

## مقایسه کارآیی مدل‌های هوشمند در روندیابی جریان روزانه رودخانه (مطالعه موردی: رودخانه بالخلوچای، استان اردبیل)

محمد رضا نیک‌پور\*؛ سجاد محمودی بابلان<sup>۲</sup>

تاریخ ارسال: ۱۳۹۶/۰۳/۱۷

تاریخ پذیرش: ۱۳۹۶/۱۰/۱۰

### چکیده

روندیابی جریان در رودخانه‌ها یکی از پراهمیت‌ترین موضوعات در مدیریت منابع آب‌های سطحی جهت اتخاذ تدابیر مناسب در مواقع سیلاب و بروز خشک‌سالی‌ها است. در این تحقیق از مدل‌های شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن، موجک-عصبی و حداقل مربعات ماشین بردار پشتیبان به منظور روندیابی جریان روزانه رودخانه بالخلوچای واقع در حوضه آبریز دره‌رود استفاده شد. در این راستا داده‌های روزانه دو ایستگاه هیدرومتری متوالی واقع بر رودخانه مذکور به کار گرفته شد. برای ارزیابی مدل‌ها از شاخص‌های آماری ریشه میانگین مربعات خطا، ضریب همبستگی، ضریب نش-ساتکلیف و بایاس استفاده شد. نتایج گویای عملکرد قابل قبول هر چهار مدل و برتری مدل حداقل مربعات ماشین بردار پشتیبان با بیشترین ضریب همبستگی ( $R=0/894$ )، کمترین ریشه میانگین مربعات خطا ( $RMSE=1/540 \text{ m}^3/\text{s}$ ) و ضرایب نش-ساتکلیف و بایاس برابر  $0/813$  و  $0/013$  در مرحله صحت‌سنجی بود. اما در برآورد دبی بیشینه (سیلاب) مدل موجک-عصبی با میانگین خطای نسبی  $34/21$  درصد، از خطای کمتری نسبت به سایر مدل‌ها برخوردار بود. لازم به ذکر است که کلیه مدل‌ها در تخمین جریان ایستگاه پایین دست حالت کم‌برآورد داشتند.

واژه‌های کلیدی: برنامه‌ریزی بیان ژن، حداقل مربعات ماشین بردار پشتیبان، روندیابی جریان، شبکه عصبی مصنوعی، موجک-عصبی.

<sup>۱</sup> استادیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران. ۰۹۱۳۲۲۲۰۴۸۵  
(نویسنده مسئول) [m\\_nikpour@uma.ac.ir](mailto:m_nikpour@uma.ac.ir)

<sup>۲</sup> دانش‌آموخته کارشناسی، گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران. ۰۹۳۶۱۸۱۴۵۲۱  
[sajadmahmodib@gmail.com](mailto:sajadmahmodib@gmail.com)

## مقدمه

پیش‌بینی مؤلفه‌های مؤثر در تحلیل سامانه‌های منابع آب از جمله جریان رودخانه یکی از موارد اساسی در طراحی، بهره‌برداری و مطالعات مربوط به این منابع به شمار می‌آید. پیش‌بینی جریان رودخانه یکی از مطرح‌ترین چالش‌ها در مدیریت منابع آب در سال‌های اخیر بوده به طوری که پژوهش‌گران راه‌کارهای مختلفی را برای این امر ارائه نموده‌اند که شامل روش‌های رگرسیونی، مدل‌های آماری و پیچیده‌تر بر پایه شبکه عصبی مصنوعی<sup>۱</sup> (ANN)، برنامه‌ریزی بیان ژن<sup>۲</sup> (GEP)، و به‌تازگی موجک-عصبی<sup>۳</sup> (WNN) و ماشین بردار پشتیبان<sup>۴</sup> (SVM) می‌شود. تاکنون تحقیقات متعددی در خصوص استفاده از مدل‌های هوشمند برای تخمین جریان (رواناب) روزانه و ماهانه رودخانه‌ها و همچنین روندیابی سیلاب صورت پذیرفته است.

و همچنین روندیابی سیلاب صورت پذیرفته است. Yu et al. (2006) در مطالعه‌ای با استفاده از مدل SVM به پیش‌بینی سطح رقومی سیل در رودخانه لن-یانگ تایوان پرداختند. نتایج نشان داد که مدل به‌خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند. Kisi (2008) عملکرد مدل ترکیبی WNN را با سیستم استنتاجی فازی-عصبی تطبیقی<sup>۵</sup> (ANFIS) در مدل کردن جریان ماهانه مقایسه و بر اساس نتایج تحقیق، مدل WNN را برای این منظور پیشنهاد نمود. Sivapragasam et al. (2008) با به‌کارگیری مدل برنامه‌ریزی ژنتیک<sup>۶</sup> (GP) به روندیابی هیدرولوژیکی سیلاب رودخانه والاوالا واقع در ایالات متحده پرداختند و دبی‌های ورودی گام زمانی قبلی و فعلی و دبی خروجی گام زمانی فعلی را به عنوان ورودی مدل اعمال کردند. نتایج بدست آمده دقت قابل قبول GP را در روندیابی سیلاب گزارش داد. 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 پیش‌بینی نمودند. نتایج نشان داد که SVM از عملکرد بهتری نسبت به ANN برخوردار است. Ghorbani et al. (2010) عملکرد سه مدل ANN، ANFIS و GP را در روندیابی سیلاب رودخانه قزل ایرماق ترکیه مورد ارزیابی قرار دادند. نتایج مطالعه آنها نشان داد از بین سه روش مذکور مدل GP با دقت بیشتری هیدروگراف خروجی را شبیه‌سازی می‌کند. Taheri and Ghafouri (2012) رواناب روزانه یکی از ایستگاه‌های رودخانه کارون را با به‌کارگیری داده‌های بارش، رطوبت و دما مدل‌سازی نمودند. در تحقیق مذکور مدل SVM نتیجه بهتری را نسبت به روش یادگیری فعال<sup>۷</sup> به همراه داشت. He et al. (2014) با استفاده از مدل‌های ANN، ANFIS و SVM جریان رودخانه پابلوگو واقع در منطقه کوهستانی شمال غربی چین را مورد مطالعه قرار دادند. در تحقیق مذکور بر اساس مقادیر دبی روزانه، سه الگو با تأخیرهای یک و دو گام زمانی تعریف شد. مقایسه عملکرد مدل‌ها حاکی از برتری محسوس مدل SVM بود. Tiwari (2015) جریان حوضه آبریز لیمخدا واقع در هندوستان را با استفاده از مقادیر دبی روزانه، شبیه‌سازی نمود. نتایج حاصل از این مطالعه نشان از برتری مدل WNN در مقایسه با مدل‌های ANN و رگرسیون خطی چندگانه<sup>۸</sup> (MLR) داشت. Shafaei and Kisi (2016) برای شبیه‌سازی جریان رودخانه آجی‌چای واقع در شمال غرب ایران، از مقادیر دبی روزانه ایستگاه نیار با دوره آماری ۳۴ ساله استفاده کردند. برای تخمین دبی، چهار الگو با تأخیرهای یک، دو و سه گام زمانی تعریف شد. در نهایت به‌ازای تمامی الگوها و همچنین در برآورد دبی پیشینه، مدل WNN در مقایسه با مدل‌های ANN و SVM عملکرد بهتری به همراه داشت. Ghorbani et al. (2016) عملکرد مدل‌های ANN و SVM را در مقایسه با مدل‌های متعارف منحنی سنجه دبی و MLR برای تخمین دبی رودخانه سیپرس واقع در

