

مدل سازی بارش - رواناب روزانه رودخانه دره رود واقع در استان اردبیل

محمد رضا نیک پور^{۱*}، هادی ثانی خانی^۲، سجاد محمودی بابلان^۳ و سعید نسترنی عموقین^۴

^۱ - نویسنده مسئول، استادیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی. m_nikpour@uma.ac.ir

^۲ - استادیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه کردستان.

^۳ - دانش آموخته کارشناسی، گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

^۴ - دانش آموخته کارشناسی، گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

پذیرش: ۹۶/۲/۹

بازنگری: ۹۶/۲/۳

دریافت: ۹۵/۱۱/۱۰

چکیده

مدل سازی بارش - رواناب یکی از پراهمیت ترین موضوعات در مدیریت منابع آب های سطحی برای اتخاذ تدابیر مناسب در مواقع سیلاب و بروز خشک سالی ها است. در این تحقیق از مدل های شبکه های عصبی مصنوعی، برنامه ریزی بیان ژن، موجک - عصبی و حداقل مربعات ماشین بردار پشتیبان به منظور تخمین جریان روزانه رودخانه دره رود استفاده شد. داده های دبی و بارش روزانه ایستگاه مشیران واقع بر رودخانه مذکور و در بالادست سد عمارت به کار گرفته شد. نتایج نشان داد که الگوی تعریف شده بر اساس دبی روز قبل و بارش همان روز می تواند بهترین برآورد را از رواناب روزانه داشته باشد. هم چنین نتایج بیانگر عملکرد قابل قبول مدل ها و برتری مدل موجک - عصبی با بیشترین ضریب همبستگی ($R=+0/952$)، کمترین ریشه میانگین مربعات خطا ($RMSE=1/089$) و ضریب نش ساتکلیف برابر $+0/905$ در مرحله صحت سنجی بود. در برآورد دبی بیشینه نیز مدل مذکور با میانگین خطای نسبی $25/97$ درصد، از خطای کمتری نسبت به سایر مدل ها برخوردار بود.

کلید واژه ها: برنامه ریزی بیان ژن، تخمین جریان، حداقل مربعات ماشین بردار پشتیبان، شبکه عصبی مصنوعی، موجک - عصبی.

مقدمه

به همراه داشت. Jayawardena et al. (2005) با استفاده از برنامه ریزی ژنتیک (GP) و با به کارگیری داده های روزانه، بارش - رواناب دو حوضه نسبتاً بزرگ را در کشور چین شبیه سازی کردند که نتایج حاصل با داده های واقعی مطابقت خوبی داشت. Nourani et al. (2009) برای مدل سازی بارش - رواناب حوضه ليقوان چای از تلفیق تحلیل موجک با مدل ANN استفاده کردند. نتایج به دست آمده نشان داد که مدل پیشنهاد شده به دلیل استفاده از سری های زمانی با مقیاس چندگانه به عنوان لایه ورودی مدل ANN، قادر به پیش بینی رویدادهای بارندگی طولانی مدت و کوتاه مدت می باشد. Alp و Aytok (2008) با مدل های ANN و GEP بارش - رواناب روزانه رودخانه جونیاتا در ایالت پنسیلوانیای آمریکا را شبیه سازی کردند. نتایج تحقیق، برتری مدل GEP را نسبت به ANN در تخمین رواناب روزانه رودخانه مذکور نشان داد. Kisi (2008) عملکرد مدل ترکیبی WNN را با مدل NF در مدل کردن جریان ماهانه مقایسه و براساس نتایج تحقیق، مدل WNN را برای این منظور پیشنهاد نمود. Soltani et al. (2010) با کاربرد GEP در شبیه سازی فرآیند بارش - رواناب روزانه حوضه آبخیز ليقوان، با تعریف دو مجموعه عملگر ریاضی به این نتیجه دست یافتند که

بارش - رواناب یکی از پیچیده ترین فرآیندهای هیدرولوژیکی است که از متغیرهای مختلف فیزیکی و هیدرولوژیکی تأثیر می پذیرد. لذا درک و پیش بینی فرآیندهای تولید رواناب و انتقال آن به نقطه خروجی حوضه آبخیز یکی از اساسی ترین مباحث علم هیدرولوژی محسوب می شود (Salajegheh et al., 2009). از سوی دیگر، با توجه به محدودیت منابع آب شیرین قابل استحصال، پیش بینی هرچه دقیق تر دبی جریان و تغییرات آن در طول سال از ارکان اساسی برنامه ریزی و مدیریت منابع آب های سطحی است (Nabizadeh et al., 2012). نظر به اهمیت موضوع، تاکنون تحقیقات متعددی در خصوص استفاده از مدل های مختلف هوشمند شامل شبکه های عصبی مصنوعی (ANNs)، برنامه ریزی بیان ژن (GEP)، فازی - عصبی (NF)، موجک - عصبی (WNN) و ماشین بردار پشتیبان (SVM) برای تخمین جریان (رواناب) روزانه و ماهانه رودخانه ها و همچنین روندیابی سیلاب صورت پذیرفته است.

Markus و Tokar (2000) جریان ماهانه سه حوضه متفاوت آبخیز را از نظر شرایط آب و هوایی و خصوصیات فیزیوگرافی، با استفاده از ANNs و مدل مفهومی تعادل آب (Watbal) مدل سازی کردند. در نهایت مدل ANNs نتیجه بهتری

متغیرهای دبی جریان و بارش برای تعیین ورودی مدل های هوشمند استفاده شد.

