

کاربرد مدل‌های ANN، WNN، LS-SVM و GEP در شبیه‌سازی بارش- رواناب رودخانه خیاوچای

محمدرضا نیک‌پور^{۱*}، هادی ثانی‌خانی^۲، سجاد محمودی بابلان^۳، عارف محمدی^۴
 ۱. استادیار، گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی
 ۲. استادیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه کردستان
 ۳ و ۴. کارشناس مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

(تاریخ دریافت ۱۳۹۵/۱۰/۰۱؛ تاریخ تصویب ۱۳۹۵/۱۱/۲۰)

چکیده

پیش‌بینی جریان رودخانه به‌منظور مدیریت و برنامه‌ریزی منابع آب در رودخانه‌ها، دریاچه‌ها، مخازن سدها و همچنین برای حفاظت کناره‌های رودخانه در زمان وقوع سیلاب انجام می‌گیرد. در این تحقیق از مدل‌های شبکه‌های عصبی مصنوعی، هیبرید موجک-عصبی، برنامه‌ریزی بیان ژن و کمترین مربعات ماشین بردار پشتیبان به‌منظور تخمین جریان روزانه رودخانه خیاوچای استفاده شد. بدین‌منظور داده‌های دبی و بارش روزانه ایستگاه هیدرومتری پل سلطانی واقع بر رودخانه یادشده طی دوره آماری ۱۳۷۸-۱۳۹۲ به‌کار گرفته شد. پس از محاسبه ضرایب همبستگی متقابل متغیرهای بارش و دبی، شش الگوی مختلف به‌منظور تخمین رواناب روزانه تعیین شد. برای ارزیابی مدل‌ها از شاخص‌های آماری و آزمون ANOVA استفاده شد. نتایج بیان‌کننده برتری مدل هیبرید موجک-عصبی با بیشترین ضریب همبستگی ($R=0/877$)، کمترین ریشه میانگین مربعات خطا ($RMSE=0/696$) و ضریب نش ساتکلیف برابر $0/767$ در مرحله صحت‌سنجی بود. نتایج آزمون آنوا نیز نتایج شاخص‌های آماری را تأیید کرد و مدل هیبرید موجک-عصبی با داشتن کمترین مقدار آماره $F(0/11)$ و بیشترین سطح معناداری ($0/75$) به‌عنوان بهترین مدل شناخته شد. در برآورد دبی پیشینه (سیلاب) نیز مدل یادشده با میانگین خطای نسبی $30/19$ درصد، به مقدار شایان توجهی خطای کمتری نسبت به سایر مدل‌ها داشت.

کلیدواژگان: بارش- رواناب، برنامه‌ریزی بیان ژن، حداقل مربعات ماشین بردار پشتیبان، شبکه عصبی مصنوعی، هیبرید موجک-عصبی.

مقدمه

در بیشتر پروژه‌های مدیریت منابع آب و کنترل سیلاب، داشتن یک تخمین از رواناب به دست آمده از بارش ضروری است. هدف نهایی از مدل سازی بارش- رواناب نیز یافتن راه حلی با دقت مناسب برای برآورد رواناب بارش در یک حوضه آبریز و بررسی ارتباط تغییرات آن با مؤلفه‌های مؤثر در تولید رواناب است؛ اما بارش- رواناب فرایندی پیچیده و غیرخطی است و تغییرات مکانی و زمانی وسیعی دارد و به سادگی مدل سازی نمی شود. به همین دلیل مدل های پیش بینی کننده مختلفی با دیدگاه های متفاوت برای توسعه و بهبود مدل سازی این فرایند ارائه شده است. در حالت کلی، سه نگرش تئوریک، مفهومی و سیستمی در مدل سازی بارش- رواناب وجود دارد. به کارگیری مدل های تئوری و مفهومی به اطلاعات پیچیده و وسیع نیاز دارد؛ اما مدل های سیستمی (جعبه سیاه) با اینکه بر مبنای قوانین فیزیکی نیستند، در بسیاری از حالت ها ممکن است نتایج دقیقی به همراه داشته باشند و در تصمیم گیری ها مفید واقع شوند [۱]. تا کنون تحقیقات متعددی در خصوص استفاده از مدل های جعبه سیاه (هوشمند) شامل شبکه عصبی مصنوعی^۱، برنامه ریزی بیان ژن^۲، فازی- عصبی^۳، هیبرید موجک- عصبی^۴ و ماشین بردار پشتیبان^۵ برای تخمین جریان (رواناب) روزانه و ماهانه رودخانه ها صورت پذیرفته است.

پیشینه تحقیق

ویگهام و کراپر [۲] با استفاده از برنامه ریزی ژنتیک^۶ و مدل قطعی ایپاکرس^۷ فرایند بارش- رواناب روزانه را در دو حوضه تیفی و نامی واقع در کشور ولز مدل سازی کردند. نتایج برنامه ریزی ژنتیک دقت بیشتری نسبت به مدل قطعی داشت. لی یونگ و همکارانش [۳] با مطالعه رفتار بارش- رواناب در زمان های متفاوت نتیجه گرفتند که استفاده از مدل برنامه ریزی ژنتیک در پیش بینی بارش- رواناب در حوضه های آبریز با دقت مناسبی همراه است. جایاواردنا و همکارانش [۴] با استفاده از برنامه ریزی ژنتیک فرایند بارش- رواناب را با به کارگیری داده های روزانه در دو حوضه نسبتاً بزرگ چین

مدل سازی کردند که نتایج به دست آمده از GP با داده های واقعی مطابقت خوبی نشان داد. آیتک و همکارانش [۵] 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 یادشده نشان داد. نورانی و همکارانش [۶] مدل ترکیبی موجک- عصبی را برای شبیه سازی بارش- رواناب روزانه گیگل آبای واقع در اتیوپی به کار بردند. در تحقیق یادشده برای زیاد کردن دقت تخمین مدل، از مقادیر ثبت شده بارش توسط ماهواره ها استفاده شد. نایاک و همکارانش [۷] برای مدل سازی بارش- رواناب و استخراج هیدروگراف های سیلاب حوضه آبریز مالایرپها واقع در هندوستان از آمار روزانه دبی، بارش و تبخیر استفاده کردند. در تحقیق آنها، مدل موجک- عصبی نسبت به شبکه های عصبی مصنوعی عملکرد بهتری نشان داد. بدرزاده و همکارانش [۸] عملکرد سه مدل ANN، ANFIS و WNN را در تخمین رواناب روزانه حوضه آبریزی واقع در استرالیا را مقایسه کردند. همچنین به منظور مدیریت سیلاب ها از داده های بارش- رواناب ساعتی دو ایستگاه بالادست و پایین دست در حوضه آبریز یادشده استفاده کردند. در نهایت، مدل WNN عملکرد بهتری را مدل سازی بارش- رواناب و پیش بینی هیدروگراف های سیلاب به همراه داشت. نورانی [۹] برای اولین بار، کاربرد شبکه های عصبی عاطفی^۸ را در مدل سازی بارش- رواناب مطرح کرد. منطقه ای که او مطالعه کرد، دو حوضه آبریز با شرایط اقلیمی متفاوت در کشور فرانسه بود. نتایج نشان داد استفاده از مدل یادشده سبب بهبود دقت نتایج در مراحل آموزش و صحت سنجی نسبت به شبکه های عصبی کلاسیک می شود. در سال های اخیر ماشین بردار پشتیبان (SVM) به عنوان یک مدل جدید به منظور تخمین متغیرهای هیدرولوژیکی به کار گرفته می شود و موفقیت های شایان توجه در زمینه های مختلف، از جمله مدل سازی و پیش بینی بارش و رواناب ماهانه به همراه داشته است. بهزاد و همکارانش [۱۰] با استفاده از آمار یک ایستگاه هیدرومتری واقع بر رودخانه بختیاری، جریان روزانه را با در نظر گرفتن آمار روز قبل پیش بینی کردند. نتایج پژوهش آنها نشان داد SVM عملکرد بهتری نسبت به شبکه های عصبی دارد. باتسیس و همکارانش [۱۱] بارش- رواناب روزانه