<sup>۷</sup>Active Learning Method

<sup>۸</sup>Multiple linear regression (MLR)

<sup>۱</sup>Artificial Neural Network (ANN)

<sup>۲</sup>Gene Expression Programming (GEP)

<sup>۳</sup>Wavelet-ANN (WNN)

<sup>۴</sup>Support Vector Machine (SVM)

<sup>۵</sup>Adaptive Neural-Fuzzy Interference System (ANFIS)

<sup>۶</sup>Genetic Programming (GP)

سرعت بالا و مدل WNN به جهت استفاده از نویزدایی در ساختار داده‌ها، برای روندیابی جریان روزانه رودخانه مورد ارزیابی قرار گرفت.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبریز دره‌رود با وسعتی برابر ۱۴۳۱۰ کیلومتر مربع بخش قابل توجهی از استان اردبیل را تحت پوشش قرار می‌دهد. ۶۸ درصد وسعت حوضه در استان اردبیل و ۳۲ درصد آن در استان آذربایجان شرقی است. بالخلوچای یکی از رودخانه‌های مهم حوضه آبریز مذکور می‌باشد. برای انجام روندیابی جریان روزانه رودخانه از داده‌های آماری مربوط به دو ایستگاه پل الماس (بالادست) و گیلانده (پایین‌دست) واقع در رودخانه مذکور طی دوره آماری ۱۷ ساله از سال ۱۳۷۵ تا سال ۱۳۹۲ استفاده گردید. ایستگاه پل الماس در ۱۲'۴۸ طول جغرافیایی، ۱۰'۳۸ عرض جغرافیایی، در ارتفاع ۱۴۳۰ متری از سطح دریا و ایستگاه گیلانده در ۱۹'۴۸ طول جغرافیایی، ۲۲'۳۸ عرض جغرافیایی، در ارتفاع ۱۱۹۰ متری از سطح دریا واقع شده است. لازم به ذکر است فاصله دو ایستگاه، ۱۴/۶۸ کیلومتر می‌باشد. شکل ۱ محدوده و موقعیت کلی منطقه مورد مطالعه را نشان می‌دهد.

### روش پژوهش

تعداد کل نمونه‌ها در طول دوره آمار برداری از سال ۷۶-۱۳۷۵ لغایت ۹۲-۱۳۹۱ معادل ۶۱۷۵ داده می‌باشد که از سازمان آب منطقه‌ای استان اردبیل اخذ شد. ۷۰ درصد داده‌های مذکور (۴۳۲۰ داده) به‌عنوان داده‌های آموزش<sup>۱</sup> و ۳۰ درصد داده‌ها (۱۸۵۵ داده) به‌عنوان داده‌های صحت‌سنجی<sup>۲</sup> در نظر گرفته شد. در جدول ۱ پارامترهای آماری مربوط به داده‌های اندازه‌گیری شده در بازه زمانی مذکور نشان داده شده است.

ایلات متحده آمریکا، مورد بررسی قرار دادند. در تحقیق مذکور، ۱۰ الگوی ترکیبی بر اساس مقادیر دبی و اشل رودخانه با گام‌های زمانی متفاوت تعریف شد که به‌ازای کلیه الگوها، مدل‌های SVM و ANN نتایج بهتری را نسبت به دو مدل دیگر به همراه داشتند (Ahani et al. (2017) برای پیش‌بینی رواناب ماهانه حوضه دریاچه نمک، داده‌های ماهانه دما، بارش و دبی ایستگاه سراب هندی را مورد استفاده قرار دادند. نتایج تحقیق مذکور نشان داد که در ساختار الگوهای ورودی، به‌کارگیری داده‌های ماه‌های قبل می‌تواند باعث بهبود نتایج شود. همچنین مدل K-نزدیک‌ترین همسایه (KNN) نسبت به مدل‌های ANN، ANFIS و MLR از خطای کمتری برخوردار بود. قربانی و دهقانی (۱۳۹۵) کارآیی سه مدل شبکه عصبی بیزین<sup>۳</sup> (BNN)، SVM و GEP را در تخمین رواناب ماهانه رودخانه کاکارضا مورد مقایسه قرار دادند. از میان سه مدل مذکور، BNN به‌ازای الگوی ترکیبی بارش و دبی روزهای پیشین، بهترین نتیجه را به همراه داشت.