مواد و روش ها

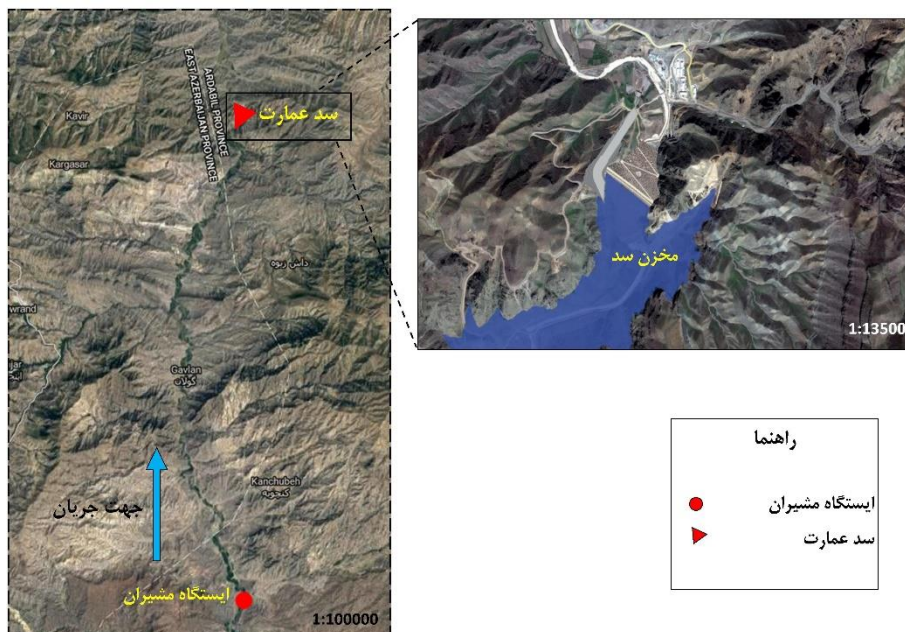
منطقه مورد مطالعه

حوضه آبریز دره رود با وسعتی برابر ۱۴۳۱۰ کیلومتر مربع بخش قابل توجهی از استان اردبیل را تحت پوشش قرار می دهد. ۶۸ درصد وسعت حوضه در استان اردبیل و ۳۲ درصد آن در استان آذربایجان شرقی است. دره رود که یکی از رودخانه های مهم حوضه آبریز مذکور می باشد، به عنوان مهمترین سرشاخه رود مرزی ارس در ایران، از الحاق دو سرشاخه اصلی قره سو و اهرچای تشکیل می گردد (Shafiee-Jood et al., 2012). برای شبیه سازی رواناب روزانه دره رود از داده های آماری مربوط به ایستگاه هیدرومتری مشیران واقع در رودخانه مذکور و در بالادست سد عمارت طی دوره آماری ۲۶ ساله از سال ۱۳۶۷ تا سال ۱۳۹۳ استفاده گردید. لازم به ذکر است که بر اساس گزارش های موجود، سد عمارت در سال ۱۳۹۷ بهره برداری خواهد شد. ایستگاه هیدرومتری مشیران در ۴۷/۵۲ درجه طول جغرافیایی، ۳۸/۵۳ درجه عرض جغرافیایی، در ارتفاع ۷۸۰ متری از سطح دریا واقع شده است. شکل (۱) محدوده و موقعیت کلی منطقه مورد مطالعه را نشان می دهد. داده های بارش و رواناب روزانه از سازمان هواشناسی و شرکت آب منطقه ای استان اردبیل اخذ شد. تعداد کل نمونه ها در طول دوره آماربرداری، معادل ۹۳۴۰ داده می باشد. ۷۰ درصد داده های مذکور (۶۵۳۸ داده) به عنوان داده های آموزش و ۳۰ درصد داده ها (۲۸۰۲ داده) به عنوان داده های صحت سنجی در نظر گرفته شد. در جدول (۱) متغیرهای آماری مربوط به داده های اندازه گیری شده در بازه زمانی مذکور نشان داده شده است.

انتخاب الگوهای مناسب

به منظور انتخاب ترکیب مناسب از متغیرهای ورودی مدل ها، از آزمون های آماری استفاده شد و مقادیر ضرایب خود همبستگی جزئی متغیر دبی و همبستگی متقابل متغیرهای بارش و دبی محاسبه گردید. مقادیر همبستگی بین متغیرهای دبی و بارش و تأخیرهای آن ها در جدول (۲) ارائه شده است. در جدول مذکور، متغیرهای R و Q به ترتیب بیانگر مقادیر اندازه گیری شده بارش و دبی در ایستگاه هیدرومتری مشیران می باشد و اندیس t شاخص گام زمانی فعلی می باشد. با توجه به همبستگی متقابل و معنی دار بین متغیرهای ورودی و خروجی، الگوهای مختلفی برای تخمین رواناب روزانه رودخانه دره رود مطابق با جدول (۳) استفاده شد.

مدل حاصل از مجموعه عملگرهای اصلی مناسب تر است. در سال های اخیر SVM به عنوان یک مدل جدید به منظور تخمین متغیرهای هیدرولوژیکی به کار گرفته می شود و موفقیت های قابل توجهی در زمینه های مختلف، از جمله مدل سازی و پیش بینی بارش و رواناب ماهانه به همراه داشته است. Behzad et al. (2009) با استفاده از آمار یک ایستگاه هیدرومتری واقع بر روی رودخانه بختیاری، جریان روزانه را با در نظر گرفتن آمار روز قبل پیش بینی نمودند. نتایج نشان داد که SVM از عملکرد بهتری نسبت به ANNs برخوردار است. Yu et al. (2006) در مطالعه ای با استفاده از مدل SVM به پیش بینی سطح رقمی سیل در رودخانه لن - یانگ تایوان پرداختند. نتایج نشان داد که مدل به خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش بینی می کند. Taheri and Ghafouri (2012) رواناب روزانه یکی از ایستگاه های رودخانه کارون را با به کارگیری داده های بارش، رطوبت و دما مدل سازی نمودند. در تحقیق مذکور مدل SVM نتیجه بهتری را نسبت به روش یادگیری فعال به همراه داشت. Botsis et al. (2011) بارش - رواناب روزانه حوضه آبخیزی واقع در کالیفرنیا را شبیه سازی کردند. مدل SVM با سه نوع تابع کرنل با مدل ANN مورد مقایسه قرار گرفت. در نهایت SVM شبیه سازی دقیق تری از بارش - رواناب داشت. Ghorbani and Dehghani (2015) کارایی سه مدل شبکه عصبی بیزین (BNN)، SVM و GEP را در تخمین رواناب ماهانه رودخانه کاکارضا مورد مقایسه قرار دادند. از میان سه مدل مذکور، BNN بهترین نتیجه را به همراه داشت. رودخانه دره رود به عنوان مهم ترین سرشاخه رود مرزی ارس در ایران، یکی از رودخانه های مهم استان اردبیل و یکی از منابع اصلی تأمین آب بخش های مختلف استان می باشد. از سوی دیگر روی رودخانه مذکور سد مخزنی عمارت در حال ساخت می باشد. بنابراین در تحقیق حاضر، نظر به موقعیت استراتژیک رودخانه مذکور و اهمیت مدیریت صحیح بهره برداری از آن، پیش بینی مقدار دبی جریان حائز اهمیت می باشد. با بررسی منابع انجام شده می توان گفت استفاده از روش های مدل سازی غیرخطی برای پیش بینی مقدار جریان رودخانه ضروری به نظر می رسد. لذا در این راستا مدل ANN به دلیل سادگی و کارآمدی بالا، مدل GEP به دلیل ارائه روابط صریح بین متغیرهای ورودی و خروجی، مدل LS-SVM به دلیل کارایی و سرعت بالا و مدل WNN به دلیل استفاده از نویزدایی در ساختار داده ها، برای تخمین جریان ورودی به مخزن سد عمارت (واقع بر رودخانه دره رود، استان اردبیل) مورد ارزیابی قرار گرفت. در بین مدل های ذکر شده دامنه مطالعات انجام شده در زمینه مدل های WNN و LS-SVM به خصوص در مطالعات مدل سازی بارش - رواناب و هیدرولوژی، نسبتاً کم و محدود می باشد. در این تحقیق از ضرایب همبستگی موجود بین



