

مدل‌سازی جریان روزانه رودخانه با استفاده از برنامه‌ریزی ژنتیک و شبکه عصبی (مطالعه موردی: حوضه آبخیز معرف امامه)

احمد نوحه‌گر – استاد گروه برنامه‌ریزی مدیریت و آموزش محیط زیست، دانشکده محیط زیست، دانشگاه تهران، کرج
محبوبه معتمدینیا* – دانشجوی دکتری علوم و مهندسی آبخیزداری، گروه کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس
آرش ملکیان – دانشیار گروه احیای مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج

پذیرش مقاله: ۱۳۹۵/۱/۱۹ تأیید نهایی: ۱۳۹۵/۴/۸

چکیده

فرایند بارش- رواناب پیچیده و غیرخطی است و مدل‌سازی آن به دلیل عدم قطعیت‌های زیاد یکی از مهم‌ترین دغدغه‌های پژوهشگران در حیطه مسائل منابع آب به شمار می‌رود. از بین روش‌های مورد استفاده، مدل‌های هوشمند در پیش‌بینی چنین فراینداتی مفید و مؤثرند. بنابراین، به منظور مدل‌سازی جریان رودخانه از روش‌های شبکه عصبی مصنوعی و همچنین برنامه‌ریزی ژنتیک به منزله روشی صریح- که جزو الگوریتم‌های تکاملی به شمار می‌رود- در حوضه آبخیز معرف امامه و در دوره آماری ۱۳۹۱- ۱۳۹۰ تا ۱۳۵۰- ۱۳۴۹ (۴۲ ساله) استفاده شد. بدین منظور، از داده‌های هواشناسی و آب‌سنجدی در مقیاس روزانه و در قالب ۶۲ مدل پیشنهادی استفاده شد. نتایج نشان داد برنامه‌ریزی ژنتیکی، از میان مدل‌های فراوان، خطای کمتری داشت. خطای مدل‌ها نیز وقتی که فقط از عملگرهای اصلی ریاضی و توان استفاده شد بهمراه کمتر بود. سرانجام، با توجه به معیارهای ارزیابی مورد استفاده در این تحقیق، ساختار پیشنهادی با ورودی‌های (مدل ۵۴) دما، باران، و تأخیرهای باران تا دو روز، رطوبت نسبی و تبخیر و تعرق و تأخیر جریان تا دو روز به عنوان بهترین مدل با خطای ۱۰۰/۱، ۰/۰۳۱، ۰/۰۰۹ و ۰/۰۰۶ در مرحله آموزش و ۱، ۰/۰۳۲، ۰/۰۰۹ و ۰/۰۰۰ در مرحله آزمایش به دست آمد.

کلیدواژه‌ها: بارش- رواناب، برنامه‌ریزی ژنتیک، شبکه عصبی پرسپترون چندلایه، حوضه آبخیز معرف امامه.

مقدمه

پیش‌بینی میزان دبی رودخانه یکی از مسائل مهم مهندسی منابع آب است؛ این موضوع از نظر برنامه‌ریزی، مدیریت، و سیاست‌گذاری منابع آبی- در راستای توسعه اقتصادی و زیست‌محیطی بهویژه در کشوری مثل ایران، با منابع آبی محدود- اهمیت بسیار زیادی دارد (هیو و همکاران، ۲۰۱۲). به رغم سابقه طولانی مدل‌های آماری، هیدرولیکی، و هیدرولوژیکی، تجارت حاکی از آن است که این مدل‌ها، برغم نقاط قوت، ضعف‌های بسیار زیادی دارند، از قبیل نیاز به داده‌های زیاد و طولانی مدت، پارامترهای گوناگون از قبیل هندسه رودخانه، و پارامترهای مختلف هواشناسی و واسنجی وقت‌گیر؛ بدین سبب به این مدل‌ها کمتر توجه شده است (هارون و همکاران، ۲۰۰۲). بنابراین، در سال‌های اخیر، توجه به روش‌های

هوش مصنوعی، به سبب دقت و سرعت زیاد آن‌ها، افزایش یافته است. یکی از روش‌های موجود در میان مدل‌های هوشمند^۱ شبکه عصبی مصنوعی است؛ این مدل با ساختاری ریاضی قادر به شناسایی و تشخیص روابط پیچیده غیرخطی بین ورودی و خروجی است. با گسترش روزافزون کاربرد الگوهای رایانه‌ای در دهه‌های اخیر، از الگوهای ضمنی متکی بر شبکه‌های عصبی مصنوعی به طور گسترده در مطالعات پیش‌بینی پارامترهای مختلف منابع آب استفاده می‌شود و محققان بر دقت زیاد این روش در مقایسه با الگوهای سری زمانی تأکید می‌کنند. یکی از پُرکاربردترین روش‌های مورد استفاده شبکه عصبی پرسپترون چندلایه است؛ از این روش در بسیاری از مسائل پیچیده ریاضی، که به حل معادلات غیرخطی می‌انجامد، به سادگی استفاده می‌شود (داوسون و ویل‌بای، ۲۰۰۱). معمولاً شبکه عصبی پرسپترون سه‌لایه با استفاده از الگوریتم پس‌انتشار خطأ^۲ قادر است هر نوع فضایی را تفکیک کند؛ این شبکه همچنین در زمینه هیدرولوژی و منابع آبی بسیار کاربردی است (داوسون و ویل‌بای، ۲۰۰۱؛ سینیوانسولا و جین، ۲۰۰۶؛ تاؤ و همکاران، ۲۰۰۸؛ پرامانیک و پاندا، ۲۰۰۹؛ چیانگ و یه، ۲۰۱۰؛ هیو و همکاران، ۲۰۱۲؛ دانده‌مهر و همکاران، ۲۰۱۳؛ قرایی‌منش و همکاران، ۲۰۱۶). از طرفی، یکی دیگر از روش‌های مورد بررسی برنامه‌ریزی ژنتیک^۳ است؛ روشی نوین در میان روش‌های هوش مصنوعی که به دلیل ارائه مدل صریح بین ورودی‌ها و خروجی توسعه یافته و در زمینه‌های گوناگون کاربردهای موقوفیت‌آمیزی داشته است. در حقیقت، برنامه‌ریزی ژنتیک تعمیم‌یافته الگوریتم ژنتیک است؛ کوزا، در سال ۱۹۹۲، برای نخستین بار، آن را ارائه کرد. این روش شاخه‌ای از الگوریتم گردشی تلقی می‌شود و مبنای آن بر اساس نظریه تکاملی داروین استوار شده است (کوزا، ۱۹۹۲؛ آیتک و همکاران ۲۰۰۸؛ سلطانی و همکاران، ۱۳۸۹؛ مسعودی و همکاران، ۱۳۹۱). دورادو و همکاران (۲۰۰۳) با استفاده از روش برنامه‌ریزی ژنتیک به الگوسازی بارش-رواناب در حوضه‌های شهری پرداختند و نتایج به دست آمده را با روش شبکه عصبی مصنوعی ارزیابی کردند. تحقیقات نامبردگان نشان داد برنامه‌ریزی ژنتیک نسبت به شبکه عصبی برتری دارد. جایاوردن و همکاران (۲۰۰۵) به منظور مدل‌سازی بارش-رواناب از داده‌های روزانه در دو حوضه آبخیز در چین از روش برنامه‌ریزی ژنتیک استفاده کردند. نتایج آن‌ها نشان داد این روش به خوبی می‌تواند میزان رواناب خروجی در این دو حوضه را مدل‌سازی کند. آیتک و همکاران (۲۰۰۸) به مدل‌سازی بارش-رواناب رودخانه‌ای در ایالت پنسیلوانیا امریکا در مقیاس روزانه با استفاده از روش‌های شبکه عصبی و برنامه‌ریزی ژنتیک اقدام کردند. نتایج به طور معنی‌داری نشان دهنده برتری برنامه‌ریزی ژنتیک نسبت به روش شبکه عصبی است. گوین (۲۰۰۹) به منظور پیش‌بینی دبی جریان روزانه در رودخانه‌ای در ایالات متحده از روش برنامه‌ریزی ژنتیک خطی و روش‌های شبکه عصبی استفاده کرد. گوین به منظور اجرای این تحقیق از متغیر دبی رودخانه از یک تا چهار تأخیر و در مقیاس روزانه از ۱۸۲۴ و ۷۳۰ داده برای آموزش و آزمایش استفاده کرد. بر اساس نتایج، هر دو روش نتایج قابل قبولی داشتند، اما روش برنامه‌ریزی ژنتیک خطی از دقت بسیاری نسبت به روش‌های شبکه عصبی برخوردار بود. وانگ و همکاران (۲۰۰۹) به منظور پیش‌بینی جریان رودخانه در مقیاس ماهانه از روش‌های گوناگونی استفاده کردند. بر اساس نتایج این تحقیق، از بین مدل‌های مورد استفاده شبکه عصبی-فازی تطبیقی، برنامه‌ریزی ژنتیکی، و بردار

