با تشتک تبخیر رده‌ی A از نوع گرد و از جنس آهن گالوانیزه است (شکل ۱). میزان تبخیر بر اساس کاهش ارتفاع آب اندازه‌گیری می‌شود. قطر آن ۱۲۲ سانتی‌متر و عمق آن ۲۵۴ میلی‌متر است و روی پایه‌ی چوبی جا می‌گیرد تا با زمین تبادل حرارتی نداشته باشد. برای خنثا کردن اثر باد، اندازه‌گیری در استوانه‌یی به قطر حدود ۱۰ سانتی‌متر انجام می‌شود (مهدوی ۲۰۰۲). برای آن که کم‌ترین مقدار از داده‌ها حذف شود، و طول دوره‌ی داده‌برداری بیش‌ترین باشد، داده‌های دوره‌ی زمانی مشترک

۱۳۵۰-۱۳۴۹ تا ۱۳۹۱-۱۳۹۰ (۴۲ سال داده‌ی روزانه) در نظر گرفته شد (سازمان تحقیقات منابع آب ایران (تماب)، سازمان آب منطقه‌یی استان تهران، و سازمان هواشناسی کشور). پیش‌پردازش داده‌ها یعنی مرتب‌بودن، کفایت، و درستی اجرا شد و داده‌های ناقص با ضریب همبستگی<sup>۳</sup> در نرم‌افزار SPSS.21 اصلاح شد. از آن‌جا که در این پژوهش از گروه زمانی استفاده شد و هر واقعه‌یی می‌توانست از وقایع روزهای گذشته تاثیر گیرد و بر وقایع آینده نیز تاثیر بگذارد، متغیرهای ورودی باید طوری انتخاب و تعیین شود که شمار کمی از الگوهای ورودی بتواند ویژگی‌های منحصر به فرد داده‌ها را تعیین کند. یکی از راه‌های تعیین مناسب‌ترین تأخیرهای زمانی، تهیه‌ی نمودارهای خودهمبستگی<sup>۴</sup>، خودهمبستگی جزیی<sup>۵</sup> و همبستگی متقاطع<sup>۶</sup> است (وو و همکاران، ۲۰۰۹؛ هیو و همکاران، ۲۰۱۲). برای ایجاد تأخیرهای زمانی لازم

3- Correlation Coefficient

4- Autocorrelation Function (ACF)

5- Partial Autocorrelation Function (PACF)

6- Cross Correlation

مجموعه عملگرهای ریاضی استفاده شد. مجموعه‌ی اول از عملگرهای پیش‌فرض نرم‌افزار، و دیگری از چهار عملگر اصلی است، و در این پژوهش از عملگرهای ریاضی اصلی (+، -، × و /) و تابع ریاضی توان استفاده شد. گام چهارم، انتخاب تابع پیوندی است که از تابع جمع‌کننده برای ایجادکردن پیوند بین زیرشاخه‌ها استفاده می‌شود. گام آخر تعیین عمل‌گرهای ژنتیک و نرخ هر یک از آن‌ها است (جایاوردنا و همکاران ۲۰۰۵؛ یوماز و همکاران ۲۰۱۴).

مراحل کار در مدل آماری گروه زمانی اولین مرحله‌ی ایستا کردن گروه زمانی است. در حقیقت مفهوم اساسی ایستایی این است که قوانین احتمالی حاکم بر فرآیند با زمان تغییر نمی‌کند. به عبارتی دیگر، میانگین و پراش گروه در طول زمان ثابت است (چتفیلد، ۲۰۱۰؛ داننده‌مهر و همکاران، ۲۰۱۴) و اگر داده‌ها نایستا باشد، برای ازبین بردن نایستایی پراش از تبدیل‌های باکس-کاکس (۱۹۶۴)، و برای ازبین بردن نایستایی در میانگین از مدل تفاضلی کردن با مرتبه‌ی تفاضلی  $d$  استفاده می‌شود. یکی از سودمندترین آزمون‌ها در این زمینه، آزمون دیکی فولر تعمیم یافته<sup>۷</sup> است (میندز و همکاران، ۲۰۰۴؛ طرازکار و صدق‌آمیز، ۲۰۰۸). با توجه به ازدیاد مدل‌های موجود، آزمون بربوش گادفری برای برازش مدل مناسب بر گروه زمانی، و برای صحت‌سنجی شاخص AIC<sup>۸</sup> به‌کاربرده شد. با توجه به معیارهای ارزیابی و منطقی بودن، بهترین مدل‌ها در قالب ۶۲ ساختار پیشنهاد شد. سرانجام، برای ارزیابی مدل‌های پیش‌بینی، میانگین مربع‌های خطا (MSE)، مجذور میانگین مربع‌های خطا (RMSE)، و میانگین مطلق خطا (MAE) به‌کار برده و نتایج با یکدیگر مقایسه شد (رابطه‌ی ۲ تا ۴).

$$MSE = \frac{\sum_{i=1}^N (Q_0 - Q_e)^2}{N} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{j=1}^N (Q_0 - Q_e)^2}{N}} \quad (3)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_0 - Q_e| \quad (4)$$

$Q_0$  مقدار مشاهده‌ی متغیر وابسته (آب‌دهی)،  $Q_e$  مقدار تخمینی متغیر وابسته (آب‌دهی تخمینی)، و  $N$  تعداد داده است.

متغیرهای ورودی برای مدل‌سازی در نرم‌افزار Minitab ۱۶، همبستگی متقاطع در سطح معنی‌داری ۰/۰۱ و ۰/۰۵ اجرا شد. داده‌های خام موجب افزایش خطا و کاهش سرعت محاسبه در نرم‌افزار می‌شد؛ برای رفع آن پیش‌فرض ورود داده‌ها به نرم‌افزار این است که باید قبل از انجام عملیات آن‌ها را به‌معیار (استاندارد) کرد (رابطه‌ی ۱) تا برای همگون شدن و یک‌دست شدن ارزش، در محدوده‌ی ۰ تا ۱ و یا ۱- تا ۱ قرار گیرند (سارانگی و باتاچاریا ۲۰۰۵؛ سلیمانی ۲۰۰۹؛ معتمدنیا و همکاران ۲۰۱۷).

$$XN = \frac{X \max - Xi}{X \max - X \min} \quad (1)$$

که در آن  $XN$  داده‌ی بهنجار شده،  $X \max$  داده‌ی بیشینه،  $Xi$  داده‌ی درنظر، و  $X \min$  داده‌ی کمینه است.