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

جدول ۱- خصوصیات آماری مقادیر دبی روزانه رودخانه مورد استفاده در بازه زمانی ۹۳-۱۳۶۷

متغیر	واحد	تعداد رکورد	میانگین	حداقل	حداکثر	انحراف معیار	ضریب تغییرات	چولگی
$R_{(t)}$	(mm)	۹۳۴۸	۰/۹۸۴	۰	۴۴/۵	۲/۹۹۲	۳/۰۴۰	۴/۸۶۱
$Q_{(t)}$	(m^3/day)	۹۳۴۸	۸/۶۳۲	۰	۱۸۵/۲	۱۰/۸۹۹	۱/۲۶۲	۳/۴۲۹

جدول ۲- مقادیر همبستگی بین متغیرهای بارش و دبی

R_{t-2}	R_{t-1}	R_t	Q_{t-1}	Q_t
۰/۱۱۵	۰/۱۲۶	۰/۱۰۷	۰/۹۱۶	

جدول ۳- ساختار الگوهای مورد استفاده در تحقیق حاضر

شماره الگو	ساختار ورودی	خروجی
۱	R_t	Q_t
۲	R_{t-1}, R_t	Q_t
۳	R_{t-2}, R_{t-1}, R_t	Q_t
۴	Q_{t-1}, R_t	Q_t
۵	Q_{t-1}, R_{t-1}, R_t	Q_t
۶	$Q_{t-1}, R_{t-2}, R_{t-1}, R_t$	Q_t

شبکه‌های عصبی مصنوعی (ANNs)

ساختار کلی ANN از شبکه بیولوژیکی مغز انسان الهام گرفته است. ANN با پردازش روی داده‌ها قوانین کلی را فرامی‌گیرد و خروجی‌های شبکه با خروجی‌های مطلوب (اندازه‌گیری شده) مقایسه می‌شود. در ابتدا با استفاده از داده‌ها و مقادیر اندازه‌گیری شده موجود، شبکه آموزش داده می‌شود. متغیرهای مؤثر که در مدل‌سازی شبکه‌های عصبی نقش اساسی

مدل‌های هوشمند

در تحقیق حاضر برای اجرای مدل‌های ANN، WNN و LS-SVM از کد نوشته شده توسط نویسندگان مقاله در محیط برنامه‌نویسی MATLAB و برای به‌کارگیری مدل GEP از نرم‌افزار GeneXproTools استفاده گردید. در ادامه به توضیح مختصر مدل‌های مذکور و ضرایب به‌کار رفته برای واسنجی مدل‌ها پرداخته می‌شود.

تجزیه تبدیل موجک گسسته، رابطه (۳) استفاده شد (Nourani et al., 2009). در این رابطه، L سطح تجزیه، N_s تعداد داده‌های سری زمانی و Int تابع جزء صحیح می‌باشد. در تحقیق حاضر از موجک‌های خانواده دابچیز (Daubechies) با سطح تجزیه ۳ استفاده گردید. در نهایت داده‌های حاصل از تجزیه توسط موجک پس از نرمال سازی (با استفاده از رابطه ۱) به عنوان ورودی شبکه عصبی تعریف شد.

$$L = Int(\log(N)) \quad (3)$$

برنامه ریزی بیان ژن (GEP)

روش برنامه ریزی بیان ژن، در سال ۱۹۹۹ توسط فریرا ارائه شد (Ferreira, 2001). این روش ترکیبی از روش‌های برنامه ریزی ژنتیک (GP) و الگوریتم ژنتیک (GA) بوده که در آن، کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه ریزی ژنتیک، ترکیب می‌شوند. از آنجایی که در این روش تمام ساختارهای شاخه‌ای با اندازه اشکال متفاوت، در کروموزوم‌های خطی با طول ثابت کدگذاری می‌شوند، معادل این است که در این روش فنوتیپ و ژنوتیپ از هم جدا می‌شوند و سیستم می‌تواند از تمام مزایای تکاملی به سبب وجود آن‌ها بهره‌مند شود. اکنون با وجود اینکه فنوتیپ در GEP، همان نوع از ساختارهای شاخه‌ای مورد استفاده در GP را شامل می‌شود، اما ساختارهای شاخه‌ای که به وسیله GEP استنتاج می‌شوند (که بیان درختی نیز نامیده می‌شود) مبین تمامی ژنوم‌های مستقل هستند. به طور خلاصه می‌توان گفت در GEP بهسازی‌ها در یک ساختار خطی اتفاق افتاده و سپس به صورت ساختار درختی بیان می‌شود و این موجب می‌شود تنها ژنوم اصلاح شده به نسل بعد منتقل شده و نیازی به ساختارهای سنگین برای تکثیر و جهش وجود نداشته باشد (Ferreira, 2006). در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی $\{+, -, \times, /\}$ ، توابع مثلثاتی و سایر توابع ریاضی و یا توابع تعریف شده توسط کاربر است که معتقد است، می‌تواند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسأله تشکیل شده‌اند (Ferreira, 2001). برای استخراج رابطه ریاضی برآورد مقدار دبی در این تحقیق علاوه بر چهار تابع اصلی حسابی، از توابع مثلثاتی شامل \sin و \cos و همچنین عملگرهای $\sqrt{\quad}$ ، \ln ، power و Exp استفاده گردید. پس از تحلیل حساسیت مدل برنامه ریزی بیان ژن در تخمین دبی، متغیرهای مورد استفاده و نرخ آن‌ها در جدول (۵) ارائه شده است.