1. artificial intelligence (AI)

2. error back propagation (EBP)

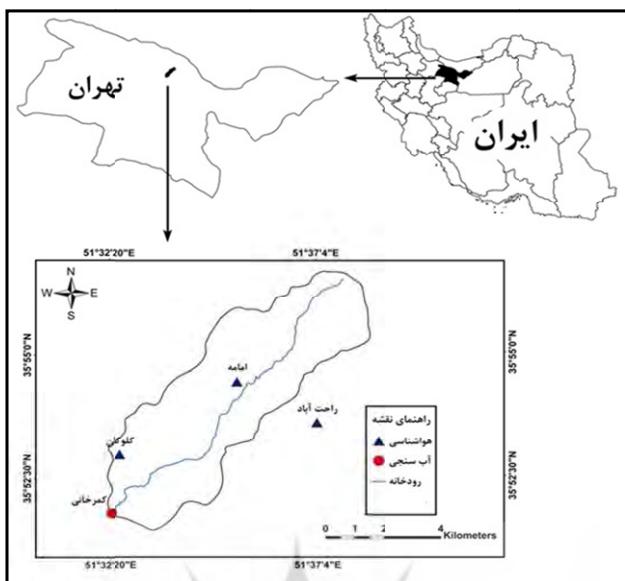
3. genetic programming (GP)

پشتیبان از خودهمبسته میانگین متحرک شبکه عصبی مصنوعی عملکرد بهتر و بیشتری داشت. قربانی و همکاران (۲۰۱۰) عملکرد سه روش برنامه‌ریزی ژنتیک، شبکه عصبی مصنوعی، و نروفازی را در روندیابی سیالاب رودخانه قزل ایرماق ترکیه ارزیابی کردند. نتایج مطالعه آن‌ها نشان داد از میان سه روش ذکر شده مدل برنامه‌ریزی ژنتیک با دقت بیشتری هیدروگراف خروجی را شبیه‌سازی می‌کند و از قابلیت بیشتری برخوردار است. داننده‌مهر و همکاران (۲۰۱۳) در زمینه پیش‌بینی جریان رودخانه از روش‌های مختلف شبکه عصبی و برنامه‌ریزی ژنتیکی در رودخانه‌ای در کشور ترکیه استفاده کردند. از میان روش‌های ذکر شده به ترتیب برنامه‌ریزی ژنتیک، شبکه عصبی موجکی، و شبکه عصبی پرسپترون سه‌لایه عملکرد خوبی داشتند. داننده‌مهر و همکاران (۲۰۱۴) به منظور پیش‌بینی جریان رودخانه در مقیاس ماهانه از روش شبکه‌های عصبی مختلف و برنامه‌ریزی ژنتیک در دو ایستگاه در کشور ترکیه استفاده کردند. نتایج نشان دهنده برتری و کارایی برنامه‌ریزی ژنتیک نسبت به دیگر روش‌های ذکر شده است. حسینی و مهgorی (۲۰۱۶)، به منظور مدل‌سازی بارش-رواناب، از روش‌های مختلف سامانه‌های هوشمند در استان قم استفاده کردند. نتایج نشان داد از میان مدل‌های ذکر شده مدل ترکیبی رگرسیون بردار پشتیبان و شبکه عصبی ژئومرفولوژیکی عملکرد بهتری نسبت به مدل‌های مبتنی بر شبکه عصبی مصنوعی دارند و در زمینه مدل‌سازی بارش-رواناب می‌توانند ابزاری بسیار مناسب با نتایج منطقی و قابل اعتماد باشند. همچنین، در ایران نیز می‌توان به تحقیقات پژوهشگرانی درباره مطالعه بارش-رواناب اشاره کرد؛ از جمله فربودنام و همکاران (۱۳۸۸) و سلطانی و همکاران (۱۳۸۹)؛ همگی این پژوهشگران اذعان کرده‌اند این روش دارای دقت بیشتری است و قادر است تا حد زیادی رابطه بارش و رواناب را تخمین بزنند. بنابراین، با توجه به موارد ذکر شده در این تحقیق، سعی شد از دو روش شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک برای پیش‌بینی جریان رودخانه و مدل‌سازی حوضه آبخیز معرف امامه واقع در استان تهران به واسطه موقعیت جغرافیایی (به عنوان نماینده و معرف مناطق جنوبی رشته‌کوه البرز) و داده‌های طولانی‌مدت (۴۲ سال) استفاده شود.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه آبخیز معرف امامه در استان تهران با متوسط بارندگی 756.6 میلی متر در بین عرض‌های جغرافیایی "۵۱°۰۰' - ۵۵°۰۰'" تا "۳۹°۰۰' - ۵۱°۰۰'" شرقی واقع شده است. این حوضه آبخیز با مساحت 372 کیلومتر مربع یکی از سرشاخه‌های رودخانه جاجروم است و از ارتفاعات جنوبی دره لار سرچشمه می‌گیرد و در جهت شمال شرقی به جنوب غربی از میان حوضه عبور می‌کند و پس از عبور از روستاهای امامه و کلوکان در پایین‌دست روستای کلوکان (پس از عبور از ایستگاه آب‌سنگی کمرخانی) به شاخه اصلی رودخانه جاجروم می‌پیوندد. بیشترین ارتفاع حوضه در بخش شمالی 3850 متر و کمترین آن در محل خروجی 1830 متر است. به منظور اجرای این تحقیق، از داده‌های ایستگاه هواشناسی امامه و ایستگاه آب‌سنگی کمرخانی در خروجی حوضه به دلیل موقعیت ایستگاه‌ها و همچنین وجود داده‌های کامل استفاده شد (شريفي و همکاران، ۱۳۹۲). شکل ۱ نمایی از حوضه آبخیز امامه و موقعیت ایستگاه‌های هواشناسی و آب‌سنگی آن را نشان می‌دهد.