نظر به اینکه بالخلوچای یکی از رودخانه‌های مهم استان اردبیل و مهم‌ترین منبع تأمین کننده آب بخش‌های مختلف شهر اردبیل و نواحی مجاور آن می‌باشد، پیش‌بینی و روندیابی جریان روزانه این رودخانه (به‌ویژه در مواقع وقوع سیلاب) در راستای بهبود برنامه‌ریزی و اقدامات مدیریتی حائز اهمیت می‌باشد. لذا هدف از تحقیق حاضر ارزیابی مدل‌های هوشمند در روندیابی جریان روزانه بالخلوچای با استفاده از آمار دو ایستگاه هیدرومتری بالادست و پایین‌دست واقع بر رودخانه مذکور می‌باشد. با بررسی منابع انجام شده می‌توان گفت استفاده از روش‌های مدل‌سازی غیرخطی جهت پیش‌بینی مقدار جریان رودخانه ضروری به نظر می‌رسد. لذا در این راستا مدل ANN به‌دلیل سادگی و کارآمدی بالا، مدل GEP به جهت ارائه روابط صریح بین متغیرهای ورودی و خروجی، مدل حداقل مربعات ماشین بردار پشتیبان<sup>۳</sup> (LS-SVM) به جهت کارآیی و

<sup>۱</sup>Training

<sup>۲</sup>Testing

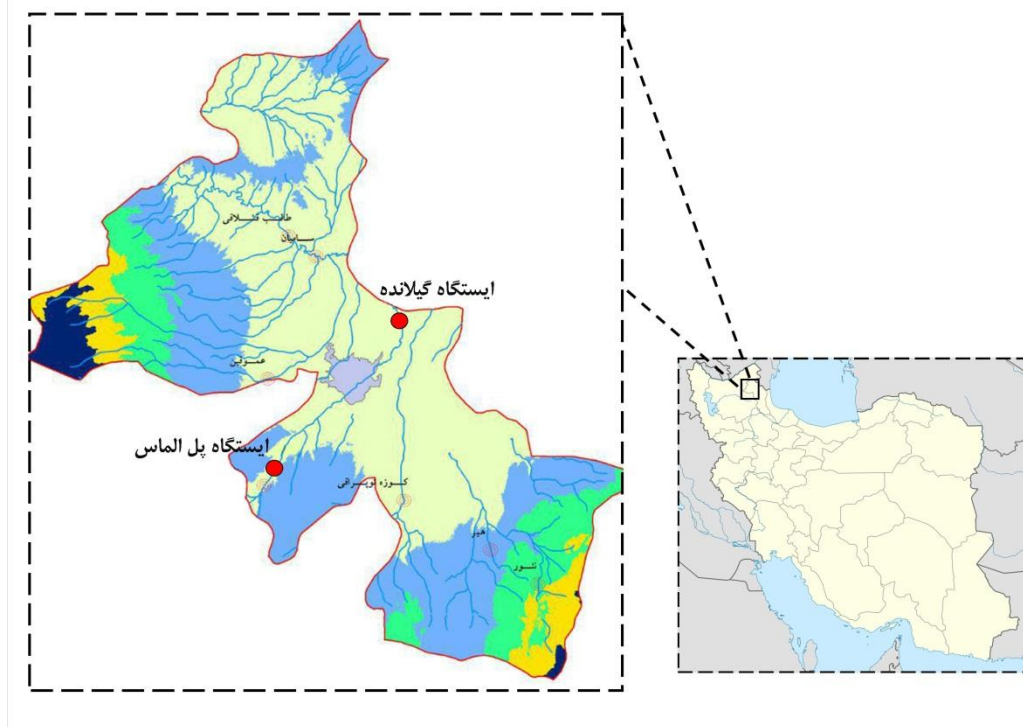
<sup>۱</sup> K-nearest neighbor

<sup>۲</sup> Bayesian Neural Network (BNN)

<sup>۳</sup>Least Square Support Vector Machine (LS-SVM)

و O به ترتیب بیانگر مقادیر اندازه‌گیری شده دبی در ایستگاه‌های بالادست (پل الماس) و پایین‌دست (گیلانده) و اندیس t شاخص گام زمانی فعلی می‌باشد.

ساختار الگوهای مورد استفاده در این تحقیق به منظور دستیابی به مدل بهینه برای روندیابی جریان روزانه به شرح جدول ۲ می‌باشد. در جدول مذکور، متغیرهای I



شکل (۱): موقعیت جغرافیایی منطقه مورد مطالعه

جدول (۱): خصوصیات آماری مقادیر دبی روزانه رودخانه مورد استفاده در بازه زمانی ۹۲-۱۳۷۵

متغیر	واحد	تعداد رکورد	میانگین	حداقل	حداکثر	انحراف معیار	ضریب تغییرات	چولگی
$I_{(t)}$	( $m^3/s$ )	۶۱۷۵	۲/۳۶۳۷	۰	۳۳	۲/۴۰۱۳	۱/۰۱۵۸	۲/۲۴
$O_{(t)}$	( $m^3/s$ )	۶۱۷۵	۱/۳۷۲۵	۰	۳۶/۷	۲/۲۱۳۰	۱/۶۱۲۴	۳/۱۹

جدول (۲): ساختار الگوهای مورد استفاده در تحقیق حاضر

شماره الگو	ساختار ورودی	خروجی
۱	$I_t$	$O_t$
۲	$I_{t-1}, I_t$	$O_t$
۳	$I_{t-2}, I_{t-1}, I_t$	$O_t$

گردید. در ادامه به توضیح مختصر مدل‌های مذکور و ضرایب به کار رفته برای واسنجی مدل‌ها پرداخته می‌شود.

#### 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

## 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 جهت‌های مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر بوده و مانند یک تابع رفتار کند، بنابراین با توجه به رفتارهای موجی نامنظم پدیده‌های هیدرولوژیک، قابلیت مدل‌سازی این پدیده‌ها توسط امواج نامنظم (موجک‌ها) نسبت به امواج منظم (امواج سینوسی) بیشتر است (Nourani et al., 2014). 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 موجک (موجک مادر) است. 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 (معروفی و همکاران، ۱۳۹۲). در تحقیق حاضر از موجک‌های خانواده دابچیز<sup>۲</sup> استفاده گردید. 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. جهت انتخاب سطح تجزیه تبدیل موجک گسسته، رابطه ۳ استفاده شد (Nourani et al., 2014). در این رابطه،  $L$  سطح تجزیه،  $N_s$  تعداد داده‌های سری زمانی و  $\text{int}$  تابع جزء صحیح می‌باشد. در نهایت داده‌های حاصل از

## شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری<sup>۱</sup> و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد (غفاری و وفاخواه، ۱۳۹۲). در شبکه عصبی مصنوعی، هر نرون زمانی فعال می‌شود که که مجموع سیگنال‌های رسیده به آن از حد آستانه مشخصی تجاوز نماید. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسأله مورد بررسی، مشخص می‌شود. حال آنکه تعداد نرون‌های موجود در لایه‌های پنهانی و همچنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا توسط طراح ارائه می‌شود (شفائی و همکاران، ۱۳۹۲). برای نرمال سازی داده‌های تحقیق حاضر از رابطه ۱ استفاده شد. در این رابطه،  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{\max}$  و  $X_{\min}$  به ترتیب مقادیر حداکثر و حداقل داده‌ها می‌باشد. به‌منظور به حداقل رساندن خطای مدل‌سازی پس از انجام تحلیل حساسیت، توابع و مقادیر بهینه در نظر گرفته شده برای شبکه عصبی مورد استفاده در تحقیق حاضر به شرح جدول ۳ می‌باشد.