دارند شامل تعداد تکرار و نوع تابع آموزش، تعداد لایه‌های شبکه و تعداد نرون‌های لایه میانی می‌باشد. گام مهم قبل از وارد کردن داده‌ها به مدل، نرمال سازی داده‌ها می‌باشد. این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (He et al., 2014). برای نرمال سازی داده‌های تحقیق حاضر از رابطه (۱) استفاده شد. در این رابطه، X_n مقدار نرمال شده ورودی X_i ، X_{\min} و X_{\max} به ترتیب مقادیر حداکثر و حداقل داده‌ها می‌باشد. به منظور به حداقل رساندن خطای مدل سازی پس از انجام تحلیل حساسیت، توابع و مقادیر بهینه در نظر گرفته شده برای شبکه عصبی مورد استفاده در تحقیق حاضر به شرح جدول (۴) می‌باشد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

موجک - عصبی (WNN)

موجک، یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا است. موجک نوسان حداقلی دارد که به سمت صفر نزول می‌کند و این نزول باید در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف پذیر بوده و مانند یک تابع رفتار کند، بنابراین با توجه به رفتارهای موجی نامنظم پدیده‌های هیدرولوژیک، قابلیت مدل سازی این پدیده‌ها توسط امواج نامنظم (موجک‌ها) نسبت به امواج منظم (امواج سینوسی) بیشتر است (Nourani et al., 2009). موجک دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است که شرط مقبولیت نامیده می‌شود و به شکل رابطه (۲) بیان می‌شود.

$$\int_{-\infty}^{+\infty} \phi(t) dt = 0 \quad (2)$$

در رابطه فوق، $\phi(t)$ تابع تبدیل موج (موجک مادر) است. عبارت مادر به این دلیل به کار رفته است که توابع (موجک‌های) متفاوت به وجود آمده بر اساس متغیرهای مقیاس و انتقال همگی از تابع پایه (موجک مادر) ناشی می‌شوند. تبدیل موجک عملگری است که یک تابع را به مجموعه‌ای از تبدیل موجک‌های مادر اصلاح شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح شده همان تبدیل موجک دختر می‌باشند (Marofi et al., 2012). بعد از تعیین نوع موجک مادر، مهم‌ترین اقدام تعیین سطح تجزیه بود. استفاده از حداکثر سطح تجزیه موجب کند شدن فرآیند آموزش و در برخی موارد می‌تواند موجب کاهش دقت مدل نیز گردد. برای انتخاب سطح

ماشین بردار پشتیبان (SVM)

ایده اصلی SVM که به عنوان فرآیندهای رگرسیونی و طبقه‌بندی شناخته می‌شوند، توسط Vapinc (1998) مطرح گردید. رگرسیون بردار پشتیبان جهت توصیف رگرسیون با استفاده از ماشین بردار پشتیبان می‌باشد. در این روش، تلاش بر این است تا وابستگی بین مجموعه داده‌های ورودی $X = (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n)$ از فضای R^n و مقادیر خروجی $Y = (\vec{y}_1, \vec{y}_2, \dots, \vec{y}_n)$ که در آن $y_i \in R$ از طریق تابع $y(x_i)$ تخمین زده شود. در این روش فرض بر این است که نمونه‌ها به صورت مستقل و از یک توزیع احتمالاتی نامعین گرفته شده‌اند. در مدل SVM برای حل معادلات از برنامه‌ریزی دوگانه استفاده می‌شود. لذا حل مسائل در ابعاد بزرگ با استفاده از مدل مذکور، هزینه محاسباتی را به شدت افزایش می‌دهد. برای رفع این مشکل، Suykens et al. (2002) روش حداقل مربعات ماشین بردار پشتیبان (LS-SVM) را ارائه نمودند. در این مدل از معادلات خطی ساده برای حل مسائل استفاده می‌شود که به طور مؤثری پیچیدگی الگوریتم را کاهش می‌دهد. تابع رگرسیونی مورد استفاده برای تخمین مسائل به صورت رابطه (۴) می‌باشد.

$$y(x_i) = w^T \cdot \phi(x_i) + b \quad (4)$$

که در آن $\phi(x_i)$ ترسیم غیرخطی ورودی‌ها در فضای ویژگی با ابعاد بالا می‌باشد. متغیرهای w و b به ترتیب مقادیر

وزن‌ها و بایاس تابع رگرسیون هستند که از طریق حداقل سازی تابع هدف در رابطه (۵) تعیین می‌گردد.

$$\min_{w,e,b} j(w,e) = \frac{1}{2} w^T \cdot w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \quad (5)$$

با محدودیت:

$$y_i = w^T \cdot \phi(x_i) + b + e_i \quad i = 1, 2, \dots, N \quad (6)$$

که در آن γ متغیر تنظیم‌کننده بخش خطا و e_i خطای داده‌های آموزش می‌باشد. در نهایت تابع تخمین مدل LS-SVM به صورت رابطه (۷) تعریف می‌شود.

$$y(x) = \sum_{i=1}^N a_i K(x_i, x_j) + b \quad (7)$$

در رابطه فوق، $K(x_i, x_j)$ تابع کرنل نامیده می‌شود که مطابق رابطه (۸)، به عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود (Rezaei et al., 2014).

$$K(x_i, x_j) = \langle \phi(x_i) \times \phi(x_j) \rangle \quad i, j = 1, 2, \dots, N \quad (8)$$

برای تحلیل حساسیت مدل LS-SVM توابع کرنل خطی، چندجمله‌ای و پایه شعاعی مورد آزمون قرار گرفت که از بین توابع مذکور، کرنل چندجمله‌ای از بالاترین سرعت و کمترین خطا برخوردار بود. ضمناً مقادیر متغیرهای تنظیم‌کننده و کرنل به ترتیب برابر ۲۰ و $[2 \text{ و } 0.2]$ در نظر گرفته شد.