برنامه‌ریزی ژنتیک از نرم‌افزار 5 GeneXprotools استفاده شد. همان طور که پیشتر ذکر شد، یک شبکه عصبی پرسپترون از سه لایه ورودی، پنهان، و خروجی تشکیل شده است. تعداد نرون در لایه ورودی و خروجی برابر با تعداد ورودی و خروجی است. اما، تعداد لایه و نرون در لایه پنهان به صورت سعی و خطاست. در این تحقیق ازتابع محرک سیگموئید برای لایه پنهان به دلیل تغییرات شدید داده‌ها و ازتابع محرک خطی برای لایه خروجی، تعداد تکرار شبکه عصبی برابر با هزار تکرار، تعداد لایه پنهان به کاررفته یک، دو، و سه تا لایه، تعداد نرون‌های لایه پنهان به صورت سعی و خط، و از الگوریتم آموزشی لونبرگ مارکوارت (که یک نوع الگوریتم پسانششار خطا بوده) به دلیل استفاده متداول و کارایی زیاد آن در مطالعات هیدرولوژی استفاده شد؛ از میان هزاران مدل، بهترین مدل‌ها با توجه به حداقل خطاهای انتخاب شدند؛ در جدول ۲ نتایج آن درج شده است. همچنین، فرایند اجرای مدل‌سازی در برنامه‌ریزی ژنتیک بدین صورت است: گام اول، انتخاب تابع برآش مناسب؛ در این مطالعه RMSE تابع برآش انتخاب شد. گام دوم، انتخاب مجموعه پایانه‌ها (متغیرهای ورودی) و مجموعه توابع به منظور تولید کروموزوم‌ها؛ در این تحقیق مجموعه پایانه‌ها مشکل است از داده‌های ورودی از قبیل تأخیرهای زمانی باران، دما، تبخیر و تعرق، رطوبت نسبی، و همچنین تأخیر جریان در روزهای قبل. انتخاب مجموع توابع نیز اگرچه امری صریح و ساده نیست، حدس اولیه و چندین بار امتحان و سعی و خطا می‌تواند در این زمینه سودمند باشد. گام سوم، استفاده از دو نوع عملگر ریاضی: شامل عملگرهای ریاضی اصلی شامل $\{+, -, \times, /\}$ و همچنین از یازده نوع عملگر یعنی عملگرهای ریاضی اصلی و همچنین $\{+, -, \times, /, \sin, \cos, \tan, \cot, \log\}$ استفاده شد. گام چهارم، انتخاب تابع پیوندی؛ از تابع جمع کننده برای ایجاد پیوند میان زیرشاخه‌ها استفاده شد. در آخر عملگرهای ژنتیک و میزان هر یک از آن‌هاست؛ مقادیر آن‌ها در جدول ۳ درج شده است. پس از محاسبات انجام شده، سرانجام، برای ارزیابی مدل‌های پیش‌بینی از رابطه‌های ۲ تا ۴ شامل میانگین مربعات خطا (MSE)، محدود میانگین مربعات خطا (RMSE)، و میانگین مطلق خطا (MAE) استفاده و نتایج با یکدیگر مقایسه شد.

$$XN = \frac{X_{\max} - X_i}{X_{\max} - X_{\min}} \quad \text{رابطه ۱}$$

$$MSE = \frac{\sum_{i=1}^N (Qo - Qe)^2}{N} \quad \text{رابطه ۲}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Qo - Qe)^2}{N}} \quad \text{رابطه ۳}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Qo - Qe| \quad \text{رابطه ۴}$$

که در آن‌ها XN داده نرمال شده، X_{\max} داده بیشینه، X_i داده مورد نظر، X_{\min} داده کمینه، Q_0 مقدار مشاهده‌ای متغیر وابسته (دبی)، Q_e مقدار تخمینی متغیر وابسته (دبی تخمینی)، و N تعداد کل داده است.

یافته‌های پژوهش

با توجه به موارد ذکر شده در بخش پیشین، جدول ۱ ساختار و مدل‌های پیشنهادی و جدول ۲ نتایج مدل‌ها را به ترتیب نشان می‌دهد.

جدول ۱. مدل‌های نهایی حوضه آبخیز معرف امامه در استان تهران

شماره مدل	ورویدی	خروچی
۱	Pt	Qt
۲	ETt	Qt
۳	RHt	Qt
۴	Tt	Qt
۵	Qt-1	Qt
۶	Pt, Pt-1	Qt
۷	Pt, Qt-1	Qt
۸	ETt, Qt-1	Qt
۹	RHt, Qt-1	Qt
۱۰	Tt, Qt-1	Qt
۱۱	Qt-1, Qt-2	Qt
۱۲	Pt, Pt-1, Pt-2	Qt
۱۳	Pt, Pt-1, Qt-1	Qt
۱۴	Pt, Qt-1, Qt-2	Qt
۱۵	ET _t , Qt-1, Qt-2	Qt
۱۶	RH _t , Qt-1, Qt-2	Qt
۱۷	T _t , Qt-1, Qt-2	Qt
۱۸	Q _{t-1} , Q _{t-2} , Q _{t-3}	Qt
۱۹	P _t , P _{t-1} , P _{t-2} , Qt-1	Qt
۲۰	P _t , P _{t-1} , Qt-1, Qt-2	Qt
۲۱	P _t , Q _{t-1} , Q _{t-2} , Qt-3	Qt
۲۲	ET _t , Qt-1, Qt-2, Qt-3	Qt
۲۳	RH _t , Qt-1, Qt-2, Qt-3	Qt
۲۴	T _t , Qt-1, Qt-2, Qt-3	Qt
۲۵	P _t , T _t , ET _t , RH _t	Qt
۲۶	Q _{t-1} , Q _{t-2} , Q _{t-3} , Qt-4	Qt
۲۷	P _t , P _{t-1} , P _{t-2} , Qt-1, Qt-2	Qt
۲۸	P _t , P _{t-1} , Qt-1, Qt-2, Qt-3	Qt
۲۹	P _t , Q _{t-1} , Qt-2, Qt-3, Qt-4	Qt
۳۰	ET _t , Qt-1, Qt-2, Qt-3, Qt-4	Qt
۳۱	RH _t , Qt-1, Qt-2, Qt-3, Qt-4	Qt

ادامه جدول ۱. مدل‌های نهایی حوضه آبخیز معروف امامه در استان تهران

شماره مدل	ورودی	خرجی
۲۲	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۳۳	$P_t, T_t, ET_t, RH_t, Q_{t-1}$	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	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۳۹	$RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۴۰	$T_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۴۱	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t$	Q_t
۴۲	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}$	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	$ET_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	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	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}$	Q_t
۵۱	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	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	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}$	Q_t
۵۵	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	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	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۵۹	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	Q_t
۶۰	$P_t, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t
۶۱	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	Q_t
۶۲	$P_t, P_{t-1}, P_{t-2}, T_t, ET_t, RH_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	Q_t

در رابطه‌های بالا Q_t دبی خروجی، P_t میانگین بارندگی، ET_t میانگین تبخیر و RH_t میانگین رطوبت

نسبی، T_t میانگین دما، 1 دبی یک روز قبل، P_{t-1} میانگین بارندگی یک روز قبل، Q_{t-2} دبی دو روز قبل، P_{t-1}

2 میانگین بارندگی دو روز قبل، Q_{t-3} دبی سه روز قبل، 4 دبی چهار روز قبل، Q_{t-5} دبی پنج روز قبل، و

6 دبی شش روز قبل است.