1. Artificial Neural Network (ANN)
2. Gene Expression Programming (GEP)
3. Neuro-Fuzzy
4. ANN-Wavelet Hybrid (WNN)
5. Support Vector Machine (SVM)
6. Genetic Programming (GP)
7. IHACRES

8. Emotional ANN

به ایستگاه پل سلطانی واقع در رودخانه یادشده طی دوره آماری ۱۵ ساله از سال ۱۳۷۸ تا سال ۱۳۹۲ استفاده شد. ایستگاه پل سلطانی در 40° - 47° طول جغرافیایی، 24° - 38° عرض جغرافیایی، در ارتفاع ۱۴۲۰ متری از سطح دریا واقع شده است. شکل ۱ محدوده و موقعیت کلی منطقه مطالعه شده 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 طی دوره آماری، معادل ۵۴۹۰ داده است. ۶۰ درصد داده های یادشده (۳۳۰۳ داده) به عنوان داده های آموزش^۲ و ۴۰ درصد آنها (۲۱۸۷ داده) به عنوان داده های صحت سنجی^۳ در نظر گرفته شد. در جدول ۱ پارامترهای آماری مربوط به داده های اندازه گیری شده در بازه زمانی یادشده 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 خودهمبستگی جزئی متغیر دبی و همبستگی متقابل متغیرهای بارش و دبی محاسبه شد. مقادیر همبستگی بین متغیرهای دبی و بارش و تأخیرهای آنها در جدول ۲ ارائه شده است. در جدول یادشده، پارامترهای R و Q به ترتیب بیان کننده مقادیر اندازه گیری شده بارش و دبی در ایستگاه پل سلطانی و اندیس t شاخص گام زمانی فعلی است. با توجه به همبستگی متقابل و معنادار بین متغیرهای ورودی و خروجی، الگوهای مختلفی برای تخمین رواناب روزانه رودخانه دره رود مطابق با جدول ۳ استفاده شد.

مدل های هوشمند

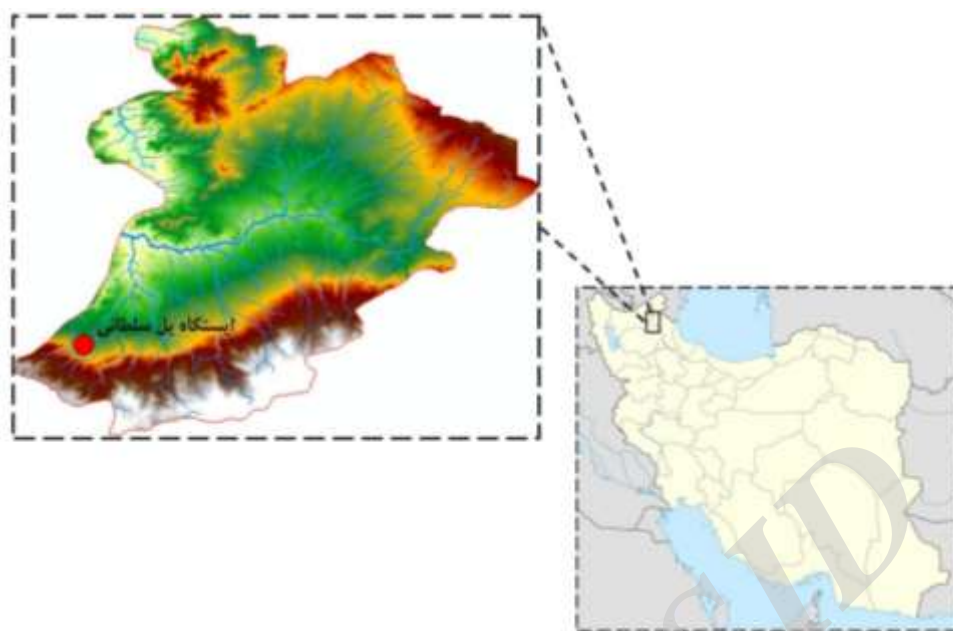
در تحقیق حاضر برای اجرای مدل های شبکه عصبی مصنوعی، هیبرید موجک-عصبی و کمترین مربعات ماشین بردار پشتیبان از کد نوشته شده توسط نویسندگان مقاله در محیط برنامه نویسی MATLAB و برای به کارگیری مدل برنامه ریزی بیان ژن از نرم افزار GeneXproTools استفاده شد. در ادامه به توضیح مختصر مدل های یادشده و ضرایب به کاررفته برای واسنجی مدل ها پرداخته می شود.

حوضه آبخیزی واقع در کالیفرنیا را شبیه سازی کردند. مدل SVM با سه نوع تابع کرنل با مدل ANN مقایسه شد. در نهایت، ماشین بردار پشتیبان شبیه سازی دقیق تری از بارش- رواناب داشت. آداموسکی [۱۲] مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای شبیه سازی بارش- رواناب حوضه کوهستانی دهرادان در هندوستان را استفاده کردند. مدل SVM در پیش بینی رواناب مستقیم، جریان پایه و جریان کل این منطقه کارایی بهتری از خود نشان داد. قربانی و همکارانش [۱۳] کارایی سه مدل شبکه عصبی بیزین، SVM و GEP را در تخمین رواناب ماهانه رودخانه کاکارضا را مقایسه کردند. از میان سه مدل یادشده، شبکه عصبی بیزین بهترین نتیجه را به همراه داشت. ناظری تهرودی و همکارانش [۱۴] رواناب ماهانه رودخانه نازلوچای واقع در غرب دریاچه ارومیه را با استفاده از داده های بارش و دبی با تأخیرهای یک تا پنج ماه بررسی کردند. در تحقیق آنها مدل ANFIS نسبت به مدل های GP و SVM نتیجه بهتری به همراه داشت. بر اساس موارد یادشده و دقت قابل قبول مدل های هوشمند در پیش بینی جریان رودخانه، در تحقیق حاضر از مدل های شبکه عصبی مصنوعی، هیبرید موجک-عصبی، برنامه ریزی بیان ژن و کمترین مربعات ماشین بردار پشتیبان^۱ برای مدل سازی بارش- رواناب روزانه رودخانه خیابوچای واقع در شهرستان مشکین شهر استفاده شد. رودخانه خیابوچای مهم ترین منبع تأمین آب شهرستان مشکین شهر و یکی از سرشاخه های اصلی رودخانه قره سو است. خیابوچای از کوه های سبلان سرچشمه می گیرد و پس از عبور از مسیرهای کوهستانی وارد شهرستان مشکین شهر می شود. به همین دلیل سالانه بارش های رگباری، سیلاب های مخربی را در منطقه یادشده به جای می گذارد. بر این اساس و نظر به سیل خیز بودن حوضه آبریز خیابوچای، آگاهی از چگونگی ارتباط بین بارندگی و رواناب حوضه آبریز یادشده به منظور بهبود برنامه ریزی و اقدامات مدیریتی اهمیت دارد.

مواد و روش ها

منطقه مطالعه شده

حوضه آبریز خیابوچای با وسعت $142/3$ کیلومتر مربع در استان اردبیل، شهرستان مشکین شهر واقع شده است. برای پیش بینی رواناب روزانه خیابوچای از داده های آماری مربوط



شکل ۱. موقعیت جغرافیایی منطقه مطالعه شده

جدول ۱. خصوصیات آماری مقادیر دبی روزانه رودخانه استفاده شده در بازه زمانی ۱۳۷۸-۱۳۹۲

پارامتر	واحد	تعداد رکورد	میانگین	کمترین	بیشترین	انحراف معیار	ضریب تغییرات	چولگی
بارش	(mm)	۵۴۹۰	۱/۰۸۳	۰	۴۸/۷	۳/۳۹۲	۳/۱۳۰	۵/۶۱۴
دبی	(m ³ /s)	۵۴۹۰	۰/۶۱۲	۰	۱۷/۸	۱/۰۵۹	۱/۷۲۶	۶/۰۴۰

جدول ۲. مقادیر همبستگی بین متغیرهای بارش و دبی

R_{t-2}	R_{t-1}	R_t	Q_{t-1}	Q_t
۰/۰۱۷	۰/۰۰۷	۰/۰۰۶	۰/۸۶۰	

جدول ۳. ساختار الگوهای استفاده شده 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

می‌شود [۱۳]. در این مدل برای حل معادلات از برنامه‌ریزی دوگانه استفاده می‌شود. بنابراین، حل مسائل در ابعاد بزرگ با استفاده از مدل یادشده، هزینه محاسباتی را به شدت افزایش می‌دهد. برای رفع این مشکل، سویکنز و همکارانش [۱۶] روش کمترین مربعات ماشین بردار

مدل کمترین مربعات ماشین بردار پشتیبان (LS-SVM) ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که توسط وپینک [۱۵] ارائه شد. در این مدل از اصل استقرای کمینه‌سازی خطای ساختاری استفاده و به یک جواب بهینه کلی منجر

تعداد تکرار^۵ در مرحله آموزش، تعداد لایه های شبکه و تعداد نورون های لایه میانی است. در حالت کلی، هر چه تعداد تکرار در آموزش شبکه بیشتر شود، خطای شبیه سازی شبکه کمتر می شود؛ اما هنگامی که تعداد تکرارها از یک مقدار تجاوز کند، خطای دسته آزمایشی نیز افزایش می یابد. بهترین تعداد تکرار آموزشی مقداری است که خطای هر دو دسته آزمایشی و آموزشی تا حد ممکن کمینه شوند [۱۸]. به منظور به حداقل رساندن خطای مدل سازی پس از انجام تحلیل حساسیت، توابع و مقادیر بهینه در نظر گرفته شده برای شبکه عصبی استفاده شده در تحقیق حاضر به شرح جدول ۴ است.

جدول ۴. مقادیر پارامترهای استفاده شده در مدل شبکه های

عصبی مصنوعی

پارامتر	بهترین مقدار
نوع شبکه عصبی	Feed-forward back propagation
تعداد لایه پنهان	1
الگوریتم آموزش	Levenberg-Marquardt
تعداد نورون	1-10
تابع انتقالی برای لایه اول	TANSIG
تابع انتقالی برای لایه دوم	RURELIN
تعداد تکرار	1000

مدل ترکیبی موجک-عصبی (WNN)

تبدیل موجک یکی از مبدل های ریاضی کارآمد در زمینه پیش بینی سیگنال است. آموزش شبکه عصبی مصنوعی با پیش پردازش داده ها با استفاده از تبدیل موجک کارکرد مؤثری در یاد کردن دقت پیش بینی ها دارد. تبدیل های موجکی به دو دسته موجک پیوسته و گسسته تقسیم می شوند. برای کاربردهای عملی، هیدرولوژیست ها اغلب سیگنال های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال های زمانی گسسته در اختیار آنهاست. از این رو، تبدیل موجک گسسته در طرح های هیدرولوژی بیشتر استفاده می شود [۱۹]. موجک سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر دارد که شرط مقبولیت نامیده می شود و به شکل رابطه ۶ بیان می شود.

پشتیبان را ارائه کردند. در این مدل از معادلات خطی ساده برای حل مسائل استفاده می شود که به طور مؤثری پیچیدگی الگوریتم را کاهش می دهد. تابع رگرسیونی استفاده شده در مدل SVM برای تخمین مسائل به صورت رابطه ۱ است.

$$y(x_i) = w^T \cdot \varphi(x_i) + b \quad (1)$$

که در آن $\varphi(x_i)$ ترسیم غیرخطی ورودی ها در فضای ویژگی با ابعاد زیاد است. پارامترهای w و b به ترتیب مقادیر وزن ها و بایاس تابع رگرسیون هستند که از طریق حداقل سازی تابع هدف در رابطه ۵ تعیین می شوند.

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

با محدودیت:

$$y_i = w^T \varphi(x_i) + b + e_i \quad i = 1, 2, \dots, N \quad (3)$$

که در آن γ پارامتر تنظیم کننده بخش خطا و e_i خطای داده های آموزش است. در نهایت، تابع تخمین مدل LS-SVM به صورت رابطه ۴ تعریف می شود.

$$y(x) = \sum_{i=1}^N a_i K(x_i, x_j) + b \quad (4)$$

در رابطه ۴ $K(x_i, x_j)$ تابع کرنل نامیده می شود که مطابق رابطه ۵، به عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می شود [۱۶].

$$K(x_i, x_j) = \varphi(x_i) \cdot \varphi(x_j) \quad i, j = 1, 2, \dots, N \quad (5)$$

برای تحلیل حساسیت مدل LS-SVM توابع کرنل خطی^۱، چندجمله ای^۲ و پایه شعاعی^۳ آزموده شد که از بین توابع یاد شده، کرنل پایه شعاعی بیشترین سرعت و کمترین خطا را داشت. در ضمن، مقادیر پارامترهای تنظیم کننده و کرنل به ترتیب برابر ۱۰ و ۰/۴ در نظر گرفته شد.

شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یکی از روش های محاسباتی است که به کمک فرایند یادگیری^۴ و با استفاده از پردازشگرهایی به نام نورون تلاش می کند با شناخت روابط ذاتی بین داده ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد [۱۷]. پارامترهای مؤثر در مدل سازی شبکه های عصبی شامل

1. Linear
2. Polynomial
3. Radial Basis Function Kernel
4. Learning

5. Epoch

اظهار شده، که این هم مطابق با یک تابع برازش ارزیابی می‌شود تا میزان مناسب بودن یک راه حل در حیطه مسئله تعیین شود. معمولاً تابع برازش به وسیله پردازش تعدادی نمونه از مسئله هدف ارزیابی می‌شود که موارد برازش نیز نامیده می‌شوند. اگر کیفیت رضایت بخش از یک راه حل پیدا شود و یا نسل‌ها به تعداد معینی برسد، تکامل متوقف شده و بهترین راه حل یافت شده گزارش داده می‌شود. از طرف دیگر، اگر شرایط توقف یافت نشود، بهترین راه حل از نسل حاضر نگه داشته می‌شود (به معنای نخبه‌گزینی است) و بقیه راه حل‌ها به فرایندی گزینشی واگذار می‌شوند. گزینش یا انتخاب، کارکرد بقای شایستگی دارد و بر اساس آن بهترین افراد شانس بهتری برای تولید فرزندان دارند. کل این روند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو، انتظار می‌رود که کیفیت جمعیت نیز به طور متوسط بهبود یابد [۲۲]. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی 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 مسئله تشکیل شده‌اند [۲۱]. 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 ، Exp ، ln ، power استفاده شد. پس از تحلیل حساسیت مدل برنامه‌ریزی بیان ژن در تخمین دبی، پارامترهای استفاده شده و نرخ آنها در جدول ۵ ارائه شده است.

$$\int_{-\infty}^{+\infty} \varphi(t) dt = 0 \quad (6)$$

در رابطه ۶، $\varphi(t)$ تابع تبدیل موج (موجک مادر) است. عبارت مادر به این دلیل به کار رفته است که توابع (موجک‌های) متفاوت به وجود آمده بر اساس پارامترهای 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 هستند [۲۰]. بعد از تعیین نوع موجک مادر، مهم‌ترین اقدام تعیین سطح تجزیه بود. استفاده از بیشترین سطح تجزیه موجب گندشدن فرایند آموزش و در برخی موارد می‌تواند موجب کاهش دقت مدل نیز شود. برای انتخاب سطح تجزیه تبدیل موجک گسسته، از رابطه ۳ استفاده شد [۱۹]. در این رابطه، L سطح تجزیه، N تعداد داده‌های سری زمانی و Int تابع جزء صحیح است. در تحقیق حاضر از موجک‌های خانواده دابچیز^۱ با سطح تجزیه ۳ استفاده شد. در نهایت، داده‌های تجزیه توسط موجک پس از نرمال‌سازی (با استفاده از رابطه ۸) به عنوان ورودی شبکه عصبی تعریف شد.

$$L = \text{Int}[\log(N)] \quad (7)$$

برنامه‌ریزی بیان ژن (GEP)

برنامه‌ریزی بیان ژن تعمیم یافته الگوریتم ژنتیک است که برای اولین بار بر اساس تئوری داروین توسط فریرا در سال ۱۹۹۹ ارائه شد [۲۱]. اولین مرحله در الگوریتم GEP، تولید جمعیت اولیه از راه حل‌هاست. این موضوع می‌تواند به وسیله فرایند تصادفی و یا با استفاده از مقداری اطلاعات درباره مسئله انجام شود. سپس کروموزوم‌ها به صورت بیان درختی

جدول ۵. مقادیر پارامترهای استفاده شده در روش برنامه‌ریزی بیان ژن

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

نرمال سازی داده ها

گام مهم قبل از وارد کردن داده ها به مدل، نرمال سازی داده ها است. این عمل به خصوص وقتی دامنه تغییرات ورودی ها زیاد باشد کمک شایانی به آموزش بهتر و سریع تر مدل می کند. اصولاً وارد کردن داده ها به صورت خام موجب کاهش سرعت و دقت شبکه می شود [۲۳]. برای نرمال سازی داده های تحقیق حاضر از رابطه ۸ استفاده شد. در این رابطه، X_n مقدار نرمال شده ورودی X_i ، X_{max} و X_{min} به ترتیب مقادیر بیشترین و کمترین داده ها است.

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (8)$$

یافته ها

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 شد. بهترین مقدار برای معیارهای یادشده به ترتیب یک، صفر و یک است.

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

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

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

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

ارزیابی مدل بر اساس شاخص های آماری

در جدول های ۶ تا ۹ شاخص های آماری عملکرد مدل های استفاده شده 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 یادشده، برای مدل برنامه ریزی بیان ژن، الگوی ۴، برای مدل هیبرید موجک- عصبی الگوی ۵ و برای مدل های کمترین مربعات ماشین بردار پشتیبان و شبکه های عصبی مصنوعی الگوی ۶ به طور نسبی بهترین عملکرد را به همراه داشت. بنابراین، جریان رودخانه خیاوچای در حالت کلی متأثر از مقدار آن در روز قبل و میزان بارش همان روز است. همچنین استفاده از مقادیر بارش در گام های زمانی پیشین نیز تا حدودی بهبود نتایج مدل ها در تخمین جریان رودخانه به همراه داشت. 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 بیان می کند که در حوضه آبریز خیاوچای صرفاً با استفاده از مقادیر بارش به تنهایی نمی توان برآورد صحیحی از جریان رودخانه داشت. در تحقیقات مشابه سایر محققان در خصوص پیش بینی 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 جایاواردنا و همکارانش [۴]، نورانی و همکارانش [۶] و قربانی و همکارانش [۱۳] اشاره کرد. مقایسه نتایج مدل های مختلف به ازای بهترین الگو بیان می کند که مدل هیبرید موجک- عصبی با بیشترین ضریب همبستگی ($R=0.877$)، کمترین ریشه میانگین مربعات خطا ($RMSE=0.696$) و همچنین ضریب نش ساتکلیف برابر 0.767 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 یادشده به مقادیر مطلوب نزدیک تر است. این در حالی است که عملکرد سایر مدل ها تقریباً مشابه یکدیگر است. با مقایسه مقادیر RMSE مدل ها به ازای بهترین الگو در مرحله صحت سنجی می توان دریافت که میزان کاهش خطای یادشده در مدل WNN نسبت به مدل های ANN، GEP و LS-SVM به ترتیب ۲۶، ۲۷ و ۲۹ درصد بوده است.

جدول ۶. مقادیر شاخص‌های آماری عملکرد مدل کمترین مربعات ماشین بردار پشتیبان برای الگوهای مختلف در مراحل آموزش و صحت‌سنجی

الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف
۱	۰/۰۴۶	۰/۶۹۲	۰/۰۰۲	۰/۰۳۱	۱/۴۴۳	۰
۲	۰/۰۶۴	۰/۶۹۲	۰/۰۰۴	۰/۰۴۶	۱/۴۴۲	۰/۰۰۱
۳	۰/۰۷۶	۰/۶۹۱	۰/۰۰۵	۰/۰۶۰	۱/۴۴۱	۰/۰۰۳
۴	۰/۹۰۸	۰/۲۸۹	۰/۸۲۵	۰/۷۵۰	۰/۹۸۰	۰/۵۴۰
۵	۰/۹۰۸	۰/۲۸۹	۰/۸۲۵	۰/۷۵۲	۰/۹۸۱	۰/۵۴۰
۶	۰/۹۰۸	۰/۲۸۹	۰/۸۲۵	۰/۷۵۴	۰/۹۷۹	۰/۵۴۲

جدول ۷. مقادیر شاخص‌های آماری عملکرد مدل شبکه‌های عصبی مصنوعی برای الگوهای مختلف در مراحل آموزش و صحت‌سنجی

الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف
۱	۰/۰۳۱	۰/۶۹۴	۰	۰/۰۴۱	۱/۴۴۳	۰/۰۰۱
۲	۰/۰۶۷	۰/۶۹۲	۰/۰۰۳	۰/۰۶۴	۱/۴۴۱	۰/۰۰۴
۳	۰/۰۳۴	۰/۶۹۳	۰	۰/۰۱۴	۱/۴۴۴	۰
۴	۰/۹۰۷	۰/۲۹۳	۰/۸۲۱	۰/۶۶۰	۱/۱۱۱	۰/۴۱۶
۵	۰/۹۱۰	۰/۲۸۷	۰/۸۲۸	۰/۶۱۷	۱/۱۶۱	۰/۳۶۷
۶	۰/۹۰۹	۰/۲۸۸	۰/۸۲۷	۰/۸۳۰	۰/۹۵۲	۰/۵۷۳

جدول ۸. مقادیر شاخص‌های آماری عملکرد مدل هیبرید موجک-عصبی برای الگوهای مختلف در مراحل آموزش و صحت‌سنجی

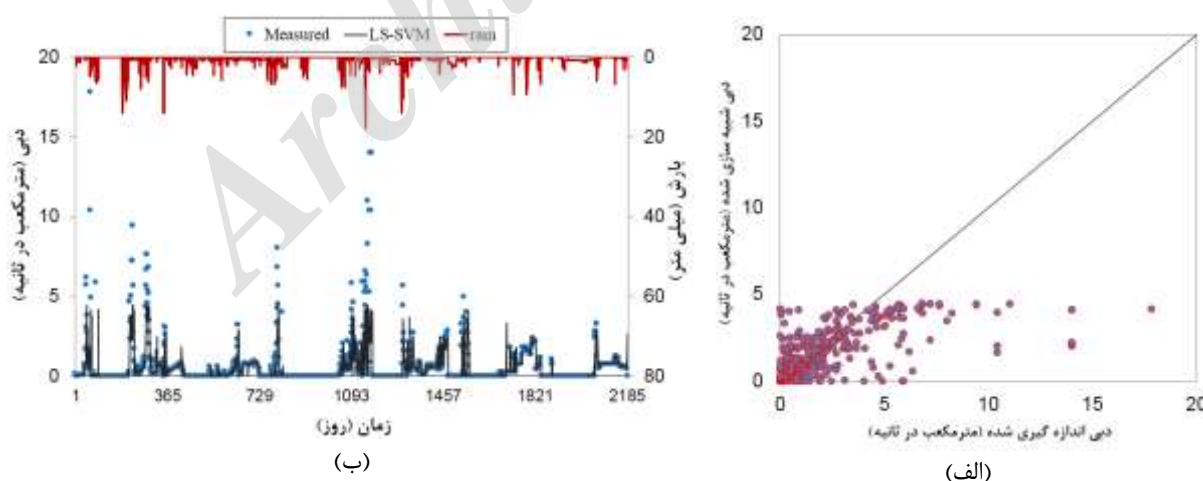
الگو	آموزش			صحت‌سنجی		
	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف	ضریب همبستگی	ریشه میانگین مربعات خطا (m^3/s)	نش-ساتکلیف
۱	۰/۱۳۱	۰/۶۸۵	۰/۰۱۷	۰/۰۸۵	۱/۴۳۸	۰/۰۰۶
۲	۰/۰۲۸	۰/۶۹۴	-۰/۰۰۱	۰/۰۷۰	۱/۴۴۱	۰/۰۰۳
۳	۰/۰۸۱	۰/۶۹۴	۰/۰۰۴	۰/۰۳۷	۱/۴۴۵	۰
۴	۰/۹۶۹	۰/۱۶۹	۰/۹۴۰	۰/۸۶۵	۰/۷۳۶	۰/۷۴۱
۵	۰/۹۶۴	۰/۱۸۲	۰/۹۳۱	۰/۸۷۷	۰/۶۹۶	۰/۷۶۷
۶	۰/۹۲۵	۰/۲۹۵	۰/۸۳۰	۰/۸۶۷	۰/۷۵۷	۰/۷۲۶

جدول ۹. مقادیر شاخص های آماری عملکرد مدل برنامه ریزی بیان ژن برای الگوهای مختلف در مراحل آموزش و صحت سنجی

الگو	آموزش			صحت سنجی		
	ضریب همبستگی	ریشه میانگین مربعات خطا (m ³ /s)	نش- ساتکلیف	ضریب همبستگی	ریشه میانگین مربعات خطا (m ³ /s)	نش- ساتکلیف
۱	۰/۰۳۲	۰/۶۹۳	۰	۰/۰۳۳	۱/۴۴۳	۰
۲	۰/۰۵۵	۰/۶۹۲	۰/۰۰۳	۰/۰۵۲	۱/۴۴۲	۰/۰۰۲
۳	۰/۰۳۰	۰/۹۱۶	۰	۰/۰۵۳	۱/۴۴۳	۰/۰۰۱
۴	۰/۹۰۳	۰/۲۹۷	۰/۸۱۵	۰/۷۹۱	۰/۹۳۶	۰/۵۸۱
۵	۰/۹۰۵	۰/۲۹۵	۰/۸۱۸	۰/۸۱۸	۱/۰۵۲	۰/۶۵۷
۶	۰/۹۰۹	۰/۲۸۸	۰/۸۲۶	۰/۷۵۹	۰/۹۶۷	۰/۵۵۲

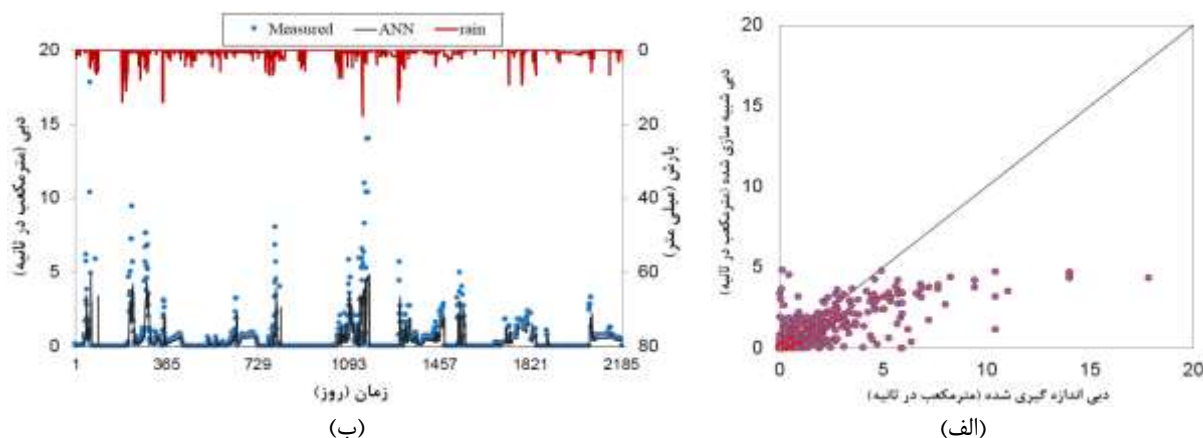
می دهد در مدل WNN هم پوشانی بهتری بین مقادیر مشاهداتی و پیش بینی شده وجود دارد. همچنین ضعف مدل ها در محاسبه مقادیر دبی بیشینه کاملاً نمایان است. با وجود این، دقت مدل WNN در این خصوص نیز نسبت به سایر مدل ها بیشتر و تخمین بهتری از مقادیر پیک به همراه داشته است. البته شایان یادآوری است که اغلب مدل های هوشمند در درون یابی مقادیر در مقایسه با برون یابی، توانایی بیشتری دارند و بنابراین عملکرد آنها در پیش بینی مقادیر میانگین بهتر از مقادیر حدی (بیشینه و کمینه) است.

ارزیابی مدل ها بر اساس نمودارهای پراکنش و سری زمانی در شکل های ۲ تا ۵ نمودارهای پراکنش حول خط یک به یک ($y=x$) و سری زمانی مدل های استفاده شده در تحقیق حاضر برای مرحله صحت سنجی و به ازای بهترین الگو نمایش داده شده است. همان طور که ملاحظه می شود در مدل WNN پراکنش مناسب تری حول محور یک به یک دیده می شود که نشان دهنده همبستگی بیشتر بین مقادیر مشاهداتی و پیش بینی شده توسط مدل یاد شده است. در سایر مدل ها و به خصوص به ازای مقادیر بیشینه، حالت کم برآورد دیده می شود. نمودارهای سری زمانی نیز نشان

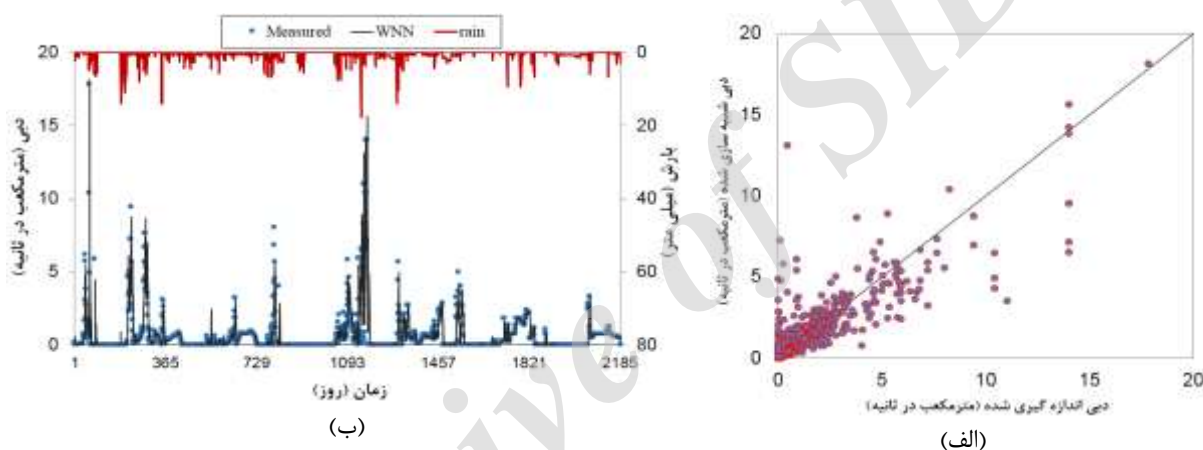


شکل ۲. نمودارهای به دست آمده از مدل کمترین مربعات ماشین بردار پشتیبان به ازای بهترین الگو در مرحله صحت سنجی

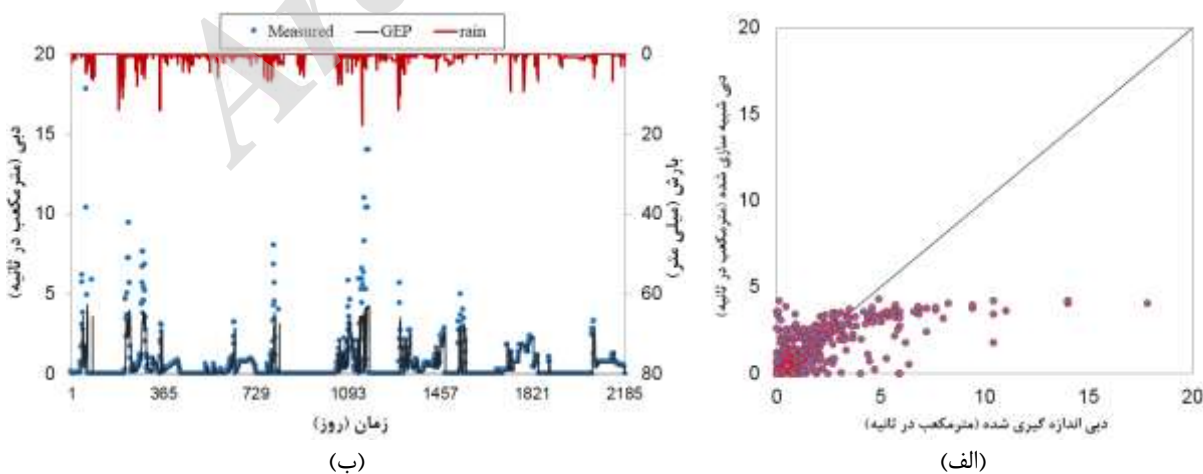
(الف) پراکنش حول محور یک به یک؛ (ب) سری زمانی مقادیر مشاهداتی و پیش بینی شده



شکل ۳. نمودارهای به دست آمده از مدل شبکه‌های عصبی مصنوعی به‌ازای بهترین الگو در مرحله صحت‌سنجی
 الف) پراکنش حول محور یک به یک؛ ب) سری زمانی مقادیر مشاهداتی و پیش‌بینی شده



شکل ۴. نمودارهای به دست آمده از مدل هیبرید موجک-عصبی به‌ازای بهترین الگو در مرحله صحت‌سنجی
 الف) پراکنش حول محور یک به یک؛ ب) سری زمانی مقادیر مشاهداتی و پیش‌بینی شده



شکل ۵. نمودارهای به دست آمده از مدل برنامه‌ریزی بیان ژن به‌ازای بهترین الگو در مرحله صحت‌سنجی
 الف) پراکنش حول محور یک به یک؛ ب) سری زمانی مقادیر مشاهداتی و پیش‌بینی شده

ارزیابی مدل ها بر اساس آزمون ANOVA

در جدول ۱۰، نتایج آزمون ANOVA برای بررسی عملکرد و توانایی مدل های هوشمند استفاده شده با سری داده های مشاهداتی متناظر با آنها ارائه شده است. با توجه به جدول یادشده می توان دید که مدل شبکه های عصبی دارای بیشترین مقدار آماره F و کمترین سطح معناداری است. همچنین مدل ترکیبی موجک- عصبی دارای کمترین مقدار برای آماره F و بیشترین مقدار برای سطح معناداری است. با توجه به نتایج به دست آمده، می توان گفت که مدل های ترکیبی موجک- عصبی و شبکه های عصبی به ترتیب بهترین و ضعیف ترین عملکرد را در بین مدل ها داشته اند. همچنین نتایج به دست آمده نشان می دهند عملکرد مدل های کمترین مربعات ماشین بردار پشتیبان و برنامه ریزی بیان ژن تقریباً به یکدیگر نزدیک است و تفاوت معناداری بین عملکرد این دو مدل وجود ندارد.

ارزیابی مدل ها در پیش بینی دبی بیشینه (سیلاب) 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 ۱۱ ارائه شده است. شایان یادآوری است که برای محاسبه خطای نسبی از رابطه ۱۲ استفاده شد. در رابطه یادشده، RE معرف خطای نسبی، Q_o و Q_c به ترتیب مقادیر دبی بیشینه مشاهداتی و پیش بینی شده است.

$$RE(\%) = \left| \frac{Q_o - Q_c}{Q_o} \right| \times 100 \quad (12)$$

تخمین دبی بیشینه جریان (دبی سیلاب) در بازه های پایین دست رودخانه، به منظور مدیریت و کنترل سیلاب بسیار اهمیت دارد. با توجه به نتایج جدول ۱۱ مشاهده می شود که کمترین خطا در تخمین دبی بیشینه مربوط به مدل هیبرید موجک- عصبی و به مقدار ۳۰/۱۹ درصد است. مدل های ANN، GEP و LS-SVM نیز به ترتیب در رتبه های بعدی قرار دارند.

جدول ۱۰. نتایج آماره F (ANOVA) برای مدل های مختلف به ازای سری داده های دوره صحت سنجی

مدل	آماره F	مقادیر سطح معناداری
ANN	۳۴/۸۷	۰/۰۰۰
LS-SVM	۸/۳۲	۰/۰۰۴
GEP	۹/۵۳	۰/۰۰۲
WNN	۰/۱۱	۰/۷۵۰

جدول ۱۱. کارایی مدل های مطالعه شده در پیش بینی دبی بیشینه جریان

خطای نسبی (درصد)				مقادیر پیش بینی شده (m^3/s)				مقادیر دبی بیشینه مشاهداتی (m^3/s)
WNN	ANN	GEP	LS-SVM	WNN	ANN	GEP	LS-SVM	
۱/۸۱۱	۷۵/۶۱۰	۷۷/۳۴۰	۷۶/۷۱۱	۱۸/۱۲۲	۴/۳۴۱	۴/۰۵۱	۴/۱۴۵	۱۷/۸
۱/۰۲۰	۶۸/۹۴۴	۷۱/۰۶۳	۸۵/۲۸۵	۱۳/۸۵۷	۴/۳۴۷	۴/۰۵۱	۲/۰۶۰	۱۴/۰
۱/۶۷۳	۶۶/۵۱۲	۶۹/۸۴۱	۸۴/۵۹۸	۱۴/۲۳۴	۴/۶۸۸	۴/۲۲۲	۲/۱۵۶	۱۴/۰
۳۱/۸۴۰	۶۶/۴۰۹	۶۹/۸۴۱	۸۴/۴۵۸	۹/۵۴۲	۴/۷۰۲	۴/۲۲۲	۲/۱۷۵	۱۴/۰
۴۸/۶۹۴	۶۷/۰۷۱	۶۹/۸۴۱	۸۴/۰۷۲	۷/۱۸۲	۴/۶۱۰	۴/۲۲۲	۲/۲۲۹	۱۴/۰
۵۳/۳۷۴	۶۶/۸۷۵	۶۹/۸۴۱	۸۴/۰۴۴	۶/۵۲۷	۴/۶۳۷	۴/۲۲۲	۲/۲۳۳	۱۴/۰
۶۷/۷۶۶	۶۸/۰۰۹	۶۶/۸۰۸	۵۹/۷۰۰	۳/۵۴۵	۴/۵۱۸	۳/۶۵۱	۴/۴۳۲	۱۱/۰
۵۸/۴۴۶	۸۸/۵۷۹	۸۲/۹۵۹	۸۳/۹۳۷	۴/۳۲۱	۱/۱۸۷	۱/۷۷۲	۱/۶۷۰	۱۰/۴
۷/۰۷۴	۵۹/۸۲۹	۵۹/۹۲۸	۵۳/۱۸۴	۸/۷۴۴	۳/۷۸۰	۳/۷۷۰	۴/۴۰۵	۹/۴۱
۳۰/۱۹	۶۹/۷۶	۷۰/۸۲	۷۷/۳۳	میانگین قدرمطلق خطا (درصد)				

Modeling and Simulation Society of Australia and New Zealand. 2005: 1841-1847.

- [5]. Aytek A, Alp M. An application of artificial intelligence for rainfall-runoff modeling. *Journal of Earth System Science*. 2008;117(2):145-155.
- [6]. Nourani V, Baghanam AH, Adamowski J, Gebremichael M. Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling. *Journal of Hydrology*. 2013;476:228-243.
- [7]. Nayak PC, Venkatesh B, Krishna B, Sharad KJ. Rainfall-runoff modeling using conceptual, data driven, and wavelet based computing approach. *Journal of Hydrology*. 2013;493:57-67.
- [8]. Badrzadeh H, Sarukkalige R, Jayawardena AW. Hourly runoff forecasting for flood risk management: Application of various computational intelligence models. *Journal of Hydrolog*. 2015;529:1633-1643.
- [9]. Nourani V. An Emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology*. 2016;544:267-277.
- [10]. Behzad M, Asghari K, Eazi M, Palhang M. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with applications*. 2009;36(4):7624-7629.
- [11]. Botsis D, Latinopoulos P, Diamantaras K. Rainfall-Runoff Moeling Using Suport Vector Regression and Artificial Neural Networks. 12th International Conference on Environmental Science and Technology (CEST2011), Rhodes, Greece, 8-10 September. 2011
- [12]. Adamowski J. Using support vector regression to predict direct runoff, base flow and total flow in a mountainous watershed whit limited data in Uttaranchal, India. *Journal of Land Reclamation*. 2013;45(1):71-83.
- [13]. Ghorbani M. A., and Dehghani R. Application of Bayesian Neural Networks, Support Vector Machines and Gene Expression Programming Analysis of Rainfall - Runoff Monthly (Case Study: Kakarza River). *Irrigation Science and Engineering*. 2016;39(2):125-138. [Persian]
- [14]. Nazeri Tahroodi M, Hashemi R, Ahmadi F, Nazeri Tahroodi Z. Accuracy investigation of ANFIS, SVM and GP models in modelling of river discharge values. *Journal of Echo Hydrology*. 2016;3(3):361-347. [Persian]
- [15]. Vapnic VN. *Statistical Learning Theory*. Wiley, NEW YORK, USA. 1998

نتیجه‌گیری

در تحقیق حاضر کارایی مدل‌های ANN، LS-SVM و WNN و GEP در تخمین جریان روزانه رودخانه خیاوچای بررسی شد. بدین‌منظور حجم وسیعی از مقادیر دبی و بارش روزانه مشاهداتی طی دوره آماری ۱۵ ساله، در ایستگاه‌های هیدرومتری پل سلطانی واقع بر رودخانه یادشده استفاده شد. به‌منظور پیش‌بینی جریان رودخانه شش الگوی متفاوت تعریف شد. در کلیه مدل‌ها با ترکیب بارش و دبی دقت تخمین جریان روزانه بهبود یافت. بیشترین دقت مدل‌ها در ترکیب ورودی رواناب با یک تأخیر زمانی و بارش‌های روزانه و پیشین فراهم شد. با مقایسه عملکرد مدل‌های استفاده‌شده در تحقیق حاضر بر اساس شاخص‌های آماری و آزمون ANOVA، می‌توان مدل WNN را به‌عنوان ابزاری کارآمد و با دقت قابل قبول برای پیش‌بینی جریان روزانه خیاوچای معرفی کرد. کارایی مدل‌های مختلف در پیش‌بینی دبی بیشینه نیز بررسی شد. نتایج نشان می‌داد عملکرد مدل‌ها در این خصوص ضعیف است و در عین حال مدل WNN در تخمین مقادیر پیک جریان در مقایسه با سایر مدل‌ها به‌مراتب عملکرد بهتری را به‌همراه داشت. در مجموع با توجه به نتایج قابل قبول مدل‌های استفاده‌شده در تحقیق حاضر، ضرایب و توابع به‌کاررفته برای واسنجی آنها می‌تواند برای تخمین جریان حوضه آبریز خیاوچای بسیار مفید باشد.

منابع

- [1]. Saeedi Farzad B. Intelligent simulation of rainfall-runoff using a semi-distributed model with time variables. Ph.D. thesis in civil engineering, Faculty of Engineering, University of Tabriz, Tabriz. 2014. [Persian]
- [2]. Whigham PA, Crapper PF. Modeling rainfall-runoff using genetic programming. *Mathematical and Computer Modeling*. 2001;33:707-721.
- [3]. Liong SY, Gautam TR, Khu ST, Babovic V, Keijzer M, Muttill N. Genetic programming: A new paradigm in rainfall runoff modeling. *J Am Water Res Assoc*. 2001;38:705-718.
- [4]. Jayawardena AW, Muttill N, Fernando TM. Rainfall-Runoff Modeling Using Genetic Programming. International Congress on

- [16]. Suykens JA, De Brabanter J, Lukas L, Vandewalle J. 2002. Weighted least squares support vector machines: robustness and sparse approximation. *Neurocomputing*. 2002;48(1):85-105.
- [17]. Ghafari G, Vafakhah M. Simulation of rainfall-runoff process using artificial neural network and adaptive neuro-fuzzy interface system (Case study: Hajighoshan watershed). *Journal of Watershed Management Research*. 2013;4(8):120-136. [Persian]
- [18]. Dehghani A, Zanganeh MA, Mosaedi A, Kouhestani N. Comparison of suspended load estimation using sediment rating curve and artificial neural networks. *Journal of Researches on Water and Soil Conservation*. 2009;16(1):30-41. [Persian]
- [19]. Nourani V, Hosseini Baghanam A, Adamowski J, Kisi, O. Applications of hybrid wavelet-Artificial Intelligence models in hydrology. A review. *Journal of Hydrology*. 2014;514(1):358-377.
- [20]. Marofi S, Amir Moradi K, Parsafar N. River flow prediction using Artificial Neural Network and Wavelet Neural Network models (Case study: Barandozchay River). *Journal of Water and Soil Science*. 2013;23(3):93-103. [Persian]
- [21]. Ferreira C. Gene Expression Programming: a New Adaptive Algorithm for Solving Problems. *Complex Systems*. 2001;13(2):87-129.
- [22]. Ferreira C. Automatically defined functions in gene expression programming. In *Genetic Systems Programming*. Springer Berlin Heidelberg. 2006:21-56.
- [23]. Yu P. S., Chen S. T., and Chang I. F. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*. 2006;328(3):704-716.

Archive of SID