جدول ۴- مقادیر متغیرهای مورد استفاده در مدل شبکه‌های عصبی مصنوعی

متغیر	بهترین مقدار
نوع شبکه عصبی	Feed-forward back propagation
تعداد لایه پنهان	۱
الگوریتم آموزشی	Levenberg-Marquardt
تعداد نرون	۱-۱۰
تابع انتقالی برای لایه اول	TANSIG
تابع انتقالی برای لایه دوم	RURELIN
تعداد تکرار	۱۰۰۰

جدول ۵- مقادیر متغیرهای مورد استفاده در روش برنامه‌ریزی بیان ژن

تنظیمات کلی	عملکردهای ژنتیکی
تعداد کروموزوم‌ها	۳۰
اندازه رأس	۷
تعداد ژن در هر کروموزوم	۳
تعداد جمعیت تولیدی	۱۰۰۰
تابع پیوند	مجموع (+)
	نرخ جهش ۰/۰۴۴
	نرخ وارون سازی ۰/۱
	نرخ ترانسپس درج متوالی ۰/۱
	نرخ ترانسپس ریشه درج متوالی ۰/۱
	نرخ ترکیب تک نقطه‌ای ۰/۳

معیارهای ارزیابی مدل

در تحقیق حاضر به منظور ارزیابی دقت و کارایی مدل ها از نمایه های ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش- ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای معیارهای مذکور به ترتیب یک، صفر و یک می باشد.

$$R = \frac{\sum_{i=1}^N (Q_i^O - \overline{Q^O})(Q_i^P - \overline{Q^P})}{\sqrt{\sum_{i=1}^N (Q_i^O - \overline{Q^O})^2 \sum_{i=1}^N (Q_i^P - \overline{Q^P})^2}} \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_i^O - Q_i^P)^2}{N}} \quad (10)$$

$$NS = 1 - \frac{\sum_{i=1}^N (Q_i^O - Q_i^P)^2}{\sum_{i=1}^N (Q_i^O - \overline{Q^O})^2} \quad (11)$$

در روابط فوق، Q_i^O و Q_i^P به ترتیب مقادیر دبی مشاهده ای و محاسباتی توسط مدل در گام زمانی i ام، N تعداد گام های زمانی، $\overline{Q^O}$ و $\overline{Q^P}$ نیز به ترتیب میانگین مقادیر دبی مشاهده ای و محاسباتی می باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش حول خط یک به یک و سری زمانی مقادیر مشاهده ای و محاسباتی برای مقایسه و تحلیل بیشتر نتایج استفاده شد.

نتایج و بحث

ارزیابی مدل ها بر اساس شاخص های آماری

در جدول های (۶) تا (۹) شاخص های آماری عملکرد مدل های مورد استفاده در تحقیق حاضر برای مراحل آموزش و صحت سنجی و به ازای الگوهای مختلف گزارش شده است. بر اساس نتایج گزارش شده در جدول های (۵) تا (۸)، برای مدل

GEP، الگوی شماره ۵ و برای سایر مدل ها الگوی شماره ۴ به طور نسبی بهترین عملکرد را به همراه داشت. الگوی ۴ در مقایسه با سایر الگوهای ترکیبی تعداد داده های ورودی کمتری نیاز دارد و مزیت مهم آن کاهش زمان اجرای مدل ها و پیچیدگی آن ها می باشد. بنابراین جریان رودخانه در هر روز در گام زمانی فعلی در حالت کلی متأثر از مقدار آن در روز قبل و بارش همان روز می باشد و استفاده از مقادیر بارش در گام های زمانی پیشین نیز تأثیری بر بهبود نتایج مدل ها در تخمین جریان رودخانه نداشت. از سوی دیگر ملاحظه می شود که در کلیه مدل ها، الگوهای ۱، ۲ و ۳ نتایج ضعیفی را به دنبال داشته است و این حاکی از آن است که در حوضه آبریز در هر روز صرفاً با استفاده از مقادیر بارش به تنهایی نمی توان برآورد صحیحی از جریان رودخانه داشت. در تحقیقات مشابه سایر محققین در خصوص شبیه سازی جریان رودخانه نیز الگوی تعریف شده بر اساس ترکیب گام های زمانی فعلی و پیشین بارش - رواناب، بهترین نتیجه را به دنبال داشت که از آن جمله می توان به تحقیقات (Jayawardena et al., 2005); (Ghorbani and Dehghani, 2015); (Nourani et al., 2009) اشاره نمود. مقایسه نتایج مدل های مختلف به ازای بهترین الگو حاکی از آن است که مدل WNN با بیشترین ضریب همبستگی ($R=0/952$)، کمترین ریشه میانگین مربعات خطا ($RMSE=1/589$) و همچنین ضریب نش ساتکلیف برابر $0/905$ در مرحله صحت سنجی عملکرد بهتری را نسبت به سایر مدل ها در تخمین جریان رودخانه از خود نشان داده است. علاوه بر آن، شاخص های آماری مربوط به مرحله آموزش مدل مذکور به مقادیر مطلوب نزدیک تر است. این در حالی است که عملکرد سایر مدل ها تقریباً مشابه یکدیگر می باشد. از سوی دیگر مقدار ضریب نش ساتکلیف مراحل آموزش و صحت سنجی کلیه مدل های مورد مطالعه در تحقیق حاضر به ازای الگوهای مطلوب، بزرگتر از $0/8$ حاصل شده است که حاکی از عملکرد قابل قبول آن ها می باشد (He et al., 2014; Shu and Ouarda, 2008).

جدول ۶- مقادیر شاخص های آماری عملکرد مدل LS-SVM برای الگوهای مختلف در مراحل آموزش و صحت سنجی

الگو	آموزش			صحت سنجی		
	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m^2/s)	نش ساتکلیف	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m^2/s)	نش ساتکلیف
۱	۰/۱۰۰	۱۲/۲۹۹	۰/۰۱۰	۰/۰۴۴	۷/۸۱۴	۰/۰۱۷
۲	۰/۱۲۷	۱۲/۲۴۵	۰/۰۱۸	۰/۰۵۶	۷/۸۳۳	۰/۰۳۲
۳	۰/۱۸۲	۱۲/۱۵۵	۰/۰۳۳	۰/۰۷۸	۷/۸۶۷	۰/۰۵۳
۴	۰/۹۲۸	۴/۵۸۶	۰/۸۶۲	۰/۹۳۳	۱/۹۳۸	۰/۸۵۹
۵	۰/۹۲۰	۴/۵۱۹	۰/۸۶۶	۰/۹۲۹	۲/۰۰۹	۰/۸۴۹
۶	۰/۹۳۰	۴/۵۲۰	۰/۸۶۶	۰/۹۳۰	۱/۹۹۱	۰/۸۵۱

جدول ۷- مقادیر شاخص‌های آماری عملکرد مدل WNN برای الگوهای مختلف در مراحل آموزش و صحت سنجی

الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف
۱	-۰/۲۲۸	۱۲/۰۲۷	۰/۰۵۶	-۰/۱۳۱	۸/۰۶۰	-۰/۱۰۵
۲	-۰/۲۵۱	۱۲/۰۱۷	۰/۰۶۲	-۰/۱۳۲	۸/۰۰۸	-۰/۱۲۴
۳	-۰/۳۳۶	۱۱/۶۳۹	۰/۱۱۳	-۰/۱۳۴	۸/۱۱۱	-۰/۱۲۵
۴	-۰/۹۷۴	۲/۸۰۹	۰/۹۴۸	-۰/۹۵۲	۱/۵۸۹	۰/۹۰۵
۵	-۰/۹۷۲	۲/۸۶۸	۰/۹۴۶	-۰/۹۴۲	۱/۷۴۰	۰/۸۸۶
۶	-۰/۹۷۴	۲/۸۴۱	۰/۹۴۷	-۰/۹۴۷	۱/۷۲۸	۰/۸۸۹

جدول ۸- مقادیر شاخص‌های آماری عملکرد مدل GEP برای الگوهای مختلف در مراحل آموزش و صحت سنجی

الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف
۱	-۰/۱۷۵	۱۲/۱۳۹	۰/۰۳۰	۰/۰۷	۷/۴۶۳	-۰/۰۱۷
۲	-۰/۲۰۹	۱۲/۰۵۲	۰/۰۴۳	۰/۰۹۵	۷/۷۹	-۰/۰۲۸
۳	-۰/۱۲۷	۱۲/۲۲۹	۰/۰۱۶	۰/۰۱۴۵	۷/۷۰۶	-۰/۰۳۵
۴	-۰/۹۱۶	۴/۹۳۹	۰/۸۳۹	-۰/۹۲۸	۱/۹۸۴	۰/۸۵۳
۵	-۰/۹۲۷	۵/۰۲۹	۰/۸۳۳	-۰/۹۳۰	۱/۹۳۱	۰/۸۶۰
۶	-۰/۷۸۰	۱/۴۱۰	۰/۸۳۴	-۰/۹۲۸	۱/۹۳۶	۰/۸۵۹


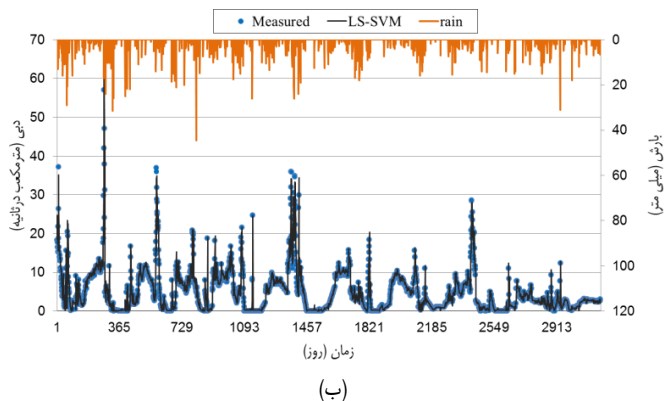
جدول ۹- مقادیر شاخص‌های آماری عملکرد مدل ANNs برای الگوهای مختلف در مراحل آموزش و صحت سنجی

الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف	ضریب همبستگی (R)	ریشه میانگین مربعات خطا (m ² /s)	نش ساتکلیف
۱	-۰/۱۳۰	۱۲/۲۵۴	۰/۰۱۷	۰/۰۷۷	۷/۷۷۲	-۰/۰۱۸
۲	-۰/۲۴۰	۱۲/۰۰۰	۰/۰۵۷	۰/۰۸۷	۷/۷۷۰	-۰/۰۴۲
۳	-۰/۲۲۳	۱۲/۰۵۰	۰/۰۴۹	۰/۱۲۷	۷/۷۶۳	-۰/۰۵۵
۴	-۰/۹۳۰	۴/۳۵۰	۰/۸۷۵	-۰/۹۳۰	۱/۹۱۱	۰/۸۶۰
۵	-۰/۹۳۰	۴/۶۳۰	۰/۸۵۹	-۰/۹۳۰	۱/۹۳۴	۰/۸۶۱
۶	-۰/۹۲۸	۴/۶۱۰	۰/۸۶۱	-۰/۹۳۰	۱/۹۳۲	۰/۸۶۱

ارزیابی مدل‌ها بر اساس نمودارهای پراکنش و سری زمانی


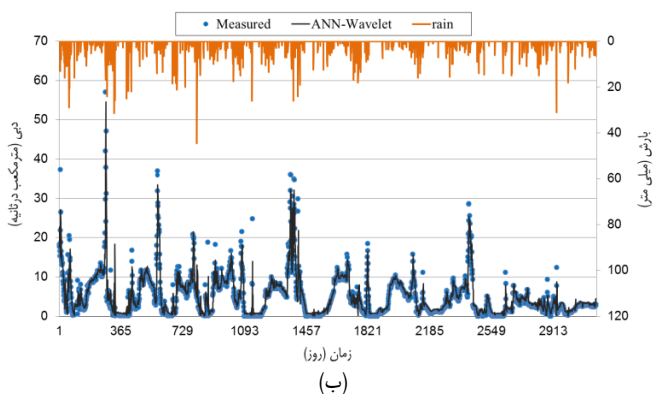
در شکل‌های (۲) تا (۵) نمودارهای پراکنش حول خط یک به یک ($y=x$) و سری زمانی مدل‌های مورد استفاده در تحقیق حاضر برای مرحله صحت‌سنجی و به‌ازای بهترین الگو نمایش داده شده است. همان‌طور که ملاحظه می‌شود در کلیه مدل‌ها پراکنش مناسبی حول محور یک به یک دیده می‌شود و در نمودارهای

سری زمانی آن‌ها هم‌پوشانی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی وجود دارد. از سوی دیگر با توجه به نمودارهای سری زمانی برای یک روز معین، تأثیر بارش بر مقدار جریان رودخانه کاملاً محسوس است، به‌طوری‌که فراز و نشیب مقدار دبی با نوسانات بارش همسو می‌باشد. برتری الگوی ۴ را نیز می‌توان به این موضوع مرتبط دانست.





شکل ۲- نمودارهای حاصل از مدل LS-SVM به ازای بهترین الگو در مرحله صحت سنجی

(الف) - پراکنش حول محور یک به یک (ب) - سری زمانی مقادیر مشاهداتی و شبیه سازی شده



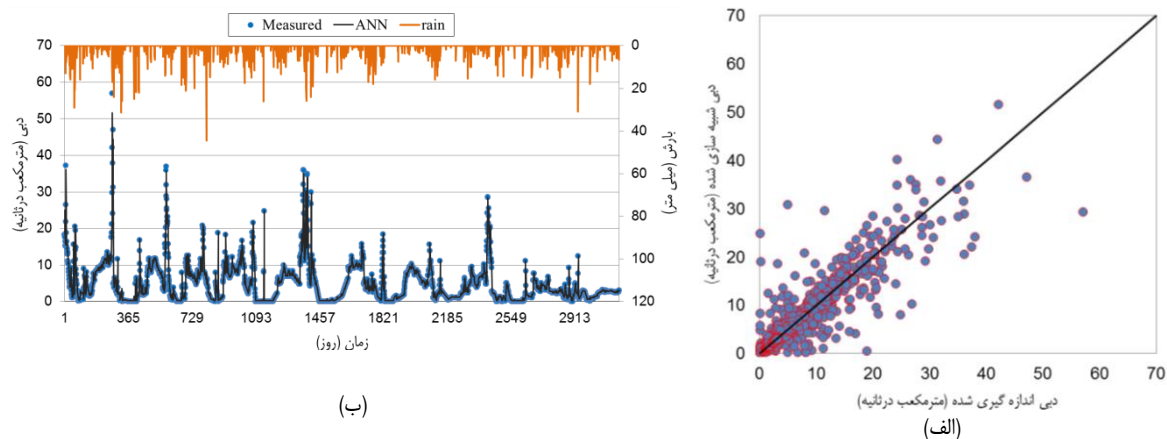
شکل ۳- نمودارهای حاصل از مدل WNN به ازای بهترین الگو در مرحله صحت سنجی

(الف) - پراکنش حول محور یک به یک (ب) - سری زمانی مقادیر مشاهداتی و شبیه سازی شده



شکل ۴- نمودارهای حاصل از مدل GEP به ازای بهترین الگو در مرحله صحت سنجی

(الف) - پراکنش حول محور یک به یک (ب) - سری زمانی مقادیر مشاهداتی و شبیه سازی شده



شکل ۵- نمودارهای حاصل از مدل ANN به ازای بهترین الگو در مرحله صحت سنجی

(الف) - پراکنش حول محور یک به یک (ب) - سری زمانی مقادیر مشاهداتی و شبیه سازی شده

ارزیابی مدل ها در پیش بینی دبی بیشینه (سیلاب)

تخمین دبی بیشینه جریان (دبی سیلاب) در بازه های پایین دست رودخانه، به منظور مدیریت و کنترل سیلاب بسیار حائز اهمیت می باشد. با توجه به نتایج جدول (۹) مشاهده می شود که خطای مدل ها در برآورد مقادیر دبی بیشینه تقریباً یکسان بوده و کمترین خطا به مقدار ۲۵/۹۷ درصد مربوط به مدل WNN می باشد.

مقادیر بیشینه دبی به دست آمده از بهترین الگوهای مدل های مختلف و مقادیر مشاهداتی متناظر آنها به همراه قدر مطلق خطای نسبی هر مدل در جدول (۱۰) ارائه شده است. لازم به ذکر است که برای محاسبه خطای نسبی از رابطه (۱۳) استفاده شد. در رابطه مذکور، RE معرف خطای نسبی، Q_c و Q_o به ترتیب مقادیر دبی بیشینه مشاهداتی و شبیه سازی شده می باشد.

$$RE(\%) = \left| \frac{Q_o - Q_c}{Q_o} \right| \times 100 \quad (13)$$

جدول ۱۰- کارآیی مدل های مورد مطالعه در شبیه سازی دبی بیشینه جریان

خطای نسبی			مقادیر شبیه سازی شده				مقادیر دبی بیشینه مشاهداتی	
موجک - عصبی	شبکه عصبی	برنامه ریزی بیان ژن	ماشین بردار پشتیبان	موجک - عصبی	شبکه عصبی	برنامه ریزی بیان ژن	ماشین بردار پشتیبان	
۴۶/۵۶	۴۸/۴۷	۴۸/۸۱	۴۱/۲۳	۳۰/۴۶	۲۹/۳۷	۲۹/۱۸	۳۳/۵۰	۵۷/۰۰
۴۱/۷۸	۲۲/۱۶	۲۳/۳۵	۲۲/۴۲	۲۷/۴۰	۳۶/۶۳	۳۶/۰۷	۳۶/۵۱	۴۷/۰۶
۷/۲۳	۲۲/۸۷	۲۹/۷۲	۲۷/۷۹	۳۹/۰۲	۵۱/۶۸	۵۴/۵۶	۵۳/۷۵	۴۲/۰۶
۲/۶۴	۳۵/۹۳	۳۸/۹۴	۳۵/۸۸	۳۶/۸۸	۲۴/۲۷	۲۳/۱۳	۲۴/۲۹	۳۷/۸۸
۲۲/۷۴	۴۰/۶۰	۴۳/۴۷	۴۰/۳۹	۲۸/۷۷	۲۲/۱۲	۲۱/۰۵	۲۲/۲۰	۳۷/۲۴
۲۵/۴۷	۵/۱۸	۷/۱۵	۵/۴۷	۲۷/۵۰	۳۴/۹۹	۳۴/۲۶	۳۴/۸۸	۳۶/۹۰
۳۳/۸۶	۱۹/۵۶	۲۲/۶۷	۱۹/۷۵	۲۳/۸۱	۲۸/۹۶	۲۷/۸۴	۲۸/۸۹	۳۶/۰۰
۴۲/۰۰	۴۲/۷۰	۴۵/۴۵	۴۲/۳۴	۲۰/۸۵	۲۰/۶۰	۱۹/۶۱	۲۰/۷۳	۳۵/۹۵
۱۱/۴۵	۱۲/۱۲	۱۴/۸۷	۱۲/۳۴	۳۱/۷۹	۳۱/۵۵	۳۰/۵۶	۳۱/۴۷	۳۵/۹۰
۲۵/۹۷	۲۷/۷۳	۳۰/۴۹	۲۷/۵۱	میانگین قدرمطلق خطا				

نتیجه گیری

تأثیرپذیری کمتر دبی جریان از متغیر بارش می باشد. بررسی شاخص های آماری نشان داد که مدل های مورد استفاده در تحقیق حاضر از عملکرد قابل قبول در برآورد روزانه رودخانه دره رود برخوردار می باشند. همچنین نظر به دقت بالاتر مدل WNN می توان از مدل مذکور به عنوان ابزاری کارآمد و قابل اعتماد در تخمین جریان رودخانه مذکور استفاده نمود. کارایی مدل های مختلف در پیش بینی دبی بیشینه نیز مورد بررسی قرار گرفت. نتایج حاصله دلالت بر این داشت که عملکرد مدل ها در این خصوص مشابه یکدیگر بوده و در عین حال مدل WNN در تخمین مقادیر پیک جریان در مقایسه با سایر مدل ها به صورت جزئی عملکرد بهتری را دارد. در مجموع با توجه به نتایج قابل قبول مدل های مورد استفاده در تحقیق حاضر، ضرایب و توابع به کار رفته برای واسنجی آن ها می تواند برای تخمین جریان حوضه آبریز دره رود بسیار مفید باشد.

در تحقیق حاضر کارایی مدل های مختلف هوشمند در تخمین جریان روزانه رودخانه دره رود مورد بررسی قرار گرفت. در این راستا حجم وسیعی از مقادیر دبی و بارش روزانه مشاهداتی طی دوره آماری ۲۶ ساله، در ایستگاه هیدرومتری مشیران واقع بر روی رودخانه مذکور مورد استفاده قرار گرفت. به منظور شبیه سازی جریان رودخانه شش الگوی متفاوت تعریف شد. در کلیه مدل ها با ترکیب بارش و دبی دقت تخمین جریان روزانه بهبود یافت. چنانچه بیشترین دقت مدل ها در ترکیب ورودی رواناب با یک تأخیر زمانی و بارش روزانه فراهم شد. این نشان دهنده تأثیرپذیری زیاد جریان حوضه آبریز دره رود از دبی روز قبل و بارندگی همان روز می باشد. در این راستا میزان تأثیرپذیری دبی جریان از دبی روز قبل به مراتب بیشتر از میزان بارندگی می باشد و لزوماً افزایش مقدار بارندگی موجب افزایش دبی نمی گردد. مقادیر ضرایب همبستگی (جدول ۲) نیز به لحاظ آماری حاکی از

منابع

- 1- Aytek, A. and Alp, M., 2008. An application of artificial intelligence for rainfall-runoff modeling. *Journal of Earth System Science*, 117(2), pp.145-155.
- 2- Behzad, M. Asghari, K. Eazi, M. and Palhang, M., 2009. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36(4), pp.7624-7629.
- 3- Botsis, D. Latinopoulos, P. and Diamantaras, K., 2011. Rainfall-Runoff Moeling Using Suport Vector Regression and Artificial Neural Networks. In *12th International Conference on Environmental Science and Technology, Rhodes, Greece*.
- 4- Ferreira, C., 2006. Automatically defined functions in gene expression programming. In *Genetic Systems Programming*. Springer Berlin Heidelberg.
- 5- Ferreira, C., 2001. Gene Expression Programming: a new adaptive algorithm for solving problems. *Complex Systems*, 13(2), pp.87-129.
- 6- Ghorbani, M.A. and Dehghani, R., 2015. Application of bayesian neural networks, support vector machines and gene expression programming analysis of rainfall - runoff monthly (case study: Kakarza river). *Irrigation Sciences and Engineering*, 39(2), pp.125-138. (In Persian).
- 7- He, Z. Wen, X. Liu, H. and Du, J., 2014. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509, pp.379-386.
- 8- Jayawardena, A.W. Muttill, N. and Fernando, T.M.K.G., 2005. Rainfall-runoff modeling using genetic programming. In *International Congress on Modeling and Simulation Society of Australia and New Zealand*.
- 9- Kisi, O., 2008. Stream flow forecasting using neuro-wavelet technique. *Journal of Hydrological Processes*, 22(20), pp.4142-4152.
- 10- Marofi, S. Amir-Moradi, K. and Parsafar, N., 2012. River flow prediction using Artificial Neural Network and Wavelet Neural Network models (Case study: Barandozchay River). *Water and Soil Science*, 23(3), pp.93-103. (In Persian).

- 11-Nabizadeh, M. Mosaedi, A. and Dehghani, A.A., 2012. Intelligent estimation of stream flow by Adaptive Neuro-Fuzzy Inference System). *Water and Irrigation Management*, 2(1), pp.69-80. (In Persian).
- 12-Nourani, V. Komasi, M. and Mano, A., 2009. A multivariate ANN-wavelet approach for rainfall-runoff modeling. *Journal of Water Resources Management*, 23(14), pp.2877-2894.
- 13-Rezaei, E. Khashei-Siuki, A. and Shahidi A., 2014. Design of groundwater level monitoring network, using the model of least squares support vector machine (LS-SVM). *Iranian Journal of Soil and Water Research*, 45(4), pp.389-396. (In Persian).
- 14-Salajegheh, A. Fathabadi, A. and 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*, 62(1), pp.65-79.
- 15-Shafiee-Jood, M. Abrishamchi, A. and Salavitarbar, A., 2012. Evaluation of water resources development plans in multi-reservoir darehrood sub catchment system using performance indices. *Journal of Water and Wastewater*, 3, pp.22-32. (In Persian).
- 16-Shu, C. and Ouarda, T.B.M.J., 2008. Regional flood frequency analysis at ungauged sites using the adaptive neuro-fuzzy inference system. *Journal of Hydrology*, 349(1), pp.31-43.
- 17-Soltani, A. Ghorbani, M.A. Fakheri-Fard, A. Darbandi, S. and Farsadizadeh, D., 2010. Genetic programming and application in rainfall-runoff modeling. *Water and Soil Science*, 20(4), pp.62-71. (In Persian).
- 18-Suykens, J.A. De Brabanter, J. Lukas, L. and Vandewalle, J., 2002. Weighted least squares support vector machines, pp. robustness and sparse approximation. *Neurocomputing*, 48(1), pp.85-105.
- 19-Taehri, H. and Ghafouri M., 2012. Comparison between active learning method and support vector machine for runoff modeling. *Journal of Hydrology and Hydromechanics*, 60(1), pp.16-32.
- 20-Tokar, A.S. and Markus, M., 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrologic Engineering*, 5(2), pp.156-161.
- 21-Vapnic, V.N., 1998. *Statistical Learning Theory*. Wiley, New York, USA.
- 22-Yu, P.S. Chen, S.T. and Chang, I.F., 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3), pp.704-716.