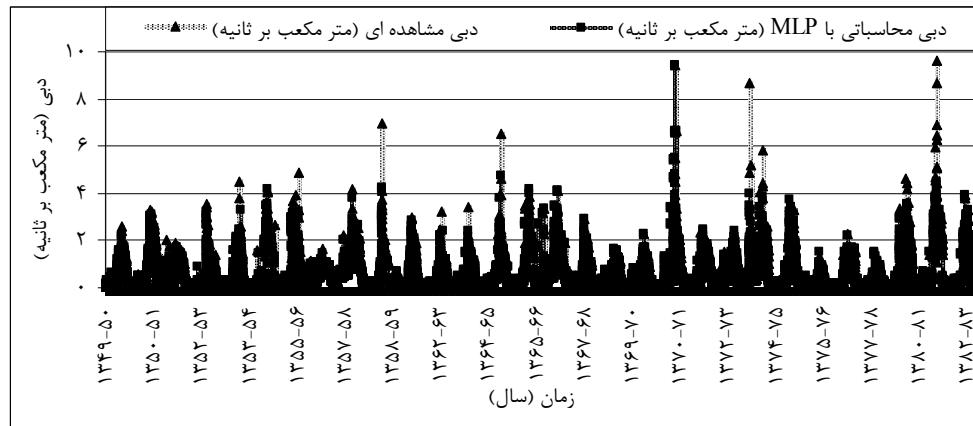
جدول ۲. نتایج مدل‌های شبکه عصبی پرسپترون چندلایه در حوضه آبخیز امامه

اعتبارستحی				آموزش			ساختار شبکه	شماره مدل
MAE	RMSE	MSE	MAE	RMSE	MSE			
۰/۱۳	۰/۳۷	۰/۱۴	۰/۳۴	۰/۵۷	۰/۳۳	۱-۴-۱	۱	
۰/۱۴	۰/۳۹	۰/۱۵	۰/۳۷	۰/۵۸	۰/۳۴	۱-۶-۱۲-۱	۲	
۰/۱۴	۰/۴۰	۰/۱۶	۰/۳۹	۰/۵۹	۰/۳۵	۱-۷-۹-۱	۳	
۰/۱۳	۰/۳۶	۰/۱۳	۰/۳۳	۰/۵۶	۰/۳۱	۱-۱۲-۱	۴	
۰/۰۶	۰/۲۰	۰/۰۴	۰/۰۸	۰/۲۲	۰/۰۵	۱-۱۱-۱	۵	
۰/۱۲	۰/۳۵	۰/۱۲	۰/۳۱	۰/۵۴	۰/۲۹	۲-۴-۴-۱	۶	
۰/۰۳	۰/۱۸	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۲-۱۱-۱	۷	
۰/۰۳	۰/۲۰	۰/۰۴	۰/۰۶	۰/۲۱	۰/۰۴	۲-۸-۱۰-۱	۸	
۰/۰۳	۰/۲۰	۰/۰۴	۰/۰۶	۰/۲۱	۰/۰۴	۲-۷-۱-۱	۹	
۰/۰۳	۰/۱۷	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۲-۹-۴-۱	۱۰	
۰/۰۳	۰/۱۷	۰/۰۳	۰/۰۶	۰/۲۰	۰/۰۴	۲-۸-۱۲-۱	۱۱	
۰/۱۱	۰/۳۲	۰/۱۰	۰/۲۸	۰/۵۰	۰/۲۵	۳-۵-۱	۱۲	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۳-۱۴-۱	۱۳	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۳-۱۴-۱	۱۴	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۳-۶-۳-۱	۱۵	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۳-۵-۱-۱	۱۶	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۳-۱۰-۱	۱۷	
۰/۰۳	۰/۱۷	۰/۰۳	۰/۰۶	۰/۲۰	۰/۰۴	۳-۴-۱۰-۱	۱۸	
۰/۰۳	۰/۱۶	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۴-۲-۱	۱۹	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۴-۹-۱۲-۱	۲۰	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۴-۱۳-۱	۲۱	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۴-۵-۶-۱	۲۲	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۴-۷-۱۰-۱	۲۳	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۴-۵-۳-۱	۲۴	
۰/۱۱	۰/۳۳	۰/۱۱	۰/۲۹	۰/۵۲	۰/۲۷	۴-۷-۱	۲۵	
۰/۰۸	۰/۲۲	۰/۰۵	۰/۰۸	۰/۲۴	۰/۰۶	۴-۱۵-۱	۲۶	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۵-۳-۷-۱	۲۷	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۱۰-۱۱-۱	۲۸	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۹-۹-۱	۲۹	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۳-۳-۱	۳۰	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۷-۱۱-۱	۳۱	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۴-۱۲-۱	۳۲	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۶	۰/۲۰	۰/۰۴	۵-۴-۱-۱	۳۳	

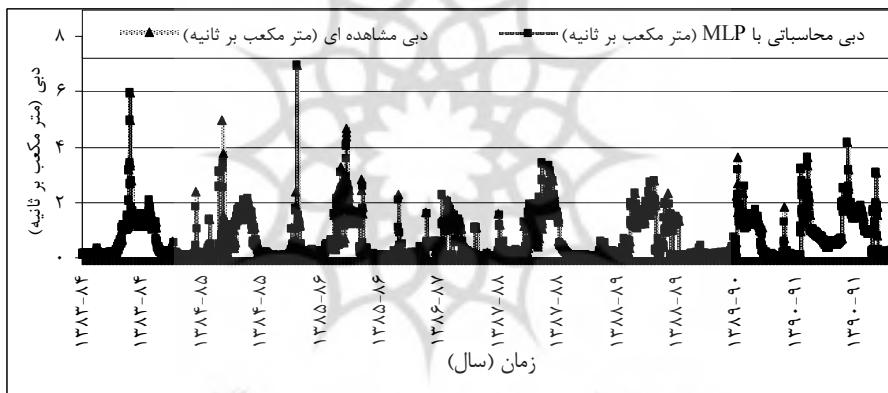
ادامه جدول ۲. نتایج مدل‌های شبکه عصبی پرسپترون چندلایه در حوضه آبخیز امامه

اعتبارستحی				آموزش			ساختار شبکه	شماره مدل
MAE	RMSE	MSE	MAE	RMSE	MSE			
۰/۰۸	۰/۲۴	۰/۰۶	۰/۰۹	۰/۲۶	۰/۰۷	۵-۸-۳-۱	۳۴	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۶-۶-۹-۱	۳۵	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۶-۸-۱	۳۶	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۶-۱۰-۱۲-۱	۳۷	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۶-۵-۶-۱	۳۸	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۶-۷-۱۰-۱	۳۹	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۶-۸-۲-۱	۴۰	
۰/۱۱	۰/۳۲	۰/۱۰	۰/۲۷	۰/۴۹	۰/۲۴	۶-۷-۵-۱	۴۱	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۶-۱۰-۱۰-۱	۴۲	
۰/۰۹	۰/۲۶	۰/۰۷	۰/۱۰	۰/۲۸	۰/۰۸	۶-۶-۱-۱	۴۳	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۷-۹-۱۱-۱	۴۴	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۷-۹-۵-۱	۴۵	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۷-۱۰-۱۰-۱	۴۶	
۰/۰۲	۰/۱۵	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۷-۹-۵-۱	۴۷	
۰/۰۲	۰/۱۶	۰/۰۳	۰/۰۶	۰/۲۱	۰/۰۴	۷-۴-۱۲-۱	۴۸	
۰/۰۲	۰/۱۵	۰/۰۲	۰/۰۶	۰/۲۱	۰/۰۴	۷-۷-۷-۱	۴۹	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۷-۴-۴-۱	۵۰	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۷-۸-۸-۱	۵۱	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۸-۱۶-۱	۵۲	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۸-۹-۱۲-۱	۵۳	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۴	۰/۱۸	۰/۰۳	۸-۹-۸-۱	۵۴	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۸-۶-۱۱-۱	۵۵	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۹-۹-۶-۱	۵۶	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۳	۹-۱۲-۱	۵۷	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۹-۹-۱۰-۱	۵۸	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۱۰-۸-۲-۱	۵۹	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۱۰-۷-۵-۱	۶۰	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۱۹	۰/۰۴	۱۱-۹-۲-۱	۶۱	
۰/۰۲	۰/۱۴	۰/۰۲	۰/۰۵	۰/۲۰	۰/۰۴	۱۲-۱۰-۲-۱	۶۲	

در جدول فوق در ستون ساختار شبکه عدد اول و آخر نشان‌دهنده تعداد نرون در لایه اول و لایه خروجی است و عدد دوم در ساختار سه‌تایی و عدد دوم و سوم در ساختار چهارتایی نشان‌دهنده تعداد نرون در لایه پنهان است. در ضمن، وجود سه و چهار عدد در ساختار شبکه به ترتیب نشان‌دهنده وجود یک و دو لایه پنهان در شبکه عصبی پرسپترون است.