با استفاده از رابطه‌ی (۱) داده‌ها بهنجار، و در محدوده‌ی صفر تا یک گذاشته شد. داده‌ها در هر دو مدل به دو بخش آموزش و آزمایش تقسیم شد. بیش‌تر داده‌ها باید در فرآیند آموزش شرکت داده شود، و مقادیر بیشینه و کمینه‌ی داده‌ها در مجموعه‌ی آموزش باشد. البته هیچ قانونی برای دسته‌بندی داده‌ها برای آموزش و آزمایش وجود ندارد و انتخاب آن با سعی و خطا است (وارنچوتیکول، ۲۰۰۳؛ یوسفی و همکاران، ۲۰۱۴)، بنابراین ۸۰٪ از داده‌ها برای آموزش (۱۳۴۹-۱۳۵۰ تا ۱۳۸۳-۱۳۸۴) و ۲۰٪ از آن برای آزمایش (۱۳۸۴-۱۳۸۳ تا ۱۳۹۱-۱۳۹۰) انتخاب شد (سلاجقه و همکاران، ۲۰۰۹؛ هیو و همکاران، ۲۰۱۲؛ احمدی و همکاران، ۲۰۱۵). برای برنامه‌ریزی ژنتیک از نرم‌افزار GeneXprotools 5 استفاده شد. گام اول فرآیند اجرای مدل‌سازی در برنامه‌ریزی ژنتیک انتخاب تابع برازش مناسب است. تابع RMSE برای برازش انتخاب شد. گام دوم، انتخاب مجموعه‌ی پایانه‌ها (متغیرهای ورودی) و مجموعه‌ی تابع‌ها برای تولید کروموزوم‌ها است. مجموعه‌ی پایانه‌ها متشکل از داده‌های ورودی تاخیرهای زمانی باران، دما، تبخیر، رطوبت نسبی و تاخیر جریان در روزهای قبل است. انتخاب مجموع تابع‌ها نیز اگرچه صریح و ساده نیست، اما حدس اولیه و چندین بار امتحان و سعی و خطا می‌تواند سودمند و کافی باشد (داننده‌مهر و همکاران ۲۰۱۳ و ۲۰۱۴). گام سوم، تعیین ساختار و معماری کروموزوم‌ها و تعیین عملگرهای ریاضی است. برای مدل‌سازی جریان رود از دو

7- Augmented Dicky Fuller (ADF)

8- Akaike Information Criterion

### نتایج

داده‌های طولانی‌مدت (۴۲ سال) در مقیاس روزانه‌ی بارندگی، دما، تبخیر، رطوبت نسبی و آب‌دهی (جدول ۱) به کار برده شد. نتیجه‌ی دو مدل در جدول‌های ۲ و ۳ آورده شده است.

برای پیش‌بینی آب‌دهی رود در آبخیز امامه مدل هوشمند برنامه‌ریزی ژنتیکی و مدل‌های خطی و آماری خودمبسته‌ی میانگین متحرک در قالب ۶۲ ساختار به کار گرفته شد.

جدول ۱- مدل‌های نهایی آبخیز امامه.

شماره مدل	ورودی	خروجی
۱	$P_t$	$Q_t$
۲	$E_t$	$Q_t$
۳	$RH_t$	$Q_t$
۴	$T_t$	$Q_t$
۵	$Q_{t-1}$	$Q_t$
۶	$P_t, P_{t-1}$	$Q_t$
۷	$P_t, Q_{t-1}$	$Q_t$
۸	$E_t, Q_{t-1}$	$Q_t$
۹	$RH_t, Q_{t-1}$	$Q_t$
۱۰	$T_t, Q_{t-1}$	$Q_t$
۱۱	$Q_{t-1}, Q_{t-2}$	$Q_t$
۱۲	$P_t, P_{t-1}, P_{t-2}$	$Q_t$
۱۳	$P_t, P_{t-1}, Q_{t-1}$	$Q_t$
۱۴	$P_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۱۵	$E_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۱۶	$RH_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۱۷	$T_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۱۸	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۱۹	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}$	$Q_t$
۲۰	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}$	$Q_t$
۲۱	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۲۲	$E_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۲۳	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۲۴	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۲۵	$P_t, T_t, E_t, RH_t$	$Q_t$
۲۶	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۲۷	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}$	$Q_t$
۲۸	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۲۹	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۳۰	$E_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۳۱	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۳۲	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۳۳	$P_t, T_t, E_t, RH_t, Q_{t-1}$	$Q_t$
۳۴	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۳۵	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۳۶	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۳۷	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۳۸	$E_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۳۹	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$

در رابطه‌های بالا  $Q_t$  آب‌دهی خروجی،  $P_t$  میانگین بارندگی،  $E_t$  میانگین تبخیر،  $RH_t$  میانگین رطوبت نسبی،  $T_t$  میانگین دما، و  $Q_{t-1}$  تا  $Q_{t-6}$  آب-دهی یک روز قبل تا شش روز قبل است.

ادامه‌ی جدول ۱- مدل‌های نهایی آبخیز امامه.

شماره مدل	ورودی	خروجی
۴۰	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۴۱	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t$	$Q_t$
۴۲	$P_t, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۴۳	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۴۴	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۴۵	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۴۶	$P_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۴۷	$E_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۴۸	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۴۹	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۵۰	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t, Q_{t-1}$	$Q_t$
۵۱	$P_t, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۵۲	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۵۳	$P_t, P_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۵۴	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}$	$Q_t$
۵۵	$P_t, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۵۶	$P_t, P_{t-1}, P_{t-2}, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۵۷	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$Q_t$
۵۸	$P_t, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۵۹	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$Q_t$
۶۰	$P_t, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$
۶۱	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	$Q_t$
۶۲	$P_t, P_{t-1}, P_{t-2}, T_t, E_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	$Q_t$

در رابطه‌های بالا  $Q_t$  آب‌دهی خروجی،  $P_t$  میانگین بارندگی،  $E_t$  میانگین تبخیر،  $RH_t$  میانگین رطوبت نسبی،  $T_t$  میانگین دما،  $P_{t-1}$  میانگین بارندگی یک روز قبل، و  $Q_{t-1}$  تا  $Q_{t-6}$  آب‌دهی یک روز قبل تا شش روز قبل است.


جدول ۲- نتیجه‌ی مدل‌های برنامه‌ریزی ژنتیک.

شماره‌ی مدل	آموزش			آزمایش		
	MAE	RMSE	MSE	MAE	RMSE	MSE
۱	۰/۰۰۶	۰/۰۷۸	۰/۰۱۵	۰/۰۰۸	۰/۰۸۹	۰/۰۱۶
۲	۰/۰۰۶	۰/۰۷۹	۰/۰۱۵	۰/۰۰۸	۰/۰۹۰	۰/۰۱۶
۳	۰/۰۰۷	۰/۰۸۴	۰/۰۱۵	۰/۰۰۹	۰/۰۹۵	۰/۰۱۷
۴	۰/۰۰۶	۰/۰۷۷	۰/۰۱۵	۰/۰۰۷	۰/۰۸۹	۰/۰۱۶
۵	۰/۰۰۵	۰/۰۶۸	۰/۰۱۴	۰/۰۰۶	۰/۰۷۸	۰/۰۱۵
۶	۰/۰۰۶	۰/۰۷۶	۰/۰۱۵	۰/۰۰۷	۰/۰۸۸	۰/۰۱۶
۷	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳	۰/۰۰۵	۰/۰۷۷	۰/۰۱۵
۸	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳	۰/۰۰۵	۰/۰۷۷	۰/۰۱۵
۹	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳	۰/۰۰۵	۰/۰۷۷	۰/۰۱۵
۱۰	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳	۰/۰۰۵	۰/۰۷۷	۰/۰۱۵
۱۱	۰/۰۰۵	۰/۰۶۸	۰/۰۱۴	۰/۰۰۶	۰/۰۷۸	۰/۰۱۵
۱۲	۰/۰۰۶	۰/۰۷۱	۰/۰۱۴	۰/۰۰۷	۰/۰۸۶	۰/۰۱۶
۱۳	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳
۱۴	۰/۰۰۳	۰/۰۵۹	۰/۰۱۲	۰/۰۰۴	۰/۰۶۸	۰/۰۱۴
۱۵	۰/۰۰۳	۰/۰۵۹	۰/۰۱۲	۰/۰۰۴	۰/۰۶۸	۰/۰۱۴
۱۶	۰/۰۰۳	۰/۰۵۹	۰/۰۱۲	۰/۰۰۴	۰/۰۶۸	۰/۰۱۴
۱۷	۰/۰۰۳	۰/۰۵۹	۰/۰۱۲	۰/۰۰۴	۰/۰۶۸	۰/۰۱۴
۱۸	۰/۰۰۵	۰/۰۶۸	۰/۰۱۴	۰/۰۰۶	۰/۰۷۸	۰/۰۱۵
۱۹	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳	۰/۰۰۵	۰/۰۷۷	۰/۰۱۵
۲۰	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۵	۰/۰۱۳
۲۱	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳
۲۲	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۵	۰/۰۱۳
۲۳	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۶	۰/۰۱۳
۲۴	۰/۰۰۲	۰/۰۴۸	۰/۰۱۱	۰/۰۰۳	۰/۰۶۰	۰/۰۱۳
۲۵	۰/۰۰۶	۰/۰۷۵	۰/۰۱۵	۰/۰۰۷	۰/۰۸۷	۰/۰۱۶
۲۶	۰/۰۰۵	۰/۰۶۹	۰/۰۱۴	۰/۰۰۶	۰/۰۷۹	۰/۰۱۵
۲۷	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲	۰/۰۰۴	۰/۰۶۳	۰/۰۱۳
۲۸	۰/۰۰۳	۰/۰۵۵	۰/۰۱۲	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳
۲۹	۰/۰۰۳	۰/۰۵۸	۰/۰۱۲	۰/۰۰۴	۰/۰۶۶	۰/۰۱۳
۳۰	۰/۰۰۳	۰/۰۵۸	۰/۰۱۲	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳
۳۱	۰/۰۰۳	۰/۰۵۸	۰/۰۱۲	۰/۰۰۴	۰/۰۶۷	۰/۰۱۳
۳۲	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۶	۰/۰۱۳
۳۳	۰/۰۰۳	۰/۰۵۷	۰/۰۱۲	۰/۰۰۴	۰/۰۶۵	۰/۰۱۳
۳۴	۰/۰۰۵	۰/۰۶۹	۰/۰۱۴	۰/۰۰۶	۰/۰۷۹	۰/۰۱۵
۳۵	۰/۰۰۲	۰/۰۴۶	۰/۰۱۱	۰/۰۰۲	۰/۰۴۸	۰/۰۱۱
۳۶	۰/۰۰۲	۰/۰۴۸	۰/۰۱۱	۰/۰۰۳	۰/۰۶۰	۰/۰۱۳
۳۷	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳	۰/۰۰۵	۰/۰۷۲	۰/۰۱۴
۳۸	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳	۰/۰۰۵	۰/۰۷۲	۰/۰۱۴
۳۹	۰/۰۰۴	۰/۰۶۴	۰/۰۱۳	۰/۰۰۵	۰/۰۷۴	۰/۰۱۴

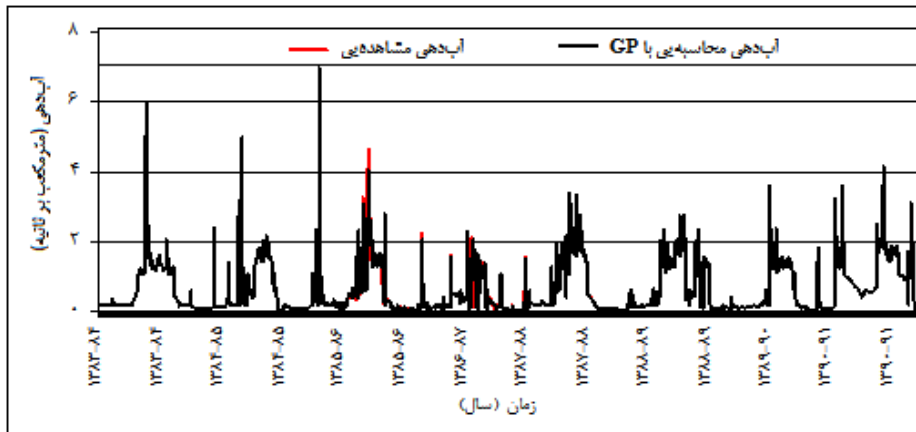


ادامه‌ی جدول ۲- نتیجه‌ی مدل‌های برنامه‌ریزی ژنتیک.

شماره‌ی مدل	آموزش			آزمایش		
	MAE	RMSE	MSE	MAE	RMSE	MSE
۴۰	۰/۰۶۳	۰/۰۰۴	۰/۰۱۳	۰/۰۷۱	۰/۰۰۵	۰/۰۱۴
۴۱	۰/۰۷۰	۰/۰۰۵	۰/۰۱۴	۰/۰۸۵	۰/۰۰۷	۰/۰۱۵
۴۲	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱
۴۳	۰/۰۶۹	۰/۰۰۵	۰/۰۱۴	۰/۰۸۴	۰/۰۰۷	۰/۰۱۵
۴۴	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۸	۰/۰۰۳	۰/۰۱۲
۴۵	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۸	۰/۰۰۳	۰/۰۱۲
۴۶	۰/۰۶۶	۰/۰۰۴	۰/۰۱۳	۰/۰۷۶	۰/۰۰۵	۰/۰۱۵
۴۷	۰/۰۶۶	۰/۰۰۴	۰/۰۱۳	۰/۰۷۶	۰/۰۰۵	۰/۰۱۵
۴۸	۰/۰۶۶	۰/۰۰۴	۰/۰۱۳	۰/۰۷۶	۰/۰۰۵	۰/۰۱۵
۴۹	۰/۰۶۵	۰/۰۰۴	۰/۰۱۳	۰/۰۷۵	۰/۰۰۵	۰/۰۱۵
۵۰	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱
۵۱	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱
۵۲	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۷	۰/۰۰۳	۰/۰۱۲
۵۳	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۸	۰/۰۰۳	۰/۰۱۲
۵۴	۰/۰۳۱	۰/۰۰۱	۰/۰۰۹	۰/۰۳۲	۰/۰۰۱	۰/۰۰۹
۵۵	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱	۰/۰۵۰	۰/۰۰۲	۰/۰۱۲
۵۶	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۷	۰/۰۰۳	۰/۰۱۲
۵۷	۰/۰۴۵	۰/۰۰۲	۰/۰۱۰	۰/۰۴۵	۰/۰۰۲	۰/۰۱۰
۵۸	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱	۰/۰۵۵	۰/۰۰۳	۰/۰۱۲
۵۹	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱
۶۰	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۵۷	۰/۰۰۳	۰/۰۱۲
۶۱	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱	۰/۰۴۹	۰/۰۰۲	۰/۰۱۱
۶۲	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱	۰/۰۵۵	۰/۰۰۳	۰/۰۱۲



شکل ۲- بهترین پیش‌بینی آب‌دهی مشاهده‌ی و پیش‌بینی شده به مدل GP در آبخیز امامه (آموزش).




شکل ۳- بهترین پیش‌بینی آبدهی مشاهده‌یی و پیش‌بینی‌شده به مدل GP در آبخیز امامه (آزمایش).

جدول ۳- نتیجه‌ی مدل‌های آماری خودهمبسته‌ی میانگین متحرک.


آزمایش				آموزش				نوع مدل	شماره‌ی مدل
ACI	MAE	RMSE	MSE	ACI	MAE	RMSE	MSE		
۳/۴۰۰	۰/۷۲۶	۰/۸۲۶	۰/۶۸۳	۲/۸۸۰	۰/۶۰۰	۰/۷۵۰	۰/۵۶۲	ARMA(2, 2)	۱
۳/۴۰۰	۰/۷۲۷	۰/۸۲۷	۰/۶۸۴	۲/۸۹۰	۰/۶۲۰	۰/۷۶۰	۰/۵۷۸	ARMA(2, 2)	۲
۳/۴۰۰	۰/۷۲۷	۰/۸۲۷	۰/۶۸۴	۲/۹۲۰	۰/۶۴۲	۰/۷۷۱	۰/۵۹۴	ARMA(2, 2)	۳
۳/۳۸۰	۰/۷۲۶	۰/۸۲۶	۰/۶۸۲	۲/۸۷۰	۰/۵۹۵	۰/۷۴۵	۰/۵۵۵	ARMA(1, 1)	۴
۲/۹۵۰	۰/۶۷۱	۰/۷۹۰	۰/۶۲۴	۲/۸۴۴	۰/۵۴۸	۰/۷۱۸	۰/۵۱۵	ARMA(0, 1)	۵
۳/۳۹۰	۰/۷۲۵	۰/۸۲۵	۰/۶۸۱	۲/۸۷۰	۰/۵۹۴	۰/۷۴۴	۰/۵۵۴	ARMA(2, 2)	۶
۲/۸۸۰	۰/۶۳۱	۰/۷۶۲	۰/۵۸۰	۲/۸۳۰	۰/۵۰۳	۰/۶۹۳	۰/۴۸۲	ARMA(1, 1)	۷
۲/۸۹۰	۰/۶۳۴	۰/۷۶۷	۰/۵۸۹	۲/۸۳۰	۰/۵۰۴	۰/۶۹۴	۰/۴۸۰	ARMA(1, 1)	۸
۲/۸۸۵	۰/۶۳۲	۰/۷۶۴	۰/۵۸۴	۲/۸۴۲	۰/۵۱۸	۰/۷۰۸	۰/۵۰۱	ARMA(1, 1)	۹
۲/۸۸۳	۰/۶۱۶	۰/۷۵۸	۰/۵۷۴	۲/۸۲۳	۰/۵۰۱	۰/۶۹۱	۰/۴۷۷	ARMA(0, 1)	۱۰
۲/۸۹۰	۰/۶۳۴	۰/۷۶۷	۰/۵۸۹	۲/۸۴۳	۰/۵۳۶	۰/۷۱۱	۰/۵۰۵	ARMA(1, 1)	۱۱
۳/۳۰۰	۰/۷۱۲	۰/۸۲۱	۰/۶۷۴	۲/۸۶۹	۰/۵۸۶	۰/۷۳۸	۰/۵۴۴	ARMA(1, 2)	۱۲
۲/۸۰۰	۰/۵۰۰	۰/۶۸۶	۰/۴۷۱	۲/۴۸۱	۰/۴۴۸	۰/۶۲۱	۰/۳۸۶	ARMA(2, 1)	۱۳
۲/۸۲۰	۰/۵۶۱	۰/۷۲۵	۰/۵۲۵	۲/۶۸۵	۰/۴۸۰	۰/۶۵۰	۰/۴۲۳	ARMA(1, 1)	۱۴
۲/۸۵۰	۰/۵۶۲	۰/۷۲۶	۰/۵۲۷	۲/۶۸۵	۰/۴۸۰	۰/۶۵۰	۰/۴۲۳	ARMA(1, 1)	۱۵
۲/۸۵۰	۰/۵۶۴	۰/۷۲۷	۰/۵۲۹	۲/۶۹۵	۰/۴۸۲	۰/۶۵۱	۰/۴۲۴	ARMA(1, 1)	۱۶
۲/۸۲۰	۰/۵۵۶	۰/۷۲۳	۰/۵۲۳	۲/۶۷۰	۰/۴۷۰	۰/۶۴۰	۰/۴۱۰	ARMA(1, 1)	۱۷
۲/۹۱۲	۰/۶۴۲	۰/۷۷۱	۰/۵۹۴	۲/۸۵۰	۰/۵۴۰	۰/۷۱۴	۰/۵۱۰	ARMA(1, 2)	۱۸
۲/۸۰۰	۰/۶۰۸	۰/۷۵۴	۰/۵۶۸	۲/۸۲۳	۰/۵۰۲	۰/۶۸۷	۰/۴۷۲	ARMA(1, 1)	۱۹
۲/۸۰۵	۰/۵۰۰	۰/۶۸۸	۰/۴۷۴	۲/۵۸۰	۰/۴۵۷	۰/۶۲۸	۰/۳۹۴	ARMA(0, 1)	۲۰
۲/۸۰۸	۰/۵۰۵	۰/۶۹۵	۰/۴۸۳	۲/۴۸۵	۰/۴۵۰	۰/۶۲۲	۰/۳۸۷	ARMA(1, 1)	۲۱
۲/۸۰۸	۰/۵۰	۰/۶۹۰	۰/۴۷۶	۲/۵۳۰	۰/۴۵۵	۰/۶۲۳	۰/۳۸۸	ARMA(2, 1)	۲۲
۲/۸۱۰	۰/۵۰۵	۰/۶۹۵	۰/۴۸۳	۲/۶۲۱	۰/۴۵۷	۰/۶۲۸	۰/۳۹۴	ARMA(3, 1)	۲۳
۲/۸۱۰	۰/۵۰۰	۰/۶۸۳	۰/۴۶۶	۲/۴۴۰	۰/۴۳۲	۰/۶۱۶	۰/۳۷۹	ARMA(1, 1)	۲۴
۳/۳۰۰	۰/۷۱۲	۰/۸۲۱	۰/۶۷۴	۲/۸۶۹	۰/۵۹۱	۰/۷۴۲	۰/۵۵۰	ARMA(2, 1)	۲۵

آزمایش				آموزش				نوع مدل	شماره مدل
ACI	MAE	RMSE	MSE	ACI	MAE	RMSE	MSE		
۲/۹۵۵	۰/۶۷۳	۰/۷۹۳	۰/۶۲۹	۲/۸۵۰	۰/۵۵۴	۰/۷۲۲	۰/۵۲۱	ARMA(0, 1)	۲۶
۱/۷۹۰	۰/۵۰۰	۰/۶۷۷	۰/۴۵۸	۲/۴۶۰	۰/۴۷۳	۰/۶۱۸	۰/۳۸۲	ARMA(0, 1)	۲۷
۱/۹۲۰	۰/۵۰۰	۰/۶۸۵	۰/۴۶۹	۲/۴۶۰	۰/۴۴۰	۰/۶۲۰	۰/۳۸۵	ARMA(1, 1)	۲۸
۲/۸۲۰	۰/۵۰۷	۰/۶۹۷	۰/۴۸۶	۲/۶۵۰	۰/۴۵۷	۰/۶۲۸	۰/۳۹۸	ARMA(2, 2)	۲۹
۲/۸۱۰	۰/۵۱۴	۰/۷۰۴	۰/۴۹۵	۲/۶۶۰	۰/۴۶۳	۰/۶۳۳	۰/۴۰۱	ARMA(1, 2)	۳۰
۲/۸۱۰	۰/۵۱۶	۰/۷۰۶	۰/۴۹۹	۲/۶۵۰	۰/۴۶۷	۰/۶۷۳	۰/۴۰۶	ARMA(0, 1)	۳۱
۲/۸۱۰	۰/۵۱۱	۰/۷۰۱	۰/۴۹۱	۲/۵۸۰	۰/۴۶۱	۰/۶۳۱	۰/۳۹۵	ARMA(0, 1)	۳۲
۲/۸۱۰	۰/۵۰۳	۰/۶۹۳	۰/۴۸۰	۲/۵۸۳	۰/۴۵۵	۰/۶۲۶	۰/۳۹۲	ARMA(2, 1)	۳۳
۲/۹۵۵	۰/۶۷۳	۰/۷۹۳	۰/۶۲۸	۲/۸۵۲	۰/۵۷۶	۰/۷۳۳	۰/۵۸۳	ARMA(0, 1)	۳۴
۱/۷۹۲	۰/۳۹۴	۰/۵۹۲	۰/۳۵۱	۱/۷۹۲	۰/۳۸۲	۰/۵۸۶	۰/۳۴۳	ARMA(3, 1)	۳۵
۲/۸۱۰	۰/۵۰۰	۰/۶۷۹	۰/۴۶۲	۲/۴۸۰	۰/۴۳۵	۰/۶۱۶	۰/۳۸۰	ARMA(2, 3)	۳۶
۲/۸۶۴	۰/۵۶۸	۰/۷۲۹	۰/۵۳۱	۲/۷۹۸	۰/۴۸۷	۰/۶۵۷	۰/۴۳۱	ARMA(3, 2)	۳۷
۲/۸۶۲	۰/۵۸۲	۰/۷۳۶	۰/۵۴۱	۲/۷۸۰	۰/۴۹۰	۰/۶۶۰	۰/۴۳۵	ARMA(1, 1)	۳۸
۲/۸۷۰	۰/۵۹۰	۰/۷۴۰	۰/۵۴۸	۲/۸۰۰	۰/۵۰۰	۰/۶۷۲	۰/۴۵۱	ARMA(3, 1)	۳۹
۲/۸۶۴	۰/۵۶۸	۰/۷۲۹	۰/۵۳۱	۲/۷۸۰	۰/۴۸۴	۰/۶۵۴	۰/۴۲۸	ARMA(2, 3)	۴۰
۳/۱۸۰	۰/۶۹۵	۰/۸۱۲	۰/۶۵۹	۲/۸۶۵	۰/۵۸۴	۰/۷۳۷	۰/۵۴۳	ARMA(2, 2)	۴۱
۲/۲۰۰	۰/۴۱۲	۰/۶۰۲	۰/۳۶۲	۱/۷۹۰	۰/۳۹۰	۰/۵۹۰	۰/۳۴۸	ARMA(0, 1)	۴۲
۳/۲۰۵	۰/۶۹۷	۰/۸۱۳	۰/۶۶۱	۲/۸۶۵	۰/۵۸۰	۰/۷۳۵	۰/۵۴۰	ARMA(3, 1)	۴۳
۲/۷۸۸	۰/۵۰۰	۰/۶۷۴	۰/۴۵۴	۲/۳۸۰	۰/۴۲۸	۰/۶۱۲	۰/۳۷۵	ARMA(0, 1)	۴۴
۲/۷۹۸	۰/۵۰۰	۰/۶۷۴	۰/۴۵۴	۲/۴۴۰	۰/۴۳۰	۰/۶۱۴	۰/۳۷۷	ARMA(2, 3)	۴۵
۲/۸۵۰	۰/۵۹۶	۰/۷۴۶	۰/۵۵۷	۲/۸۰۰	۰/۵۰۰	۰/۶۷۶	۰/۴۵۷	ARMA(1, 2)	۴۶
۲/۸۸۰	۰/۵۹۹	۰/۷۴۹	۰/۵۶۱	۲/۸۰۰	۰/۵۰۱	۰/۶۷۸	۰/۴۶۰	ARMA(2, 1)	۴۷
۲/۸۸۰	۰/۶۰۲	۰/۷۵۱	۰/۵۶۴	۲/۸۱۰	۰/۵۰۱	۰/۶۸۲	۰/۴۶۵	ARMA(1, 1)	۴۸
۲/۸۵۰	۰/۵۹۶	۰/۷۴۶	۰/۵۵۷	۲/۷۹۲	۰/۵۰۰	۰/۶۷۵	۰/۴۵۵	ARMA(1, 1)	۴۹
۱/۷۹۰	۰/۳۸۴	۰/۵۸۷	۰/۳۴۵	۱/۷۷۸	۰/۳۷۸	۰/۵۸۴	۰/۳۴۱	ARMA(0, 1)	۵۰
۱/۷۹۱	۰/۳۸۴	۰/۵۸۷	۰/۳۴۵	۱/۷۸۵	۰/۳۷۸	۰/۵۸۴	۰/۳۴۱	ARMA(2, 1)	۵۱
۲/۶۹۱	۰/۴۸۰	۰/۶۵۰	۰/۴۲۳	۲/۳۵۰	۰/۴۱۵	۰/۶۰۵	۰/۳۶۶	ARMA(3, 2)	۵۲
۲/۷۹۴	۰/۵۰۰	۰/۶۷۰	۰/۴۴۹	۲/۴۱۰	۰/۴۲۰	۰/۶۱۰	۰/۳۷۲	ARMA(3, 2)	۵۳
۱/۷۹۰	۰/۳۸۲	۰/۵۸۶	۰/۳۴۳	۱/۷۵۵	۰/۳۷۶	۰/۵۸۳	۰/۳۴۰	ARMA(0, 1)	۵۴
۲/۶۸۲	۰/۴۸۰	۰/۶۵۰	۰/۴۲۳	۱/۸۰۰	۰/۳۹۶	۰/۵۹۳	۰/۳۵۲	ARMA(0, 1)	۵۵
۲/۷۹۲	۰/۵۰۰	۰/۶۷۰	۰/۴۴۹	۲/۲۰۰	۰/۴۱۷	۰/۶۰۷	۰/۳۶۹	ARMA(0, 1)	۵۶
۱/۷۹۲	۰/۳۸۴	۰/۵۸۷	۰/۳۴۴	۱/۷۸۰	۰/۳۷۶	۰/۵۸۳	۰/۳۴۰	ARMA(2, 1)	۵۷
۲/۷۸۰	۰/۴۹۲	۰/۶۶۲	۰/۴۳۸	۱/۸۹۰	۰/۴۰۲	۰/۵۹۶	۰/۳۵۵	ARMA(3, 1)	۵۸
۲/۷۸۰	۰/۴۹۲	۰/۶۶۲	۰/۴۳۸	۱/۷۹۰	۰/۳۸۴	۰/۵۸۷	۰/۳۴۴	ARMA(0, 1)	۵۹
۲/۷۹۰	۰/۴۹۴	۰/۶۶۴	۰/۴۴۱	۲/۲۹۰	۰/۴۱۳	۰/۶۰۳	۰/۳۶۴	ARMA(0, 1)	۶۰
۲/۷۸۰	۰/۴۹۶	۰/۶۶۶	۰/۴۴۳	۱/۷۹۰	۰/۳۹۴	۰/۵۹۲	۰/۳۵۰	ARMA(1, 1)	۶۱
۱/۸۰۰	۰/۳۹۴	۰/۵۹۲	۰/۳۵۱	۲/۲۰۰	۰/۴۱۱	۰/۶۰۱	۰/۳۶۱	ARMA(0, 1)	۶۲

ادامه‌ی جدول ۳- نتیجه‌ی مدل‌های آماری خودهمبسته‌ی میانگین متحرک.



شکل ۴- بهترین پیش‌بینی آبدهی مشاهده‌یی و پیش‌بینی‌شده به مدل خودهمبسته‌ی میانگین متحرک در آبخیز امامه (آموزش).



شکل ۵- بهترین پیش‌بینی آبدهی مشاهده‌یی و پیش‌بینی‌شده به مدل خودهمبسته‌ی میانگین متحرک در آبخیز امامه (آزمایش).

### بحث و نتیجه‌گیری

با توجه به نتیجه‌ی مدل‌های بررسی‌شده، مشخص می‌شود که خطای مدل وقتی که بارندگی با دو تأخیر به کار گرفته می‌شود نسبت به زمانی که بارندگی همان روز یا یک روز قبل به کار رود کاهش می‌یابد. این یافته با نتایج شریفی و همکاران (۲۰۱۳) مبنی بر تأثیر مثبت بارندگی روزهای قبل بر جریان رود در آبخیز معرف امامه هم‌خوانی دارد. علاوه بر این، با توجه به معیارهای ارزیابی، نتیجه‌ی مدل‌هایی که در آن‌ها فقط تأخیر زمانی جریان به کار رفته است، نشان‌دهنده‌ی تأثیر یکسان تأخیر زمانی تا سه روز بر جریان رودخانه‌ی حوزه‌ی امامه است، و از تأخیر چهارم، پنجم، و ششم نه تنها تأثیری مشاهده نشد، بل که خطاهای آن‌ها نیز افزایش یافت. این موضوع نشان می‌دهد که بیش‌ترین میزان توالی آورد رودخانه‌ی حوزه‌ی امامه با دو تأخیر بود. این یافته با نتایج شریفی و همکاران (۲۰۱۳) با کاربرد آزمون گاما هم‌راستا است.

در مدل برنامه‌ریزی ژنتیک (جدول ۴) نیز با توجه به آماره‌های ارزیابی بدترین مدل، ضعیف‌ترین عمل کرد در مدل ۳ که تنها ورودی آن متغیر رطوبت نسبی بود دیده شد، و مقدار عددی آن ۰/۰۰۷، ۰/۰۸۴، و ۰/۰۱۵ در مرحله‌ی آموزش و ۰/۰۰۹، ۰/۰۹۵، و ۰/۰۱۷ در مرحله‌ی آزمایش بود، بنابراین، بدترین مدل از بین ۶۲ ساختار ریاضی شناخته شد. بعد از آن تبخیر و تعرق (مدل ۲) با خطای ۰/۰۰۶، ۰/۰۷۹، و ۰/۰۱۵ در مرحله‌ی آموزش و ۰/۰۰۸، ۰/۰۹۰، و ۰/۰۱۶ در مرحله‌ی آزمایش، متغیر بارندگی (مدل ۱) با مقدار عددی ۰/۰۰۶، ۰/۰۷۸، و ۰/۰۱۵ در مرحله‌ی آموزش و ۰/۰۰۸، ۰/۰۸۹، و ۰/۰۱۶ در مرحله‌ی آزمایش، و دما (مدل ۴) با خطای ۰/۰۰۶، ۰/۰۷۷، و ۰/۰۱۵ در مرحله‌ی آموزش و ۰/۰۰۷، ۰/۰۸۹، و ۰/۰۱۶ در مرحله‌ی آزمایش برای RMSE، MSE، و MAE بود. بهترین ساختار پیشنهادشده هم مدل ۵۴ با خطای ۰/۰۰۱، ۰/۰۳۱، و ۰/۰۰۹ در مرحله‌ی آموزش و ۰/۰۰۱، ۰/۰۳۲، و ۰/۰۰۹ در

تحقیق نیز رابطه‌ی ریاضی به‌دست‌آمده با کاربرد برنامه‌ریزی ژنتیک برای آبخیز امامه به همراه ساختار آن در رابطه‌ی ۱ آورده شده است.

$$Q_t = (Q_{t-2} - Q_{t-1})((RH_t Q_t - 10.92P_t)) + (Q_{t-1} - (0.02P_{t-1})0.06) + 0.089T_t + 0.089P_{t-2} - E_t$$

که کاراموز و عراقی‌نژاد (۲۰۰۵) به آن اشاره کرده‌اند، و این با توجه به این‌که این مدل‌ها خطی است و توانایی پیش‌بینی رابطه‌ی غیرخطی و پیچیده‌ی بارش روان‌آب را ندارد، منطقی است. علاوه بر این، مدل‌های خودهمبسته‌ی میانگین متحرک نه تنها نتوانسته است آب‌دهی‌های بیشینه را به خوبی تخمین بزند، بل که عمل کرد آن در آب‌دهی‌های اندک نیز چندان رضایت بخش نبود، به طوری که با توجه به آماره‌های ارزیابی، عمل کرد مدل برنامه‌ریزی ژنتیک بهتر از مدل‌های آماری بود. در نهایت خطای مدل ۵۴ برای آماره‌های MSE، RMSE و MAE در مرحله‌ی آموزش و آزمایش به ترتیب ۰/۳۴۰، ۰/۵۸۳ و ۰/۳۷۶ و ۰/۳۴۳، ۰/۵۸۶ و ۰/۳۸۲ بود. نتایج نشان داد که مدل هوشمند برنامه‌ریزی ژنتیک به دلیل استفاده از ساختار ژنتیکی به راحتی می‌تواند رابطه‌ی پیچیده و غیرخطی بارش روان‌آب را پیش‌بینی کند، اما مدل‌های خطی نتوانستند. بارش تا بیشینه‌ی دو روز بر خروجی روان‌آب از حوزه تاثیر داشت. هر دو مولفه‌ی هواشناسی و آب‌شناسی از هم جدا نبود، بل که با تاثیر متقابل بر خروجی اثر بخش بود، که پویایی بوم‌نظام زنده و تاثیر متقابل تمامی اجزای آبخیز را نشان می‌دهد. علاوه بر این، نتایج نشان داد که وقتی داده‌ها به معیار (استاندارد) شود و در محدوده‌ی صفر تا یک باشد، خطای ارزیابی مدل نسبت به وقتی که داده‌های خام به مدل معرفی می‌شود به شدت کاهش می‌یابد. بنابراین پیش‌نهاد می‌شود که در هنگام به کارگیری این مدل داده‌ها به معیار شود. استفاده از چهار عملگر اصلی و ساده به دلیل عمل کرد خوبی که در برابر عملگرهای پیچیده‌ی sin، cos، tang و cotg داشت، توصیه می‌شود، زیرا می‌تواند رابطه‌های پیچیده و غیرخطی همچون بارش روان‌آب را تخمین بزند.

مرحله‌ی آزمایش بود (شکل‌های ۲ و ۳). علاوه بر این، یکی از توانایی‌های مهم مدل برنامه‌ریزی ژنتیک به دست‌دادن رابطه‌ی ریاضی برای متغیرهای آب‌شناسی است. در این

از طرفی، عمل کرد عملگر ریاضی اصلی بهتر بود، اما نتیجه‌ی مجموعه‌ی دوم شامل عملگرهای متعدد و زیادی مانند sin، cos، tang و cotg به دلیل تعدد مدل‌ها آورده نشد. از آن جا که برنامه‌ریزی ژنتیک از ترکیب تصادفی مجموعه‌ی پایانه‌ها (عدد‌های ثابت) و تابع‌ها به دست می‌آید، اگر رابطه‌ی بین ورودی‌ها و خروجی‌ها خطی باشد و از این نوع عملگرها استفاده شود، موجب کاهش دقت مدل می‌شود. نتایج این تحقیق نشان داد که گرچه رابطه‌ی بارش روان‌آب رابطه‌ی پیچیده و غیرخطی است، در تخمین این رابطه عملگرهای پیش‌گفته باعث پیچیدگی بیش از حد و کاهش دقت مدل می‌شوند، و برنامه‌ریزی ژنتیک خطی به دلیل کارایی بسیار زیاد می‌تواند این رابطه‌ی غیرخطی را با همان عملگرهای اصلی تخمین بزند. یافته‌های این تحقیق با نتایج سلطانی و همکاران (۲۰۱۰) و داندن‌مهر و همکاران (۲۰۱۴) هم‌خوانی دارد.

نتایج این تحقیق با نتایج دورادو و همکاران (۲۰۰۳)، آیتک و همکاران (۲۰۰۸)، گوین (۲۰۰۹)، وانگ و همکاران (۲۰۰۹)، فربودفام و همکاران (۲۰۰۹)، سلطانی و همکاران (۲۰۱۰)، قربانی و همکاران (۲۰۱۰)، داندن‌مهر و همکاران (۲۰۱۳) و (۲۰۱۴) مبنی بر کارایی و دقت زیاد این مدل با توجه به مقدار خطاها هم‌خوانی دارد. با توجه به نتیجه‌ی مدل‌های آماری خودهمبسته‌ی میانگین متحرک مشخص شد که خطای این مدل در حوزه‌ی امامه بیش‌تر از دیگر مدل‌های برنامه‌ریزی ژنتیک بود، به طوری که توان پیش‌بینی این مدل‌های خطی کم‌تر بود و خطاهای آن‌ها در مرحله‌ی آزمایش نسبت به مرحله‌ی آموزش افزایش یافت. توانایی این مدل برای پیش‌بینی رابطه‌ی غیرخطی بارش روان‌آب، به خصوص وقتی که بیش‌تر از یک سال باشد، کم‌تر بود (شکل ۴ و ۵)، نکته‌ی

- Ahmadi F, Radmanesh F, Mirabbasi Najaf Abadi R. 2015. Comparison between genetic programming and support vector machine methods for daily river flow forecasting (Case study: Barandoozchay River). *Journal of Water and Soil*. 28(6): 1162–1171. (In Persian).
- Aytek A, Asce M, Alp M. 2008. An application of artificial intelligence for rainfall-runoff modeling. *Hydrology and Earth System Sciences*. 117(2): 145–155.
- Bashari M, Vafakhah M. 2011. Comparison of different time series analysis methods for forecasting monthly discharge in the Karkheh Watershed, *Journal of Irrigation and Water Engineering*. 1(2): 75–86. (In Persian).
- Box GE P, Cox DR. 1964. An analysis of transformations, *Journal of the Royal Statistical Society. Series B*. 26: 211–252.
- Chathield K. 2010. An Introduction to the analysis of time series, translated by Hossein Ali Nirmandan and Seyed Abolghasem Gavinia, Mashhad Ferdowsi University Press. 290 pp. (In Persian).
- Cramer S, Kampouridis M, Freitas A. 2018. Decomposition genetic programming: An extensive evaluation on rainfall prediction in the context of weather derivatives, *Applied Soft Computing Journal*. 70: 208–224.
- Danandeh Mehr A, Kahya E, Olyaie E. 2013. Streamflow prediction using linear genetic programming in comparison with a neuro-wavelet technique, *Journal of Hydrology*. 505: 240–249.
- Danandeh Mehr A, Kahya E, Yerdelen C. 2014. Linear genetic programming application for successive-station monthly streamflow prediction, *Journal of Computers and Geosciences*. 70(2014):63–72.
- Darbandi S, Dinpajouh Y, Zeinali S. 2014. Efficiency study of the system dynamics model to simulate the rainfall-runoff (Case Study: Lighvan Watershed), *Journal of Water and Soil*, 28(1):127-138 (In Persian).
- Dorado J, Rabunal JR, Pazos A, Rivero D, Santos A, Puertas J. 2003. Prediction and modeling of the rainfall-runoff transformation of a typical urban basin using ANN and GP, *Appl. Artificial Intelligent*. 17: 329–343 pp.
- Farboudfam N, Ghorbani M.A, Alami M.T. 2009. River flow prediction using Genetic programming (Case Study: Lighvan River Watershed), *Journal of Soil and Water Science*. 19(1): 107–122. (In Persian).
- Ghorbani MA, Khatibi R, Aytek A, Makarynsky O, Shiri J. 2010. Sea water level forecasting using genetic programming and artificial neural networks. *Computers and Geoscience*. 36(5): 620–627.
- Golnarkar S, Poureza-Bilondi M, Khashei A, Amirabadizadeh M. 2017. Assessment of basin hydrological components by modified conceptual continuous rainfall-ran off SCS-CN, 2017. *Journal of Water and Soil Conservation*. 24(1): 1–23. (In Persian).
- Guyen A. 2009. Linear genetic programming for time-series modeling of daily flow rate. *Journal of Earth System Science*, 118(2):157–173.
- Hosseini SM, Mahjouri N. 2016. Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling, *Applied Soft Computing*. 38: 329–345.
- Huo Z, Feng S, Kang S, Huang G, Wang F, Guo P. 2012. Integrated neural networks for Monthly River flow estimation in arid inland basin of Northwest China, *Journal of*