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

جدول (۳): مقادیر پارامترهای مورد استفاده برای مدل

شبکه عصبی مصنوعی	
پارامتر	بهترین مقدار
نوع شبکه عصبی	Feed-forward back propagation
تعداد لایه پنهان	۲
تعداد نرون	۱۰
نوع گشتاور برای لایه اول	TANSIG
نوع گشتاور برای لایه	PURELIN

نامیده می‌شود) مبین تمامی ژنوم‌های مستقل هستند. به‌طور خلاصه می‌توان گفت در GEP به‌سازی‌ها در یک ساختار خطی اتفاق افتاده و سپس به‌صورت 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 (Ferrira, 2006). 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 مسأله تشکیل شده‌اند (Ferrira, 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  $\sqrt$ ، power، Ln، Exp استفاده گردید. پس از تحلیل حساسیت مدل برنامه-ریزی بیان ژن در تخمین دبی، پارامترهای مورد استفاده و نرخ آنها در جدول ۴ ارائه شده است.

تجزیه توسط موجک پس از نرمال‌سازی (با استفاده از رابطه ۱) به‌عنوان ورودی شبکه عصبی تعریف شد.

$$L = \text{int} \left[ \log(N_s) \right] \quad (3)$$

### برنامه‌ریزی بیان ژن (GEP)

مدل GEP، در سال ۲۰۰۱ توسط فریرا ارائه شد (Ferrira, 2001). این روش ترکیبی از روش‌های برنامه‌ریزی 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 برنامه‌ریزی 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 به‌وسیله GEP استنتاج می‌شوند (که بیان درختی نیز

جدول (۴): مقادیر پارامترهای مورد استفاده در روش برنامه‌ریزی بیان ژن

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

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

### حداقل مربعات ماشین بردار پشتیبان (LS-SVM)

ایده اصلی ماشین بردار پشتیبان (SVM) که به عنوان فرآیندهای رگرسیونی و طبقه‌بندی شناخته می‌شوند، توسط Vapinc (1998) مطرح گردید.

در رابطه فوق  $K(x_i, x_j)$  تابع کرنل نامیده می‌شود که مطابق رابطه ۸، به‌عنوان تابعی با ایجاد ضرب داخلی در فضای ویژگی معرفی می‌شود (رضایی و همکاران، ۱۳۹۳).

$$K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \quad i, j = 1, 2, \dots, N \quad (۸)$$

برای تحلیل حساسیت مدل LS-SVM توابع کرنل خطی<sup>۱</sup>، چندجمله‌ای<sup>۲</sup> و پایه شعاعی<sup>۳</sup> مورد آزمون قرار گرفت که از بین توابع مذکور، کرنل پایه شعاعی از بالاترین سرعت و کمترین خطا برخوردار بود. ضمناً مقادیر پارامترهای تنظیم‌کننده و کرنل پس از انجام فرآیند سعی و خطا و با هدف کمینه کردن خطای مدل، به‌ترتیب برابر ۱۰ و ۰/۴ در نظر گرفته شد.

#### معیارهای ارزیابی مدل

در تحقیق حاضر به‌منظور ارزیابی دقت و کارایی مدل‌ها از نمایه‌های ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE)، ضریب نش-ساتکلیف (NS) و همچنین بایاس (Bias) طبق روابط ۹ تا ۱۲ استفاده گردید. بهترین مقدار برای معیارهای مذکور به ترتیب یک، صفر، یک و صفر می‌باشد. در روابط فوق،  $Q_i^P$  و  $Q_i^O$  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 می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش حول خط یک به یک و سری زمانی مقادیر مشاهداتی و محاسباتی برای مقایسه و تحلیل بیشتر نتایج استفاده شد.

$$R = \frac{\sum_{i=1}^N (Q_i^O - \bar{Q}^O)(Q_i^P - \bar{Q}^P)}{\sqrt{\sum_{i=1}^N (Q_i^O - \bar{Q}^O)^2 \sum_{i=1}^N (Q_i^P - \bar{Q}^P)^2}} \quad (۹)$$

طریق تابع  $y(\bar{x}_i)$  تخمین زده شود. در این روش فرض بر این است که نمونه‌ها به‌صورت 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 به‌شدت 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 به‌طور مؤثری پیچیدگی الگوریتم را کاهش داده و افزایش سرعت محاسبات را نسبت به مدل SVM به دنبال دارد. تابع رگرسیونی مورد استفاده برای تخمین مسائل به‌صورت رابطه ۴ می‌باشد.

$$y(x_i) = w^T \cdot \phi(x_i) + b \quad (۴)$$

که در آن  $\phi(x_i)$  ترسیم غیر خطی ورودی‌ها در فضای ویژگی با ابعاد بالا می‌باشد. پارامترهای  $w$  و  $b$  به‌ترتیب مقادیر وزن‌ها و بایاس تابع رگرسیون هستند که از طریق حداقل سازی تابع هدف در رابطه ۵ تعیین می‌گردد.

$$\min_{w, e, b} j(w, e) = \frac{1}{2} w^T \cdot w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \quad (۵)$$

با محدودیت:

$$y_i = w^T \cdot \phi(x_i) + b + e_i \quad i = 1, 2, \dots, N \quad (۶)$$

که در آن  $\gamma$  پارامتر تنظیم‌کننده بخش خطا و  $e_i$  خطای داده‌های آموزش می‌باشد. در نهایت تابع تخمین مدل LS-SVM به‌صورت رابطه ۷ تعریف می‌شود.

$$y(x) = \sum_{i=1}^N a_i K(x_i, x_j) + b \quad (۷)$$

<sup>۱</sup>Linear

<sup>۲</sup>Polynomial

<sup>۳</sup>Radial Basis Function Kernel

پیشین نیز باعث بهبود نتایج مدل‌ها در تخمین جریان رودخانه می‌شود. مقایسه نتایج مدل‌های مختلف به‌ازای بهترین الگو حاکی از آن است که مدل LS-SVM با بیشترین ضریب همبستگی ( $R=0/894$ )، کمترین ریشه میانگین مربعات خطا ( $RMSE=1/540 \text{ m}^3/\text{s}$ ) و همچنین ضرایب نش-ساتکلیف و بایاس به‌ترتیب برابر  $0/813$  و  $0/013$  در مرحله صحت‌سنجی عملکرد بهتری را نسبت به سایر مدل‌ها در روندیابی جریان رودخانه از خود نشان داده است. علاوه بر آن، شاخص-های آماری مربوط به مرحله آموزش مدل مذکور به مقادیر مطلوب نزدیک‌تر است. این درحالی است که عملکرد سایر مدل‌ها تقریباً مشابه یکدیگر بوده و در عین حال مدل شبکه عصبی از عملکرد ضعیف‌تری برخوردار می‌باشد. همان‌طور که در پیشینه تحقیق نیز اشاره شد، برتری مدل SVM نسبت به سایر مدل‌های هوشمند در تخمین جریان رودخانه در تحقیقات سایر محققان مانند Behzad et al. (2009) و He et al. (2014) نیز مشاهده شده است.

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

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

$$Bias = \frac{1}{N} \sum_{i=1}^N (Q_i^O - Q_i^P) \quad (12)$$

## نتایج و بحث

### ارزیابی مدل‌ها بر اساس شاخص‌های آماری

در جدول‌های ۵ تا ۸ شاخص‌های آماری عملکرد مدل‌های مورد استفاده در تحقیق حاضر برای مراحل آموزش و صحت‌سنجی و به‌ازای الگوهای مختلف گزارش شده است. بر اساس نتایج، الگوی شماره ۳ در کلیه مدل‌ها به‌طور نسبی بهترین عملکرد را به همراه داشت. در تحقیقات مشابه انجام گرفته توسط Behzad et al. (2009)، He et al. (2014) و Tiwari (2015) نیز بهترین نتیجه به‌ازای الگوی تعریف شده بر اساس ترکیب گام‌های زمانی فعلی و پیشین دبی رودخانه حاصل شده است. بنابراین نظر به اینکه جریان رودخانه در گام زمانی فعلی متأثر از مقدار آن در روزهای قبل می‌باشد، استفاده از مقادیر دبی در گام‌های زمانی

جدول (۵): مقادیر شاخص‌های آماری عملکرد مدل ماشین بردار پشتیبان برای الگوهای مختلف در مراحل آموزش و صحت

سنجی								
صحت سنجی				آموزش				
الگو	ضریب همبستگی	ریشه میانگین مربعات خطا ( $\text{m}^3/\text{s}$ )	ضریب همبستگی	بایاس	نش ساتکلیف	ریشه میانگین مربعات خطا ( $\text{m}^3/\text{s}$ )	ضریب همبستگی	الگو
۱	۰/۷۸۰	۱/۲۵۶	۰/۷۵۳	۰/۰۳۸	۰/۸۰۴	۱/۲۵۶	۰/۷۸۰	۱
۲	۰/۸۵۳	۱/۰۳۷	۰/۷۹۰	۰/۰۲۱	۰/۸۳۴	۱/۰۳۷	۰/۸۵۳	۲
۳	۰/۹۱۲	۰/۹۱۵	۰/۸۹۴	۰/۰۰۹	۰/۸۹۹	۰/۹۱۵	۰/۹۱۲	۳

جدول (۶): مقادیر شاخص‌های آماری عملکرد مدل هیبرید عصبی-موجک برای الگوهای مختلف در مراحل آموزش و صحت

سنجی								
صحت سنجی				آموزش				
الگو	ضریب همبستگی	ریشه میانگین مربعات خطا ( $\text{m}^3/\text{s}$ )	ضریب همبستگی	بایاس	نش ساتکلیف	ریشه میانگین مربعات خطا ( $\text{m}^3/\text{s}$ )	ضریب همبستگی	الگو
۱	۰/۶۸۹	۱/۷۳۶	۰/۷۰۹	۰/۰۵۲	۰/۷۱۳	۱/۷۳۶	۰/۶۸۹	۱
۲	۰/۷۸۶	۱/۲۶۰	۰/۷۹۲	۰/۰۴۸	۰/۷۹۷	۱/۲۶۰	۰/۷۸۶	۲
۳	۰/۸۹۰	۰/۹۹۴	۰/۸۵۲	۰/۰۲۷	۰/۸۵۶	۰/۹۹۴	۰/۸۹۰	۳



جدول (۷): مقادیر شاخص‌های آماری عملکرد مدل برنامه‌ریزی بیان ژن برای الگوهای مختلف در مراحل آموزش و صحت‌سنجی

الگو	آموزش				صحت‌سنجی			
	ضریب همبستگی	ریشه میانگین مربعات خطا (m <sup>3</sup> /s)	نش ساتکلیف	بیایاس	ضریب همبستگی	ریشه میانگین مربعات خطا (m <sup>3</sup> /s)	نش ساتکلیف	بیایاس
۱	۰/۶۴۱	۲/۶۳۰	۰/۶۷۹	۰/۰۶۳	۰/۷۲۱	۴/۶۷۱	۰/۶۱۹	۰/۰۹۱
۲	۰/۷۱۹	۱/۹۸۶	۰/۷۱۳	۰/۰۵۱	۰/۷۸۴	۴/۰۴۷	۰/۶۹۰	۰/۰۷۲
۳	۰/۸۸۲	۱/۰۵۴	۰/۸۱۵	۰/۰۲۹	۰/۸۴۳	۳/۵۹۰	۰/۷۸۹	۰/۰۵۰

جدول (۸): مقادیر شاخص‌های آماری عملکرد مدل شبکه عصبی مصنوعی برای الگوهای مختلف در مراحل آموزش و صحت‌سنجی

الگو	آموزش				صحت‌سنجی			
	ضریب همبستگی	ریشه میانگین مربعات خطا (m <sup>3</sup> /s)	نش ساتکلیف	بیایاس	ضریب همبستگی	ریشه میانگین مربعات خطا (m <sup>3</sup> /s)	نش ساتکلیف	بیایاس
۱	۰/۶۰۱	۲/۵۶۰	۰/۶۳۷	۰/۰۷۱	۰/۶۴۱	۴/۵۶۲	۰/۵۸۹	۰/۰۸۸
۲	۰/۶۸۹	۲/۰۶۷	۰/۶۸۲	۰/۰۶۴	۰/۷۰۸	۴/۲۳۰	۰/۶۲۵	۰/۰۷۹
۳	۰/۷۸۰	۱/۴۱۹	۰/۷۶۹	۰/۰۳۷	۰/۸۱۸	۳/۸۳۹	۰/۷۴۰	۰/۰۷۲


### ارزیابی مدل‌ها بر اساس نمودارهای پراکنش و

#### سری زمانی


در شکل‌های ۲ تا ۵ نمودارهای پراکنش حول خط یک به یک و سری زمانی مدل‌های مورد استفاده در تحقیق حاضر برای مرحله صحت‌سنجی و به‌ازای بهترین الگو (الگوی شماره ۳) نمایش داده شده است. نمودارهای مذکور در حالت کلی نشان می‌دهد که مقادیر دبی جریان در ایستگاه پایین‌دست کمتر از مقدار واقعی تخمین زده شده است و به عبارت دیگر مدل‌ها حالت کم‌برآورد<sup>۱</sup> داشته‌اند. وضعیت کم‌برآورد مدل‌ها در مورد دبی‌های بیشینه کاملاً مشهود است. که از این لحاظ با برخی از تحقیقات مشابه مطابقت دارد (Ghorbani et al., 2016; Shafaei and Kisi, al., 2016; He et al., 2014). با این وجود همان‌طور که ملاحظه می‌شود در مدل LS-SVM پراکنش بهتری حول محور یک به یک (y=x) دیده می‌شود و در نمودار سری زمانی آن

هم‌پوشانی بهتری بین مقادیر مشاهداتی و پیش‌بینی وجود دارد.

<sup>۱</sup>Under-Estimate

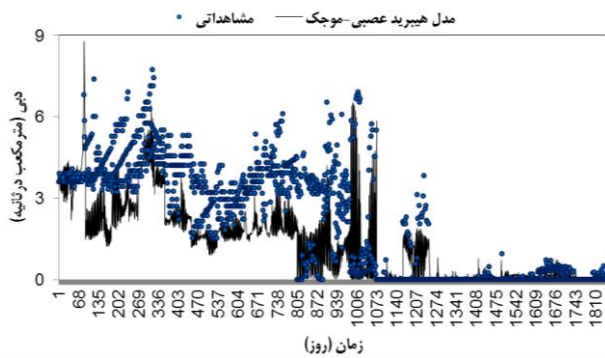


(ب)




(الف)

شکل (۲): نمودارهای حاصل از مدل حداقل مربعات ماشین بردار پشتیبان به‌ازای بهترین الگو در مرحله صحت‌سنجی (الف): پراکنش حول محور یک به یک (ب): سری زمانی مقادیر مشاهداتی و پیش‌بینی شده

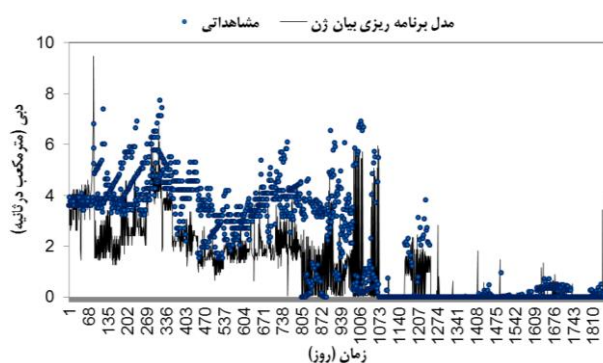


(ب)




(الف)

شکل (۳): نمودارهای حاصل از مدل موجک-عصبی به‌ازای بهترین الگو در مرحله صحت‌سنجی (الف): پراکنش حول محور یک به یک (ب): سری زمانی مقادیر مشاهداتی و پیش‌بینی شده



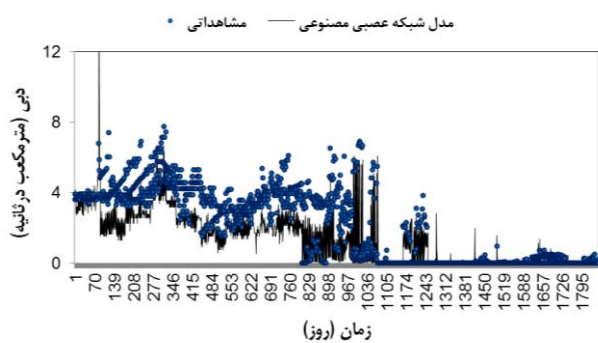
(ب)



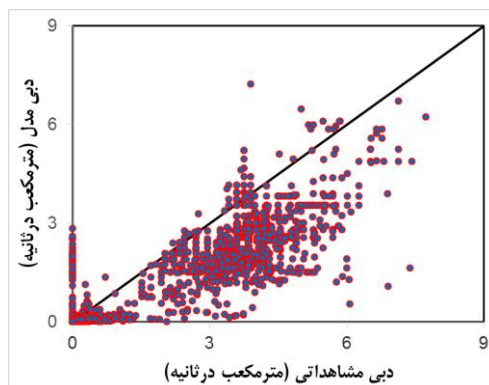
(الف)

شکل (۴): نمودارهای حاصل از مدل برنامه ریزی بیان ژن به ازای بهترین الگو در مرحله صحت سنجی

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



(ب)



(الف)

شکل (۵): نمودارهای حاصل از مدل شبکه عصبی مصنوعی به ازای بهترین الگو در مرحله صحت سنجی

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

نسبی،  $Q_0$  و  $Q_c$  به ترتیب مقادیر دبی بیشینه مشاهداتی و پیش بینی شده می باشد. با توجه به نتایج جدول ۹ مشاهده می شود که در برآورد مقادیر دبی بیشینه در ایستگاه پایین دست، مدل WNN با میانگین خطای ۳۴/۲۱ درصد دارای بهترین عملکرد نسبت به سایر مدل ها می باشد. در مقابل، مدل GEP با میانگین خطای ۵۶/۰۷ درصد ضعیف ترین عملکرد را در این خصوص به همراه داشته است. با توجه به نتایج بدست آمده حالت کم برآورد مدل ها در پیش بینی دبی بیشینه کاملاً مشهود است.

**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. مقادیر بیشینه دبی بدست آمده از بهترین الگوهای مدل های مختلف و مقادیر مشاهداتی متناظر آن ها به همراه قدر مطلق خطای نسبی هر مدل در جدول ۹ ارائه شده است. لازم به ذکر است که برای محاسبه خطای نسبی از رابطه ۱۳ استفاده شد. در رابطه مذکور، RE معرف خطای

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

جدول (۹): کارآیی مدل‌های مورد مطالعه در پیش‌بینی دبی بیشینه جریان در ایستگاه پایین‌دست

خطای نسبی (%)				مقادیر پیش‌بینی شده (m <sup>3</sup> /s)				مقادیر دبی
WNN	ANN	GEP	LS-SVM	WNN	ANN	GEP	LS-SVM	بیشینه مشاهداتی (m <sup>3</sup> /s)
۲۹/۰۰	۱۰۸/۳۳	۳۱/۳۴	۲۲/۱۵	۸/۷۷	۱۴/۱۶	۴/۶۶	۸/۳	۶/۸۰
۱۹/۳۵	۲۸/۵۰	۴۵/۹۱	۲۹/۹۴	۵/۵۰	۴/۸۷	۳/۶۸	۴/۷۷	۶/۸۲
۴۲/۸۱	۴۳/۵۳	۷۳/۹۱	۳۸/۹۴	۳/۹۴	۳/۸۹	۱/۸۰	۴/۲۱	۶/۹۰
۵۶/۹۹	۸۴/۳۴	۷۴/۶۰	۷۵/۶۱	۲/۹۷	۱/۰۸	۱/۷۵	۱/۶۸	۶/۹۱
۹/۸۷	۳۱/۶۱	۵۱/۶۴	۱۳/۴۹	۶/۴۲	۴/۸۷	۳/۴۴	۶/۱۶	۷/۱۳
۲۵/۲۷	۶/۰۲	۷۸/۵۵	۳۰/۰۹	۵/۳۲	۶/۷۰	۱/۵۲	۴/۹۸	۷/۱۳
۲۳/۴۵	۲۶/۴۱	۳۰/۸۳	۳۲/۹۸	۵/۴۵	۵/۲۴	۴/۹۳	۴/۷۷	۷/۱۳
۷۹/۰۰	۷۷/۰۷	۷۲/۳۵	۷۲/۳۰	۱/۵۴	۱/۶۳	۲/۰۴	۲/۰۴	۷/۳۸
۳۳/۵۴	۳۴/۳۷	۳۰/۰۶	۳۵/۶۹	۴/۹۳	۴/۸۷	۵/۱۹	۴/۷۷	۷/۴۳
۲۲/۸۵	۱۹/۴۰	۷۱/۷۰	۲۶/۳۳	۵/۹۶	۶/۲۳	۲/۱۸	۵/۶۹	۷/۷۳
۳۴/۲۱	۴۶/۰۳	۵۶/۰۷	۳۷/۷۵	میانگین قدرمطلق خطا (%)				

## نتیجه‌گیری

همان‌گونه که اشاره شد بالخلوچای مهم‌ترین منبع تأمین آب شرب شهر اردبیل می‌باشد که انواع سازه‌های هیدرولیکی شامل سدهای مخزنی و انحرافی بر روی آن احداث شده است. از این‌ور پیش‌بینی و روندیابی جریان آن در بازه‌های مختلف رودخانه، به‌منظور مدیریت صحیح بهره‌برداری ضروری به‌نظر می‌رسد. در تحقیق حاضر کارآیی مدل‌های مختلف هوشمند در روندیابی جریان روزانه رودخانه بالخلوچای مورد بررسی قرار گرفت. در این راستا حجم وسیعی از مقادیر دبی روزانه مشاهداتی طی دوره آماری ۱۷ ساله، در ایستگاه‌های هیدرومتری بالادست و پایین‌دست واقع بر روی رودخانه مذکور مورد استفاده قرار گرفت. به‌منظور پیش‌بینی جریان رودخانه در ایستگاه پایین‌دست، سه الگوی متفاوت تعریف شد. در کلیه مدل‌ها با ترکیب گام زمانی فعلی و پیشین دبی ایستگاه بالادست، دقت تخمین جریان روزانه ایستگاه پایین‌دست بهبود یافت. چنانچه بیشترین دقت مدل‌ها در ترکیب ورودی دبی

روزانه ایستگاه بالادست به همراه تأخیرهای یک روز و دو روز آن فراهم شد. بررسی شاخص‌های آماری نشان داد که مدل‌های مورد استفاده در تحقیق حاضر از عملکرد قابل قبول در روندیابی جریان روزانه رودخانه بالخلوچای برخوردار می‌باشند. در مجموع با توجه به نتایج قابل قبول مدل‌های مورد استفاده در تحقیق حاضر، ضرایب و توابع به‌کار رفته برای واسنجی آن‌ها می‌تواند برای روندیابی جریان حوضه آبریز دره‌رود بسیار مفید باشد. البته در صورت استفاده از نتایج تحقیق حاضر، خاصیت کم‌برآورد مدل‌ها در برنامه-ریزی‌های منابع آب حوضه مذکور (به‌خصوص در پیش‌بینی دبی سیلاب) باید مد نظر قرار گیرد. همچنین مطابق با نتایج سایر تحقیقات مشابه، نظر به برتری محسوس و دقت بالاتر مدل حداقل مربعات ماشین بردار پشتیبان می‌توان از مدل مذکور به‌عنوان ابزاری کارآمد و قابل اعتماد در روندیابی جریان رودخانه بالخلوچای استفاده نمود. در راستای پژوهش انجام شده، استفاده از سایر متغیرهای اقلیمی نظیر دما

در ورودی مدل‌ها، مقایسه عملکرد مدل‌های مورد استفاده در این تحقیق با سایر مدل‌های هوشمند و یا مدل‌های مفهومی بارش- رواناب می‌تواند موضوع تحقیقات آتی باشد.

## منابع

- رضایی، الف، ع. خاشعی سیوکی و ع. شهیدی. ۱۳۹۳. طراحی شبکه‌ی پایش سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM). نشریه تحقیقات آب و خاک ایران، سال چهارم، شماره ۴۵، ص ۳۸۹-۳۹۶.
- شفائی، م.، ا. فاخری فرد، ص. دربندی و م.ع. قربانی. ۱۳۹۲. پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی، مطالعه موردی: ایستگاه هیدرومتری ونیاد در حوضه آبریز آجی‌چای. نشریه مهندسی آبیاری و آب ایران، سال چهارم، شماره ۱۴، ص ۱۲۸-۱۱۳.
- غفاری، غ. و م. وفاخواه. ۱۳۹۲. شبیه‌سازی فرآیند بارش- رواناب با استفاده از شبکه عصبی مصنوعی و سیستم فازی- عصبی تطبیقی (مطالعه موردی: حوزه آبخیز حاجی‌قوشان). پژوهشنامه مدیریت حوزه آبخیز، سال چهارم، شماره ۸، ص ۱۳۶-۱۲۰.
- قربانی، م.ع. و ر. دهقانی. ۱۳۹۵. کاربرد شبکه‌های عصبی بیزین، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژن در تحلیل بارش- رواناب ماهانه (مطالعه موردی: رودخانه کاکارضا). نشریه علوم و مهندسی آبیاری، جلد ۳۹، شماره ۲، ص ۱۳۸-۱۲۵.
- معروفی، ص.، ک. امیرمادی و ن. پارسافر. ۱۳۹۲. پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی-موجکی (مطالعه موردی: رودخانه باراندوزچای). نشریه دانش آب و خاک، جلد ۲۳، شماره ۳، ص ۱۰۳-۹۳.
- نوری، ر.، ا. فرخ‌نیا، س. مرید و ح. ریحانی مدوار. ۱۳۸۸. تاثیر پیش پردازش‌های متغیر ورودی به شبکه عصبی برای پیش‌بینی جریان ماهانه با آنالیز مولفه‌های اصلی و موجک. نشریه آب و فاضلاب، شماره ۱، ص ۲۲-۱۳.
- Ahani, A., M. Shourian, and P. Rahimi Rad. 2017. Performance assessment of the linear, nonlinear and nonparametric data driven models in river flow forecasting. *Water Resources Management*, DOI 10.1007/s11269-017-1792-5
- Behzad, M., K. Asghari, M. Eazi and M. Palhang. 2009. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with applications*, 36(4): 7624-7629.
- Ferreira, C. 2001. Algorithm for solving gene expression programming: a new adaptive problems. *Complex Systems*, 13(2): 87-129.
- Ferreira, C. 2006. Automatically defined functions in gene expression programming. In *Genetic Systems Programming*. Springer Berlin Heidelberg, 21-56.
- Ghorbani, M. A., O. Kisi, M. Aalinezhad. 2010. A probe into the chaotic nature of daily streamflow time series by correlation dimension and largest Lyapunov methods. *Applied Mathematical Modelling*, 34(12): 4050-4057.
- Ghorbani, M. A., R. Khatibi, A. Goel, M.H. FazeliFard and A. Azani. 2016. Modeling river discharge time series using support vector machine and artificial neural networks. *Environmental Earth Sciences*, 75(8): 1-13.
- He, Z., X. Wen, H. Liu and J. Du. 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: 379-386.
- Kisi, O. 2008. Stream flow forecasting using neuro-wavelet technique. *Hydrological Processes*, 22(20): 4142-4152.

- Nourani, V., A. Hosseini Baghanam, J. Adamowski and O. Kisi. 2014. Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514(1): 358-377.
- Shafaei, M. and O. Kisi. 2016. Predicting river daily flow using wavelet-artificial neural networks based on regression analyses in comparison with artificial neural networks and support vector machine models. *Neural Computing and Applications*, 1-14.
- Sivapragasam, C., R. Maheswaran and V. Venkatesh. 2008. Genetic programming approach for flood routing in natural channels. *Hydrological processes*, 22(5): 623-628.
- Suykens, J.A., J. De Brabanter. L. Lukas and J. Vandewalle. 2002. Weighted least squares support vector machines: robustness and sparse approximation. *Neurocomputing*, 48(1): 85-105.
- Taheri, H. and M. Ghafouri. 2012. Comparison between active learning method and support vector machine for runoff modeling. *Journal of Hydrology and Hydromechanics*, 60(1): 16-32.
- Tiwari, M.K. 2015. River flow forecasting using neural networks coupled with wavelet analysis. *International Journal of Engineering Research and Technology*, 4(3): 174-179.
- Vapnic, VN. 1998. *Statistical Learning Theory*. Wiley, NEW YORK: USA
- Yu, P.S., S.T. Chen and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3): 704-716.

## Comparison of Intelligent Models Efficiency for Routing of River Daily Flow (Case Study: Baleqlu-Chay River, Ardabil Province)

Mohammad Reza Nikpour<sup>1</sup>, Sajad Mahmodi Babelan<sup>2</sup>

### Abstract

Routing of river flow is one of the most important of water resources management topics to adopt appropriate decision in occurrence time of flood or droughts. In this study, artificial neural networks (ANN), gene expression programming (GEP), wavelet- neural network (WNN) and least square support vector machine (LS-SVM) models were used for routing of Baleqlu-Chay river daily flow, located at Dareh-Roud watershed. Daily river discharge data of two consecutive hydrometric stations located at the mentioned river for the period of 1997-2013. The statistics indices including, root mean square error (RMSE), correlation coefficient (R), Nash-Sutcliffe efficiency coefficient (NS) and Bias were used to evaluate the precision of the models. Comparison of results demonstrate that the LS-SVM with RMSE=1.540 m<sup>3</sup>/s, R=0.894, NS=0.713 and Bias=0.013 had the best performance in the test period. But in estimating of peak discharge values, the WNN model with average relative error equal to 34.21% had the least error. It should be mentioned that all of the models tended to underestimate the discharge values.

**Keywords:** Gene expression programming, Least square support vector machine, Flow routing, artificial neural networks, Wavelet- neural network.

---

<sup>1</sup>Assistant Professor, Department of Water Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.

[m\\_nikpour@uma.ac.ir](mailto:m_nikpour@uma.ac.ir)

<sup>2</sup>Former Student, Department of Water Engineering, University of Mohaghegh Ardabili, Ardabil, Iran.