شکل ۲. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش شبکه عصبی MLP حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹ - ۱۳۸۲ تا ۱۳۵۰ - ۱۳۸۳ (آزمایش)



شکل ۳. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش شبکه عصبی MLP حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۴- ۱۳۸۳ تا ۱۳۹۰ - ۱۳۹۱ (آزمایش)

جدول ۳. مقادیر پارامترهای لازم برای تجزیه و تحلیل داده‌ها با استفاده از برنامه‌ریزی ژنتیک

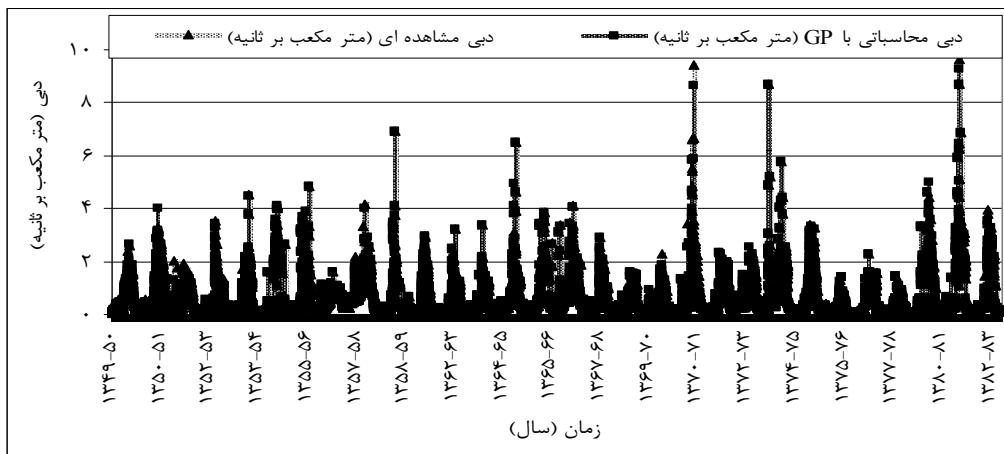
۳۰	تعداد کروموزوم‌ها (chromosomes)
۳	تعداد ژن‌ها (number of genes)
جمع	عملگر ریاضی بین ژن‌ها (linking function)
۰.۰۴۴	سرعت چهش (mutation rate)
۰.۰۱	سرعت وارونگی (inversion rate)
۰.۳۰	سرعت تلاقی با یک نقطه (one-point recombination rate)
۰.۳۰	سرعت تلاقی با دو نقطه (two-point recombination rate)
۰.۱۰	سرعت تلاقی ژن (gene recombination rate)
۰.۱۰	سرعت جابه‌جایی (gene transposition rate)

جدول ۴. نتایج مدل‌های برنامه‌ریزی ژنتیک در حوضه آبخیز امامه

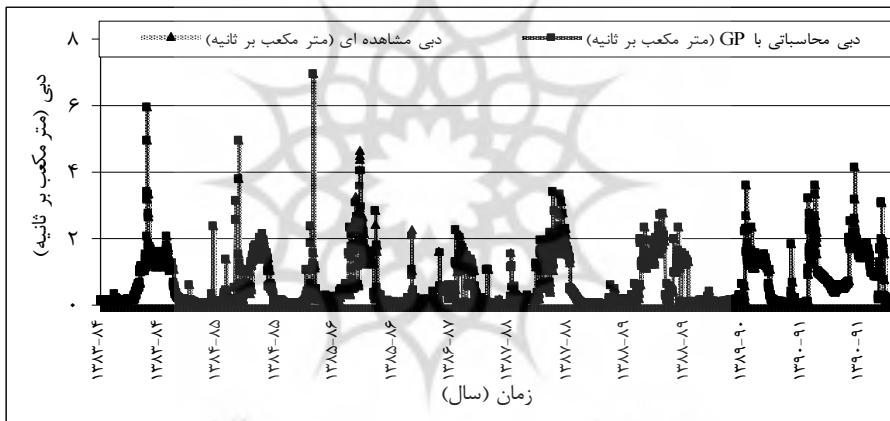
اعتبارستحصی				آموزش			شماره مدل
MAE	RMSE	MSE	MAE	RMSE	MSE		
.۰۰۱۶	.۰۰۸۹	.۰۰۰۸	.۰۰۱۵	.۰۰۷۸	.۰۰۰۶	۱	
.۰۰۱۶	.۰۰۹۰	.۰۰۰۸	.۰۰۱۵	.۰۰۷۹	.۰۰۰۶	۲	
.۰۰۱۷	.۰۰۹۵	.۰۰۰۹	.۰۰۱۵	.۰۰۸۴	.۰۰۰۷	۳	
.۰۰۱۶	.۰۰۸۹	.۰۰۰۷	.۰۰۱۵	.۰۰۷۷	.۰۰۰۶	۴	
.۰۰۱۵	.۰۰۷۸	.۰۰۰۶	.۰۰۱۴	.۰۰۶۸	.۰۰۰۵	۵	
.۰۰۱۶	.۰۰۸۸	.۰۰۰۷	.۰۰۱۵	.۰۰۷۶	.۰۰۰۶	۶	
.۰۰۱۵	.۰۰۷۷	.۰۰۰۵	.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	۷	
.۰۰۱۵	.۰۰۷۷	.۰۰۰۵	.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	۸	
.۰۰۱۵	.۰۰۷۷	.۰۰۰۵	.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	۹	
.۰۰۱۵	.۰۰۷۷	.۰۰۰۵	.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	۱۰	
.۰۰۱۵	.۰۰۷۸	.۰۰۰۶	.۰۰۱۴	.۰۰۶۸	.۰۰۰۵	۱۱	
.۰۰۱۶	.۰۰۸۶	.۰۰۰۷	.۰۰۱۴	.۰۰۷۱	.۰۰۰۶	۱۲	
.۰۰۱۳	.۰۰۶۴	.۰۰۰۴	.۰۰۱۲	.۰۰۵۵	.۰۰۰۳	۱۳	
.۰۰۱۴	.۰۰۶۸	.۰۰۰۴	.۰۰۱۲	.۰۰۵۹	.۰۰۰۳	۱۴	
.۰۰۱۴	.۰۰۶۸	.۰۰۰۴	.۰۰۱۲	.۰۰۵۹	.۰۰۰۳	۱۵	
.۰۰۱۴	.۰۰۶۸	.۰۰۰۴	.۰۰۱۲	.۰۰۵۹	.۰۰۰۳	۱۶	
.۰۰۱۴	.۰۰۶۸	.۰۰۰۴	.۰۰۱۲	.۰۰۵۹	.۰۰۰۳	۱۷	
.۰۰۱۵	.۰۰۷۸	.۰۰۰۶	.۰۰۱۴	.۰۰۶۸	.۰۰۰۵	۱۸	
.۰۰۱۵	.۰۰۷۷	.۰۰۰۵	.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	۱۹	
.۰۰۱۳	.۰۰۶۵	.۰۰۰۴	.۰۰۱۲	.۰۰۵۷	.۰۰۰۳	۲۰	
.۰۰۱۳	.۰۰۶۴	.۰۰۰۴	.۰۰۱۲	.۰۰۵۷	.۰۰۰۳	۲۱	
.۰۰۱۳	.۰۰۶۵	.۰۰۰۴	.۰۰۱۲	.۰۰۵۷	.۰۰۰۳	۲۲	
.۰۰۱۳	.۰۰۶۶	.۰۰۰۴	.۰۰۱۲	.۰۰۵۷	.۰۰۰۳	۲۳	
.۰۰۱۳	.۰۰۶۰	.۰۰۰۳	.۰۰۱۱	.۰۰۴۸	.۰۰۰۲	۲۴	
.۰۰۱۶	.۰۰۸۷	.۰۰۰۷	.۰۰۱۵	.۰۰۷۵	.۰۰۰۶	۲۵	
.۰۰۱۵	.۰۰۷۹	.۰۰۰۶	.۰۰۱۴	.۰۰۶۹	.۰۰۰۵	۲۶	
.۰۰۱۳	.۰۰۶۳	.۰۰۰۴	.۰۰۱۲	.۰۰۵۵	.۰۰۰۳	۲۷	
.۰۰۱۳	.۰۰۶۴	.۰۰۰۴	.۰۰۱۲	.۰۰۵۵	.۰۰۰۳	۲۸	
.۰۰۱۳	.۰۰۶۶	.۰۰۰۴	.۰۰۱۲	.۰۰۵۸	.۰۰۰۳	۲۹	
.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	.۰۰۱۲	.۰۰۵۸	.۰۰۰۳	۳۰	
.۰۰۱۳	.۰۰۶۷	.۰۰۰۴	.۰۰۱۲	.۰۰۵۸	.۰۰۰۳	۳۱	
.۰۰۱۳	.۰۰۶۶	.۰۰۰۴	.۰۰۱۲	.۰۰۵۷	.۰۰۰۳	۳۲	