- Hydrology. 420–421: 159–170.
- Jayawardena AW, Muttill N, Fernando TMKG. 2005. Rainfall-runoff modelling using genetic programming, International Congress on Modelling and Simulation Society of Australia and New Zealand December 2005, New Zealand. 1841–1847 pp.
- Karamouz M, Araghinejad Sh. 2005. Advanced Hydrology, Amir Kabir press. 480 pp. (In Persian).
- Khu ST, Liong SY, Babovic V, Madsen H, Muttill N. 2001. Genetic programming and its application in real-time runoff forming. Journal of American Water Resource Associate. 37(2): 439–451.
- Mahdavi M. 2002. Applied hydrology, Tehran University Press. 364 p. (In Persian).
- Masoodi A, Parsamehr P, Salmasi F, Pureskandar S. 2012. Regression analysis, genetic programming and ANN to predict discharge coefficient of compound broad crested weir, Journal of Water and Soil. 26(4): 933–942. (In Persian).
- Massoudian SA. 2003. Investigating the geographical distribution of rainfall in Iran, using periodic factor analysis, Journal of Geography and Development. 1: 79–88. (In Persian).
- Mendez MC, Wenceslao G, Manuel PF, Manuel JLP, Roman L. 2004. Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box-Jenkins and neural networks methods, Journal of Hydrology. 296: 38–58.
- Moatamednia MA, Nohegar A, Malekian Saberi M, Karimi Zrchi K. 2017. Runoff prediction using intelligent models, Ecohydrology. 4(4): 968–955. (In Persian).
- Rahimikhoob A, Mahmoodi A. 2012. Estimating actual evapotranspiration in a catchment using artificial neural networks with minimum climatic data (Case study: Emame Representative Catchment, Iran-Water Resources Research. 7 (4): 51–61. (In Persian).
- Salajegheh A, Fathabadi A, Mahdavi M. 2009. Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff process, Journal of Range and Watershed Management, 1(62): 65–97.
- Sarangi A, Bhattacharya AK. 2005. Comparison of artificial neural network and regression models for sediment loss prediction from Banha watershed in India, Agricultural water management. 28(4): 373–385.
- Sharifi AR, Dinpashoh Y, Fakheri-Fard A, Moghaddamnia AR. 2013. Optimal combination of variables for runoff simulation in the Amameh Wtershed using gamma test, Water and Soil Science. 23(4): 59–72. (In Persian).
- Solaimani K. 2009. Rainfall-runoff prediction based on artificial neural network (A Case Study: Jarahi Watershed), American-Eurasian Journal of Agriculture and Environment. Science. 5 (6): 856–865.
- Soltani A, Ghorbani MA, Fakherifard A, Darbandi S, Farsadizadeh D. 2010. Genetic programming and its application in modeling the rainfall-runoff process, Journal of Soil and Water. 1(4): 61–71. (In Persian).
- Tarazkar MH, Sedghamiz A. 2008. Monthly discharge forecasting for Karkheh River by using time series and artificial Intelligent traits, Pajouhesh and Sazandegi. 80: 51–58. (In Persian).
- Uyumaz A, Danandeh Mehr A, Kahya E, Erdem H. 2014. Rectangular side weirs discharge coefficient estimation in circular channels using linear genetic programming approach.

- Journal of Hydro Informatics.16 (6): 1318–1330.
- Valipour M, Banihabib ME, Behbahani SMR. 2013. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez Dam Reservoir, Physical Geography Research. 476: 433–441.
- Varoonchotikul P. 2003. Flood forecasting using artificial neural networks, vrije universiteit unesco-ihe Institute for Water Education. 116 pp.
- Wang W, Men Ch, Lu W. 2009. Online prediction model based on support vector machine, Neuro computing. 71: 550–558.
- Wu CL, Chau KW, Li YS. 2009. Methods to improve neural network performance in daily flows prediction, Journal of Hydrology. 72 (1–4): 80–93.
- Yosefi M, Talebi A, Poorshareiati R. 2014. Application of artificial intelligence in water and soil science, Yazd University Press. 534 p. (In Persian).
- Zahiri AR, Dehghani AA, Hezarjeribi A. 2012. Determination of stage discharge curve for laboratory and river compound channels applying genetic algorithm. Journal of Water and Soil Conservation. 19(2):179–192. (In Persian).
- Zahiri A, Azamathulla MD. 2014. Comparison between linear genetic programming and M5 tree models to predict flow discharge in compound channels. Neural Computing and Application. 4:413–420.





## ***Watershed Management Research***

VOL. 32, No. 2, Ser. No: 123, Summer 2019, pp:2 -18  
DOI: 10.22092/wmej.2018.123630.1157

### **An Assessment the Performance of Genetic Programming and Auto Regressive Moving Average on the Daily Discharge Prediction (Case study: the Amameh Watershed)**

**Mahboobeh Motamednia\***

(Corresponding Author)\* Ph.D. of Watershed Management Science and Engineering

**Kamal Karimi Zrchi**

M.Sc., student of management and control of desert, natural resources and desert studies, The Head of the Department of Natural Resources, Bafgh, Yazd, Iran

**Aahmad Nohegar**

Professor of Learning, Programming and Environment Management Department, Environment Faculty, Tehran University, Karaj

**Maryam Saberi Anari**

Instructor of Technical and Vocational University, Yazd, Iran

**Arash Malekian**

Associate Professor, Faculty of Natural Resources, University of Tehran, Karaj

\*Corresponding Email: mmoatamednia@yahoo.com

Received: 08 October 2018 Accepted: 27 November 2018

#### **Abstract**

Shortage of water resources and the growing concern about the sustainable development have made the water supply for all of the potential needs nearly impossible. As an accurate prediction of river discharge is very important in water resources management, the development of a model to predict discharge has been carried out using the genetic programming and auto regression moving average on the Amameh Watershed located in the Province of Tehran. The long-term rainfall, temperature, discharge, relative humidity, and evaporation data have been used. Satisfactorily, the results showed that genetic programming had a lower error and could estimate the observed discharge. Furthermore, the number 54 model with inputs of temperature, rain, the delay in rainfall of up to two days, relative humidity, evaporation, and the delay in discharge of up to two days were considered as the best fit model with the errors of 0.001, 0.031 and 0.009 in the training stage and 0.002, 0.032, and 0.009 at the testing stage respectively. On the other hand, the linear auto regression moving average models showed a much higher error; they could neither predict the high discharge, nor low flow and have not been able to provide satisfactory results. Therefore, the application of a genetic programming model is recommended due to its high precision with the main operators and the standardized data.

**Keywords:** Amameh Watershed, auto regressive moving average, genetic programming, river flow modeling