ادامه جدول ۴. نتایج مدل‌های برنامه‌ریزی ژنتیک در حوضه آبخیز امامه

اعتیارستنجدی				آموزش			شماره مدل
MAE	RMSE	MSE	MAE	RMSE	MSE		
۰/۰۱۳	۰/۰۶۵	۰/۰۰۴	۰/۰۱۲	۰/۰۵۷	۰/۰۰۳	۳۳	
۰/۰۱۵	۰/۰۷۹	۰/۰۰۶	۰/۰۱۴	۰/۰۶۹	۰/۰۰۵	۳۴	
۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۳۵	
۰/۰۱۳	۰/۰۶۰	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۳۶	
۰/۰۱۴	۰/۰۷۲	۰/۰۰۵	۰/۰۱۳	۰/۰۶۴	۰/۰۰۴	۳۷	
۰/۰۱۴	۰/۰۷۲	۰/۰۰۵	۰/۰۱۳	۰/۰۶۴	۰/۰۰۴	۳۸	
۰/۰۱۴	۰/۰۷۴	۰/۰۰۵	۰/۰۱۳	۰/۰۶۴	۰/۰۰۴	۳۹	
۰/۰۱۴	۰/۰۷۱	۰/۰۰۵	۰/۰۱۳	۰/۰۶۳	۰/۰۰۴	۴۰	
۰/۰۱۵	۰/۰۸۵	۰/۰۰۷	۰/۰۱۴	۰/۰۷۰	۰/۰۰۵	۴۱	
۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۴۲	
۰/۰۱۵	۰/۰۸۴	۰/۰۰۷	۰/۰۱۴	۰/۰۶۹	۰/۰۰۵	۴۳	
۰/۰۱۲	۰/۰۵۸	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۴۴	
۰/۰۱۲	۰/۰۵۸	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۴۵	
۰/۰۱۵	۰/۰۷۶	۰/۰۰۵	۰/۰۱۳	۰/۰۶۶	۰/۰۰۴	۴۶	
۰/۰۱۵	۰/۰۷۶	۰/۰۰۵	۰/۰۱۳	۰/۰۶۶	۰/۰۰۴	۴۷	
۰/۰۱۵	۰/۰۷۶	۰/۰۰۵	۰/۰۱۳	۰/۰۶۶	۰/۰۰۴	۴۸	
۰/۰۱۵	۰/۰۷۵	۰/۰۰۵	۰/۰۱۳	۰/۰۶۵	۰/۰۰۴	۴۹	
۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۵۰	
۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۵۱	
۰/۰۱۲	۰/۰۵۷	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۵۲	
۰/۰۱۲	۰/۰۵۸	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۵۳	
۰/۰۰۹	۰/۰۳۲	۰/۰۰۱	۰/۰۰۹	۰/۰۳۱	۰/۰۰۱	۵۴	
۰/۰۱۲	۰/۰۵۰	۰/۰۰۲	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۵۵	
۰/۰۱۲	۰/۰۵۷	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۵۶	
۰/۰۱۰	۰/۰۴۵	۰/۰۰۲	۰/۰۱۰	۰/۰۴۵	۰/۰۰۲	۵۷	
۰/۰۱۲	۰/۰۵۵	۰/۰۰۳	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۵۸	
۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۰/۰۱۱	۰/۰۴۶	۰/۰۰۲	۵۹	
۰/۰۱۲	۰/۰۵۷	۰/۰۰۳	۰/۰۱۱	۰/۰۴۸	۰/۰۰۲	۶۰	
۰/۰۱۱	۰/۰۴۹	۰/۰۰۲	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۶۱	
۰/۰۱۲	۰/۰۵۵	۰/۰۰۳	۰/۰۱۱	۰/۰۴۷	۰/۰۰۲	۶۲	



شکل ۴. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش برنامه‌ریزی ژنتیک (GP) حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۴۹ - ۱۳۸۲ تا ۱۳۸۳ (آموزش)



شکل ۵. نمودار دبی روزانه مشاهده‌ای و پیش‌بینی شده به روش برنامه‌ریزی ژنتیک (GP) حوضه آبخیز امامه بر حسب ساختار ۵۴ برای سال‌های ۱۳۸۳ - ۱۳۸۴ تا ۱۳۹۰ تا ۱۳۹۱ (آزمایش)

بحث و نتیجه‌گیری

با توجه به نتایج شبکه عصبی پرسپترون چندلایه و برنامه‌ریزی ژنتیک، که در جدول ۲ و ۴ درج شده است، مشخص شد که خطای مدل‌هایی که در آن‌ها فقط از متغیرهای هواشناسی استفاده شده به مراتب بیشتر از خطای مدل‌هایی است که در آن‌ها از ورودی متغیرهای آب‌سنگی روزهای قبل استفاده شده است؛ این موضوع نشان می‌دهد که دبی‌های روزهای قبل در حوضه آبخیز معرف امامه اثر معنادارتر و بیشتری در جریان رودخانه نسبت به متغیرهای هواشناسی دارند. اما، از طرفی، مدل‌هایی که در آن‌ها فقط از یک نوع متغیر استفاده شده نمی‌توانند به تنها‌یکی کافی باشند و بیش از یک عامل یا متغیر و به عبارتی دسته‌ای از عوامل هواشناسی و آب‌سنگی در پیش‌بینی جریان رودخانه در این حوضه دخالت داشته‌اند؛ این موضوع نشان‌دهنده تأثیر عوامل مختلف بر جریان رودخانه است. از طرفی دیگر، در روش شبکه عصبی پرسپترون چندلایه میان مدل‌های موجود با یک ورودی بهتر ترتیب رطوبت نسبی دارای کمترین اثر بود و بیشترین خطای معیارهای ارزیابی بهتر ترتیب شامل RMSE، MSE و MAE برابر با ۰/۳۵، ۰/۵۹ و ۰/۳۹ در مرحله آموزش و ۰/۱۶، ۰/۴۰ و ۰/۱۴

در مرحله آزمایش بود و برای متغیر دما، که دارای بیشترین اثر (از بین ورودی مدل‌های با یک متغیر هواشناسی) بر جریان خروجی بود معیارهای ارزیابی بهترتبیش شامل MAE، RMSE و MSE برابر با $0,056, 0,031$ و $0,033$ در مرحله آموزش و $0,013, 0,036, 0,013$ در مرحله آزمایش بودند. درباره بارندگی نیز مشاهده شد که میزان خطای مدل وقتی که بارندگی با دو تأخیر استفاده می‌شود نسبت به زمانی که از بارندگی همان روز یا یک روز قبل استفاده می‌شود خطای مدل کاهش می‌یابد؛ این یافته با نتایج شریفی و همکاران (۱۳۹۲) مبنی بر تأثیر مثبت بارندگی روزهای قبل بر جریان رودخانه در حوضه آبخیز معرف امامه هم‌خوانی دارد. علاوه بر این، با توجه به معیارهای ارزیابی، از بین مدل‌هایی که فقط در آن‌ها از تأخیر زمانی جریان استفاده شده نتایج حاکی از تأثیر یکسان تأخیر زمانی تا سه روز بر جریان رودخانه حوضه امامه است و از تأخیر چهارم، پنجم، و ششم نه تنها تأثیری مشاهده نمی‌شود، بلکه خطاهای نیز افزایش یافته است؛ این موضوع نشان می‌دهد که حداکثر میزان توالی آورد رودخانه حوضه امامه برابر با دو تأخیر بوده است؛ این یافته با نتایج شریفی و همکاران (۱۳۹۲)، که با استفاده از آزمون گاما به این نتیجه رسیده‌اند، هم‌راستاست. با توجه به مدل ۵۴ (بهترین مدل) میزان ضریب همبستگی دبی مشاهدهای و پیش‌بینی شده در مرحله آموزش و آزمایش بهترتبیش برابر با $0,090$ و $0,082$ است (شکل‌های ۲ و ۳). بنابراین، با توجه به نتایج جدول ۲، مدل ۵۴ با هشت متغیر ورودی و با ساختار دو لایه پنهان- در لایه اول بهترتبیش با 9 نرون و با آرایش $1-8-9-8-1$ - دارای بهترین عملکرد بود. علاوه بر این، در این پژوهش از یک، دو، و سه لایه پنهان استفاده شد؛ نتایج نشان داد استفاده از سه لایه پنهان هیچ تأثیری در بهترشدن شرایط مدل‌ها ندارد و یک شبکه عصبی پرسپترون دو لایه مناسب بود. با نگاهی دقیق بر نتایج شبکه عصبی پرسپترون چندلایه، مشخص می‌شود که بیشتر مدل‌های این شبکه عصبی دارای دو لایه در لایه پنهان‌اند؛ به طوری که هر چه متغیرهای ورودی مدل افزایش می‌یابد و، به عبارتی، ساختار شبکه عصبی پیچیده‌تر می‌شود استفاده از شبکه عصبی پرسپترون چهارلایه، که دارای دو لایه پنهان است، می‌تواند بسیار موثر باشد. نتایج یافته‌های این تحقیق با نظر ریپ‌لای (۱۹۹۴) و فود و کارتمن (۱۹۹۶) مبنی بر استفاده از شبکه‌های پس‌انتشار خطای دو لایه مخفی به دلیل قابلیت انعطاف‌پذیری آن‌ها در حل مسائل هیدرولوژی به دلیل تغییرات شدید داده‌های اغتشاش حاکم بر داده‌ها هم‌خوانی دارد. همچنین، گرچه برای اجرای این تحقیق در پرسپترون چندلایه از یک، دو، و سه لایه در لایه پنهان استفاده شد، با توجه به نتایج مدل‌ها در حوضه مطالعه، هیچ یک از مدل‌های نهایی پرسپترون چندلایه دارای سه لایه پنهان نبود؛ حتی در صورت استفاده از سه لایه باعث افزایش خطای مدل‌ها در هر دو حوضه شد. از طرفی، تعداد نرون‌های لایه پنهان نیز از ۱ تا 30 نرون برای مدل‌ها به صورت سعی و خطای استفاده شد؛ نتایج نشان داد تعداد نرون‌های لایه پنهان چنانچه از یک لایه پنهان استفاده شود، بین ۱ تا 16 نرون است و اگر از دو لایه پنهان استفاده شود، بین ۱ تا 12 نرون برای حوضه آبخیز امامه برای یک و دو لایه پنهان به دست آمد؛ یافته‌های این تحقیق تأییدکننده آرای دائمی و همکاران (۲۰۱۱) و هیو و همکاران (۲۰۱۲) مبنی بر افزایش خطاهای در صورت افزایش تعداد نرون‌های لایه پنهان است. همچنین، روش برنامه‌ریزی ژنتیک در حوضه آبخیز امامه انجام شد و نتایج آن در جدول ۴ درج گردید. در این نوع روش نیز، با توجه به آماره‌های ارزیابی بدترین مدل، مدل ۳ با متغیر رطوبت نسبی، به عنوان تنها ورودی، دارای مقدار عددی بهترتبیش برابر با $0,007$ ، $0,009$ ، $0,0095$ و $0,009$ در مرحله آموزش و $0,015$ در مرحله آزمایش به عنوان ضعیفترین عملکرد

بود، بنابراین، بدترین مدل از بین ۶۲ ساختار ریاضی در حوضه آبخیز امامه شناخته شد؛ بعد از آن تبخیر و تعرق (مدل ۲) با میزان خطای برابر با $0.006, 0.079, 0.015$ در مرحله آموزش و $0.008, 0.090, 0.016$ در مرحله آزمایش، متغیر بارندگی (مدل ۱) با مقدار عددی بهترتبه برابر با $0.006, 0.078, 0.015$ در مرحله آموزش و $0.008, 0.089, 0.016$ در مرحله آزمایش، و دما (مدل ۴) با میزان خطای $0.006, 0.077, 0.015$ در مرحله آموزش و $0.007, 0.089, 0.016$ در مرحله آزمایش برای RMSE، MSE و MAE بودند. بهترین ساختار پیشنهادی هم مدل ۵ با میزان خطای $0.001, 0.031, 0.009$ در مرحله آموزش و $0.001, 0.032, 0.009$ در مرحله آزمایش بود. شکل‌های ۴ و ۵ نمودار مقادیر مشاهده‌ای و پیش‌بینی شده در مرحله آموزش و آزمایش را نشان می‌دهد. علاوه بر این، یکی از قابلیت‌های مهم روش برنامه‌ریزی ژنتیک ارائه رابطه ریاضی برای متغیرهای هیدرولوژیکی مورد مطالعه است. در این تحقیق نیز رابطه ریاضی به دست آمده با استفاده از برنامه‌ریزی ژنتیک برای حوضه آبخیز امامه به همراه ساختار آن در رابطه ۵ ارائه شده است.

$$Q_t = (Q_{t-2} - Q_{t-1})((RH_t Q_t - 10.92P_t)) + (Q_{t-1} - (0.02P_{t-1})0.06) + 0.089T_t + 0.089P_{t-2} - ET_t \quad \text{رابطه ۵}$$

از طرفی، از بین دو نوع مجموعه عملگر ریاضی اصلی از عملکرد بهتری برخوردار بود؛ به دلیل تعدد مدل‌ها، از ذکر نتایج مجموعه دوم- که شامل عملگرهای متعدد و زیادی بود، همچون \sin , \cos , \tan , $cotg$ شد. از آنجا که برنامه‌ریزی ژنتیک از ترکیب تصادفی مجموعه ترمینال‌ها (اعداد ثابت) و توابع به دست می‌آید، چنانچه رابطه بین ورودی‌ها و خروجی‌ها خطی باشد و از این نوع عملگرها استفاده شود، موجب کاهش دقت مدل می‌شود. نتایج این تحقیق نشان داد گرچه رابطه بارش- رواناب رابطه پیچیده و غیرخطی است، در تخمین این رابطه عملگرهای ذکر شده باعث پیچیدگی بیش از حد مدل و کاهش دقت مدل می‌شوند و برنامه‌ریزی ژنتیک خطی به دلیل کارایی بسیار زیاد قادر است با همان عملگرهای اصلی این رابطه غیرخطی را تخمین بزند؛ یافته‌های این تحقیق با نتایج داننده‌مهر و همکاران (۲۰۱۴) و سلطانی و همکاران (۱۳۸۹) همخوانی دارد. با توجه به نتایج شبکه عصبی دو حوضه مورد مطالعه و مقایسه آن با نتایج حاصل از برنامه‌ریزی ژنتیک مشخص شد که از بین شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیکی روش برنامه‌ریزی ژنتیکی از عملکرد بهتری برخوردار است؛ نتایج این تحقیق با نتایج دورادو و همکاران (۲۰۰۳)؛ آیتک و همکاران (۲۰۰۸)؛ گوین (۲۰۰۹)؛ وانگ و همکاران (۲۰۰۹)؛ قربانی و همکاران (۲۰۱۰)؛ داننده‌مهر و همکاران (۲۰۱۳)؛ فربودنام و همکاران (۱۳۸۸)؛ سلطانی و همکاران (۱۳۸۹) مبنی بر کارایی و دقت زیاد این روش با توجه به مقادیر خطاهای همخوانی دارد.

منابع

- سلطانی، ع؛ قربانی، م؛ فاخری‌فرد، ا؛ دریندی، ص. و فرسادی‌زاده، د. (۱۳۸۹). برنامه‌ریزی ژنتیک و کاربرد آن در مدل‌سازی فرایند بارش - رواناب، دانش آب و خاک، ۱(۴): ۶۱ - ۷۱.
- شریفی، ع.ر؛ دین‌پژوه، ی؛ فاخری‌فرد، ا. و مقدم‌نیا، ع.ر. (۱۳۹۲). ترکیب بهینه متغیرها برای شبیه‌سازی رواناب در حوضه آبخیز امامه با استفاده از آزمون کامل، دانش آب و خاک، ۴(۲۳): ۵۹ - ۷۲.

فریدونام، ن؛ قربانی، م.ع. و اعلمی، م.ت. (۱۳۸۸). پیش‌بینی جریان رودخانه با استفاده از برنامه‌ریزی ژنتیک (مطالعه موردی حوضه آبخیز لیقوان)، *دشن آب و خاک*، ۱۹(۱): ۱۰۷ - ۱۲۲.

مسعودی، ا؛ پارسامهر، پ؛ سلامسی، ف. و پوراسکندر، س. (۱۳۹۱). تخمین ضریب دبی در سرریزهای لبه پهنه مرکب با استفاده از رگرسیون، *برنامه‌ریزی ژنتیک، شبکه عصبی، آب و خاک*، ۲۶(۴): ۹۳۳ - ۹۴۲.

Aytek, A.; Asce, M. and Alp, M. (2008). **An Application of Artificial Intelligence for Rainfall-Runoff Modeling**, *Hydrology Earth System science*, 117(2): 145-155.

Chiang, J.L. and Yeh, C.H. (2010). **Suspended Sediment Forecasting in Gao-Pen River using Artificial Neural Network**, Vol. 12, EGU2010-7549.

Dai, X.; Huo, Z. and Wang, H. (2011). **Simulation for Response of Crop Yield to Soil Moisture and Salinity with Artificial Neural Network**, *Field crops research*, 121: 441-449.

DanandehMehr, A.; Kahya, E. and Olyaei, E. (2013). **Streamflow Prediction using Linear Genetic Programming in Comparison with a Neuro-Wavelet Technique**, *Journal of Hydrology*, 505: 240-249.

DanandehMehr, A.; Kahya, E. and Yerdelen, C. (2014). **Linear Genetic Programming Application for Successive-Station Monthly Stream Flow Prediction**, *Journal of Computers and Geosciences*, 70: 63-72.

Dawson, C.W. and Wilby, R.L. (2001). **Hydrological modeling using artificial neural network**, *Progress in Physical Geography*, 25(1): 80-108.

Dorado, J.; Rabunal, J.R.; Pazos, A.; Rivero, D.; Santos, A. and Puertas, J. (2003). Prediction and Modeling of the Rainfall-Runoff Transformation of a Typical Urban Basin using ANN and GP, *Applied Artificial Intelligence*, 17: 329-343.

Farboudfam, N.; Ghorbani, M.A. and 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).

Gharaei-Manesh, S.; Fathzadeh, A. and Taghizadeh-Mehrjardi, R. (2016). **Comparison of Artificial Neural Network and Decision Tree Models in Estimating Spatial Distribution of Snow Depth in a Semi-Arid Region of Iran**, *Cold Regions Science and Technology*, 122: 26-35.

Ghorbani, M.A.; Khatibi, R.; Aytek, A.; Makarynskyy, O. and Shiri, J. (2010). **Sea water Level Forecasting using Genetic Programming and Artificial Neural Networks**, *Computers and Geoscience*, 36(5): 620-627.

Guven, A. (2009). **Linear Genetic Programming for Time-Series Modeling of Daily Flow Rate**, *Journal of Earth System Science*, 118(2): 157-173.

Harun, S.; Ahmat Nor, N.I. and Kassim, A.H.M. (2002). **Artificial Neural Network Model for Rainfall-Runoff Relationship**, *Journal Technology*, Vol. 37, (B) Dis. 2002: 1° 12© University Technology Malaysia.

Hosseini, S.M. and 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. and 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. and Fernando, T. (2005). **Rainfall-Runoff Modelling using Genetic Programming**, *International Congress on Modelling and Simulation Society of Australia and New Zealand*, December 2005, New Zealand, PP. 1841-1847.

Koza, J.R. (1992). *Genetic Programming: On the Programming of Computers by Natural Selection*, A Bradford book Cambridge, MIT Press.

Masoodi, A.; Parsamehr, P.; Salmasi, F. and 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).

- Pramanik, N. and Panda, R.K. (2009). **Application of Neural Network and Adaptive Neurofuzzy Inference Systems for River Flow Prediction**, *Journal of Hydrology*, 54(2): 247-260.
- Sarangi, A. and Bhattacharya, A.K. (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, A.R.; Dinpashoh, Y.; Fakheri-Fard, A. and Moghaddamnia, A.R. (2013). **Optimal combination of Variables for Runoff Simulation in the Amameh Watershed using Gamma test**, *Water and Soil Science*, 23(4): 59-72 (In Persian).
- Sinivasulu, S. and Jain, A. (2006). **A comparative analysis of training methods for artificial neural network rainfall-runoff models**, *Applied Soft Computing*, 6: 295-306.
- 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, M.A.; Fakherifard, A.; Darbandi, S. and 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).
- Sudheer, P.K.; Gosain, A.K. and Ramasastri, K.S. (2002). **A Data Driven Algorithm for Constructing Artificial Neural Network Rainfall- Runoff Models**, *Journal of Hydrology*, 16(6): 1325-1330.
- Tao, W.; Kailin, Y. and Yongxin, G. (2008). **Application of Artificial Neural Networks to Forecasting Ice Conditions of the Yellow River in the Inner Mongolia Reach**, *Journal of Hydrology*, 13(9): 811-816.
- Wang, W.C.; Chau, K.W.; Cheng, Ch.T. and Qiu, L. (2009). **A Comparison of Performance of Several Artificial Intelligence Methods for Forecasting Monthly Discharge Time Series**, *Journal of Hydrology*, 374(3-4): 294-306.
- Wu, C.L.; Chau, K.W. and Li, Y.S. (2009). **Methods to Improve Neural Network Performance in Daily Flows Prediction**, *Journal of Hydrology*, 372(1-4): 80-93.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی