



ارزیابی مدل‌های هیبریدی فراکاوشی در شبیه‌سازی جریان رودخانه‌ها مطالعه‌ی موردی: رودخانه‌ی کشکان لرستان

حجت‌اله یونسی^{۱*}، احمد گودرزی^۲، مسعود شاکرمی^۳

۱- استادیار گروه مهندسی آب، دانشکده‌ی کشاورزی، دانشگاه لرستان

۲- دانشجوی دکتری سازه‌های آبی، دانشکده‌ی کشاورزی، دانشگاه لرستان

۳- استادیار گروه مهندسی آب، دانشکده‌ی کشاورزی، دانشگاه لرستان

تأیید نهایی مقاله: ۱۴۰۰/۰۷/۱۸

وصول مقاله: ۱۴۰۰/۰۶/۲۹

چکیده

امروزه مدل‌های هیبریدی هوش مصنوعی به عنوان یک روش مناسب برای شبیه‌سازی پدیده‌های هیدرولوژیکی از جمله برآورد کمی جریان رودخانه‌ها مطرح است. بدین منظور جهت برآورد میزان آبدهی رودخانه‌ها رویکردهای متنوعی در هیدرولوژی وجود دارد که مدل‌های هوش مصنوعی از مهم‌ترین آن‌ها می‌باشد. بنابراین در این پژوهش عملکرد مدل‌های رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش جهت شبیه‌سازی دبی رودخانه کشکان واقع در استان لرستان طی دوره‌ی آماری ۱۳۸۹-۱۳۹۹ در مقیاس زمانی روزانه‌ی مورد تجزیه و تحلیل قرار گرفت. معیارهای ضریب همبستگی، ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا و بایاس برای ارزیابی و عملکرد مدل‌ها انتخاب شد. نتایج نشان داد الگوهای ترکیبی نتایج قابل قبولی در شبیه‌سازی دبی رودخانه دارند. مقایسه‌ی مدل‌ها نیز نشان داد مدل رگرسیون بردار پشتیبان-موجک در مرحله‌ی صحت‌سنجی مقادیر $R^2=0/960$ ، $MAE=0/024$ ، $RMSE=0/045$ و $NS=0/968$ و $BIAS=0/001$ در پیش‌بینی جریان روزانه‌ی رودخانه از خود نشان داده است. در مجموع نتایج نشان داد استفاده از مدل هیبریدی رگرسیون بردار پشتیبان-موجک می‌تواند در زمینه‌ی پیش‌بینی دبی روزانه مفید باشد.

کلمات کلیدی: دبی رودخانه، شبیه‌سازی، مدل هیبریدی، رودخانه‌ی کشکان، استان لرستان.

۱-مقدمه

مهم‌ترین مسائل جهت مدیریت سیلاب و جلوگیری از صدمات اقتصادی و جانی ناشی از آن، برآورد دقیق جریان رودخانه‌ها است. بر این اساس دستیابی به روش‌های مطمئن پیش‌بینی جریان رودخانه‌ها به‌منظور برنامه‌ریزی در بهره‌برداری به‌موقع از منابع آب از اهمیت روزافزونی برخوردار است (دهقانی و همکاران، ۱۳۹۶: ۴۰). لذا انتخاب مدلی که بتواند با استفاده از عوامل تأثیرگذار، جریان رودخانه را به‌طور قابل قبولی تخمین زند امری ضروری به نظر می‌رسد. امروزه سامانه‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد. یکی از روش‌هایی که در سال‌های اخیر در زمینه‌ی هیدرولوژی مورد توجه قرار گرفته است مدل هیبریدی ماشین بردار پشتیبان با تبدیل موجک می‌باشد مدل ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است (دهقانی و همکاران، ۱۳۹۶: ۴۰). استفاده از موجک به‌عنوان یکی از تبدیل‌های ریاضی نوین و کارآمد در زمینه‌ی پردازش سیگنال و تجلیل سری‌های زمانی است به کمک تبدیل موجک که قابلیت تجزیه سری زمانی به چند زیر سری زمانی با مقیاس‌های متفاوت دارد، می‌توان رفتار کوچک‌مقیاس و بزرگ‌مقیاس یک فرآیند هیدرولوژیکی را مورد تحلیل قرار داد که باعث افزایش دقت تحلیل موردنظر خواهد شد (صالحی و همکاران، ۱۳۹۷: ۵۱). در سال‌های اخیر استفاده از مدل‌های هوشمند و هیبریدی در مطالعات پیش‌بینی جریان رودخانه‌ها مورد توجه محققین قرار گرفته است که از جمله می‌توان به موارد ذیل اشاره نمود: قربانی و همکاران (۲۰۱۸) جهت پیش‌بینی جریان ماهانه رودخانه اجیدیر^۱ واقع در ترکیه عملکرد مدل‌های هوش مصنوعی هیبریدی را مورد تجزیه و تحلیل نتایج نشان داد مدل ترکیبی شبکه عصبی مصنوعی با الگوریتم شب‌تاب از عملکرد بهتری نسبت به سایر مدل‌های ترکیبی برخوردار است. قربانی و همکاران (۲۰۱۸) عملکرد مدل‌های هیبریدی شبکه عصبی مصنوعی و ماشین بردار پشتیبان را در تخمین دبی رودخانه‌ی زرینه‌رود واقع در ایران مورد بررسی قرار دادند نتایج نشان داد که مدل هیبریدی شبکه عصبی مصنوعی دقت مناسب‌تری نسبت به ماشین بردار پشتیبان دارد. نتایج حاصل از پژوهش عدنان و همکاران (۲۰۱۹) که جهت پیش‌بینی دبی ماهانه رودخانه سوات^۲ واقع در پاکستان از مدل‌های ماشین بردار پشتیبان و درخت تصمیم استفاده نمودند نشان داد مدل ماشین بردار پشتیبان کارایی مناسبی در پیش‌بینی جریان رودخانه‌ها دارد. علیزاده و همکاران (۲۰۲۰) در پژوهشی به بررسی مدل هیبریدی ماشین بردار پشتیبان-موجک جهت پیش‌بینی جریان روزانه رودخانه‌ی سوریس^۳ واقع در شمال ایالات متحده پرداختند و نتایج نشان

1- Egirdir
2- Swat


3- Souris

داد مدل هیبریدی ماشین بردار پشتیبان-موجک کارایی و دقت مناسبی در پیش‌بینی جریان روزانه رودخانه از خود نشان داده است. دهقانی و ترابی (۲۰۲۱) در پژوهشی عملکرد مدل‌های هوش مصنوعی هیبریدی را جهت شبیه‌سازی ایستگاه‌های هیدرومتری حوضه آبریز کرخه مورد بررسی قرار دادند نتایج نشان داد مدل‌های هوش مصنوعی هیبریدی از جمله شبکه عصبی مصنوعی-تفنگدار خلاق نسبت به سایر مدل‌های هیبریدی از دقت بیشتری برخوردار است. درمجموع با توجه به پژوهش‌های انجام‌شده و ذکر این نکته که رودخانه‌ی کشکان یکی از مهم‌ترین رودخانه‌های استان لرستان و مهم‌ترین منبع تأمین‌کننده‌ی آب بخش‌های مختلف و نواحی مجاور خود از لحاظ کشاورزی و شرب می‌باشد و همچنین کاهش جریان این رودخانه مشکلات زیادی در حوضه‌ی آبریز ایجاد کرده است؛ بنابراین، اهمیت شبیه‌سازی جریان رودخانه کشکان و اقدامات مدیریتی جهت مدیریت آب آن بیش‌ازپیش ضروری است. لذا هدف این پژوهش شبیه‌سازی جریان روزانه رودخانه کشکان با استفاده از رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش می‌باشد.

۲-موارد و روش‌ها

۲-۱- منطقه‌ی مورد مطالعه

رودخانه‌ی کشکان سیل‌خیزترین رودخانه‌ی استان لرستان است. حوضه‌ی آبریز کشکان با مساحت ۶۶/۹۷ کیلومترمربع در ناحیه‌ی جنوب غربی ایران واقع‌شده است. این حوضه بخش مهمی از سرشاخه‌های پرآب رودخانه‌ی کرخه را تشکیل می‌دهد و حدود یک‌سوم خاک لرستان را در برمی‌گیرد. حوضه‌ی آبخیز رودخانه کشکان در تقسیم‌بندی هیدرولوژی ایران جزئی از حوضه‌ی آبریز خلیج فارس به حساب می‌آید. این رودخانه در بین طول‌های جغرافیایی $34^{\circ} 31'$ تا 47° درجه تا $6^{\circ} 12' 48^{\circ}$ شرقی و عرض‌های جغرافیایی $45^{\circ} 5'$ تا 33° درجه شمالی در استان لرستان واقع‌شده است. موقعیت منطقه‌ی مورد مطالعه در شکل ۱ نشان داده‌شده است.



شکل (۱): منطقه‌ی مورد مطالعه

Fig (1): The Study area

۲-۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (واپنی، ۱۹۹۵: ۲۲۴). در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. در مدل SVM همانند مسائل رگرسیونی رابطه میان متغیرهای مستقل و وابسته به صورت رابطه‌ی ۲ بیان می‌گردد که در این معادله $f(x)$ تابع SVM به علاوه خطای مجاز مشخص شود.

$$F(x)=W^T.\phi(x)+b \quad (۱)$$

$$y=f(x)+noise \quad (۲)$$

چنانچه W^T ترانهاده بردار ضرایب و b ثابت مشخصه‌های تابع رگرسیونی و $\emptyset$ نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از داده‌ها (مجموعه آموزش) محقق می‌شود (میسرا و همکاران، ۲۰۰۹: ۱۱۷). برای محاسبه W و b لازم است تابع خطا (معادله‌ی ۳) در مدل ε -SVM با در نظر گرفتن شرایط مندرج (قیود) در معادله‌ی (۴) و (۵) کمینه شود (هامل، ۲۰۰۹: ۱۴۲).

$$\frac{1}{2} W^T . W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \quad (۳)$$

$$W^T . \emptyset (X_i) + b - y_i \leq \varepsilon + \varepsilon_i^* , \quad (۴)$$

$$y_i - W^T . \emptyset (X_i) - b \leq \varepsilon + \varepsilon_i , \varepsilon_i , \varepsilon_i^* \geq 0 \quad , \quad i=1,2,\dots,N \quad (۵)$$

در معادلات بالا C عددی صحیح و مثبت است، که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است. $\emptyset$ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ε_i و ε_i^* متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می‌توان به فرم زیر بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \emptyset(x_i)^T . \emptyset(x) + b \quad (۶)$$

در معادله‌ی ۶، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ می‌باشد. محاسبه $\emptyset(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد (یون و همکاران، ۲۰۱۱: ۲۴۶). برای حل این مشکل روند معمول در مدل SVM رگرسیون انتخاب یک تابع کرنل به صورت رابطه‌ی زیر است.

$$K(X_j, X) = \emptyset(X_j)^T \sqrt{b^2 - 4ac} \quad (۷)$$

می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف ε -SVM استفاده کرد. پرکاربردترین توابع کرنل چندجمله‌ای^۱ و کرنل توابع پایه شعاعی^۲ (RBF) و کرنل خطی، به ترتیب طبق روابط ۸-۱۰ محاسبه می‌گردند (باساک و همکاران، ۲۰۰۷: ۱۷۰؛ واپنیک و چرونسکی، ۱۹۹۱: ۴۵). در این پژوهش از این سه تابع کرنل استفاده شده است. قابل ذکر است فرآیند محاسبات ماشین بردار پشتیبان بر اساس کدنویسی در محیط متلب انجام، و پارامترهای توابع کرنل از طریق سعی و خطا بهینه گردیدند.

$$K(x, x_j) = (t + x_i . x_j)^d \quad (۸)$$

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (۹)$$

$$k(x, x_j) = x_i \cdot x_j \quad (۱۰)$$

۲-۳- تبدیل موجک

تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوریه‌ی زمان کوتاه ارائه شده است و هدف از ارائه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک پذیری فرکانس در تبدیل فوریه‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه‌ی زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هر کدام از این پنجره‌ها به صورت جداگانه انجام می‌گیرد (واپنیک، ۱۹۹۸: ۳۷). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به عبارت دیگر، در تبدیل موجک به جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان-مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال قابل بررسی می‌باشد (وانگ و همکاران، ۲۰۰۰: ۹۸). یک موجک به معنای موج کوچک، بخشی یا پنجره‌ای از سیگنال اصلی است که انرژی آن در زمان متمرکز شده است. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد. بنابراین موجک‌ها نمونه‌های انتقال یافته و تفکیک شده سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرارداد (شین و همکاران، ۲۰۰۵: ۱۶۶).

تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته‌ی تابع $f(t)$ به صورت روابط (۱۱) و (۱۲) تعریف می‌شود (واپنیک، ۱۹۹۸: ۳۷).

$$CWT_f^\psi(s, \tau) = \Psi_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-\tau}{s}\right) dt = \langle f(t), \psi_{s,\tau}(t) \rangle \quad (۱۱)$$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) \quad (۱۲)$$

رابطه‌ی (۲) یک رابطه با دو متغیر S و τ است که S پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال می‌باشند. علامت * نیز نشان‌دهنده‌ی مزدوج مختلط است. ψ تابع پنجره یا موجک مادر و $\psi\left(\frac{t-\tau}{s}\right)\frac{1}{\sqrt{|s|}}$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند [۳۴]. واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان‌دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است.


۲-۴- الگوریتم گرگ خاکستری

الگوریتم گرگ خاکستری GWO یک الگوریتم فراکاوشی است که از ساختار سلسله مراتبی سلسله مراتبی و رفتار اجتماعی گرگ‌های خاکستری در هنگام شکار کردن الهام گرفته است (اوستا، ۱۹۷۹: ۴۴). این الگوریتم مبتنی بر جمعیت بوده، فرآیند ساده‌ای دارد و به سادگی قابلیت تعمیم به مسائل با ابعاد بزرگ را دارد. گرگ‌های خاکستری به عنوان شکارچیان راس در نظر گرفته می‌شوند، که در بالای هرم زنجیره‌ی غذایی هستند. گرگ‌های خاکستری ترجیح می‌دهند در یک گروه (دسته) زندگی کنند، هر گروه به‌طور متوسط ۵-۱۲ عضو دارد. همه اعضای این گروه دارای سلسله مراتب تسلط اجتماعی بسیار دقیق هستند و وظایف خاصی دارند. در هر گله از گرگ‌ها برای شکار کردن ۴ درجه وجود دارد که مانند شکل زیر به‌صورت یک ساختار هرمی مدل می‌شود (اوستا، ۱۹۷۹: ۴۴).

- گرگ‌های رهبر گروه Alpha نامیده می‌شوند که می‌توانند مذکر یا مونث باشند. این گرگ‌ها بر گله تسلط دارند.
 - گرگ‌های Beta: کمک به گرگ‌های Alpha در فرایند تصمیم‌گیری بوده و همچنین مستعد انتخاب شدن به جای آنها هستند.
 - گرگ‌های Delta: پایین‌تر از گرگ‌های Beta و شامل گرگ‌های پیر، شکارچی‌ها و گرگ‌های مراقبت‌کننده از نوزادان.
 - گرگ‌های Omega: پایین‌ترین مرتبه در هرم سلسله مراتب که کمترین حق را نسبت به بقیه اعضای گروه دارند. بعد از همه غذا می‌خورند و در فرایند تصمیم‌گیری مشارکتی ندارند.
- این الگوریتم شامل سه مرحله می‌باشد که به صورت زیر تشریح می‌گردد.
- مشاهده شکار، ردیابی و تعقیب آن (tracking and approaching)

نزدیک شدن، احاطه کردن (حلقه زدن) به دور شکار و گمراه کردن آن تا زمانی که از حرکت باز بماند (Pursing and encircling)
حمله به شکار (attacking)

در این مقاله ساختار سلسله مراتبی و رفتار اجتماعی گرگ‌ها در حین فرایند شکار به صورت ریاضی مدل شده و برای طراحی الگوریتمی برای بهینه‌سازی مورد استفاده قرار گرفته است.



شکل (۲): فلوچارت الگوریتم گرگ خاکستری

Fig (2): Gray wolf algorithm flowchart

۲-۵- الگوریتم خفاش

هوش جمعی یکی از قویترین تکنیک‌های بهینه‌سازی می‌باشد که بر مبنای رفتارهای گروهی است (آمودا، ۲۰۱۳: ۱۲۲). الگوریتم خفاش از دسته الگوریتم‌های فراشناختی است که الهام گرفته از رفتار جمعی خفاش‌ها در محیط طبیعی است که در سال ۲۰۱۰ توسط یانگ ارائه شد. این الگوریتم بر مبنای استفاده از خاصیت انعکاس صدا توسط خفاش‌ها است. خفاش‌ها مسیر و محل دقیق طعمه خود را بوسیله‌ی فرستادن امواج صوتی و دریافت بازتاب آن، پیدا می‌کنند. زمانی که امواج صوتی به سمت فرستنده امواج (خفاش) بازمی‌گردد، این پرنده می‌تواند یک تصویر صوتی از موانع روبروی محیط اطراف خود رسم کند و محیط اطراف را حتی در تاریکی

مطلق به‌خوبی ببینند. با استفاده از این سیستم، خفاش‌ها می‌توانند اجسام متحرک مثل حشرات و اجسام بی‌حرکت مثل درختان را تشخیص دهند (آمودا، ۲۰۱۳: ۱۲۲).


الگوریتم خفاش مبتنی بر ویژگی پژواکیایی ریز خفاش‌ها است. در حالت کلی دو نوع خفاش وجود دارد که نوع اول بزرگ – خفاش‌ها هستند و نوع دوم ریز خفاش‌ها نام دارند. ریز خفاش‌ها از این ویژگی برای پرواز در شب و شکار استفاده می‌کنند. پژواکیایی ریز خفاش‌ها در عمل یک سامانه ادراکی است که در آن موج‌های فراصوتی برای بدست آوردن پژواک، تولید می‌شوند. مغز و دستگاه عصبی خفاش با مقایسه‌ی موج‌های فرستاده‌شده و موج‌های بازتاب شده می‌تواند تصویری از فضای پیرامون و جزئیاتش را برای خود بسازد. این توانایی به ریز خفاش‌ها اجازه می‌دهد تا در تاریکی مطلق شکارشان را شناسایی کنند (آمودا، ۲۰۱۳: ۱۲۲).

قوانین الگوریتم خفاش این قوانین می‌تواند به زبان ساده به‌صورت زیر بیان شود:

تمامی خفاش‌ها با بکارگیری پژواکیایی می‌توانند مسافت را تخمین بزنند و تفاوت بین طعمه و موانع ثابت را تشخیص دهند.

خفاش‌ها به‌صورت تصادفی با سرعت V_i در موقعیت X_i با فرکانس ثابت f_{min} با طول موج متغیر λ و بلندی صدای A_0 در جست‌وجوی شکار هستند. آن‌ها می‌توانند به‌طور اتوماتیک طول موج پالس‌های منتشرشده از خود را تنظیم کرده و نرخ انتشار پالس خود یعنی $r \in (1,0)$ را طبق نزدیکی طعمه خود مطابقت دهند.

اگرچه بلندی صدا می‌تواند به طرق مختلف تغییر کند، اما فرض می‌شود که بلندی از یک مقدار بزرگ (مثبت A_0) تا یک مقدار مینیمم ثابت یعنی A_{min} تغییر کند.



شکل (۳): فلوچارت الگوریتم بهینه‌سازی خفاش
Fig (3): Flowchart of the Bat Optimization Algorithm

۲-۶- ارزیابی و عملکرد مدل‌ها

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب تبیین (R^2)، ریشه‌ی میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب نش ساتکلیف (NS) و درصد بایاس (PBIAS) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر، صفر، یک، صفر و صفر می‌باشد.

$$R^2 = \left[\frac{\sum_{i=1}^n (M_{oi} - \bar{M}_0)(M_{ei} - \bar{M}_e)}{\sqrt{\sum_{i=1}^n (M_{oi} - \bar{M}_0)^2 \cdot \sum_{i=1}^n (M_{ei} - \bar{M}_e)^2}} \right]^2, 0 \leq R^2 \leq 1 \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (M_{ei} - M_{oi})^2}, 0 \leq RMSE \leq +\infty \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |M_{ei} - M_{oi}|, 0 \leq MAE \leq +\infty \quad (15)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (M_{ei} - M_{oi})^2}{(\sum_{i=1}^n (M_{ei} - \bar{M}_e))^2}, -\infty < NSE < 1 \quad (16)$$

$$PBIAS = \frac{\sum_{i=1}^n (M_{oi} - M_{ei})}{\sum_{i=1}^n M_{ei}} \times 100, -100 \leq PBIAS \leq 100 \quad (17)$$

در روابط بالا، M_{ei} و M_{oi} به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، $\bar{M}_e$ و $\bar{M}_0$ نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است.

۳- نتایج و بحث

یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. بدین منظور پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت پیش‌بینی جریان رودخانه‌ی کشکان واقع در استان لرستان انتخاب و در جدول ۱ ارائه شد. در این جدول، ستون‌های $Q(t-1)$ ، $Q(t-2)$ ، $Q(t-3)$ و $Q(t-4)$ (به ترتیب جریان رودخانه در زمان‌های $t-1$ ، $t-2$ ، $t-3$ ، $t-4$) به عنوان ورودی و $Q(t)$ (جریان رودخانه در زمان t) به عنوان خروجی مدل در نظر گرفته شد. به منظور آموزش ماهیت سازوکار حاکم بر پدیده نه تنها سبب پیچیدگی الگو و افزایش حافظه درگیر خواهد شد، بلکه سبب کاهش دقت مدل نیز می‌شود. لذا در الگوسازی جریان رودخانه نیز بایستی سعی نمود مؤثرترین داده‌های مشاهداتی را به عنوان داده‌های آموزشی انتخاب کرد (دهقانی و همکاران، ۱۴۰۰: ۱۵۵). با توجه به اینکه در تحقیق حاضر تأثیر توالی دبی روزهای قبل در پیش‌بینی دبی روز مدنظر بوده، صرفاً از داده‌های نرمال شده دبی جریان با توالی برگشتی تا ۴ روز به عنوان داده‌های آموزشی، به صورت ترکیب‌های مختلف مطابق جدول استفاده شده است که از این پس از آن‌ها به عنوان الگو نام برده خواهد شد. در این پژوهش جهت شبیه‌سازی دبی رودخانه از داده‌های ایستگاه هیدرومتری کشکان که دارای ۳۶۵۰ رکورد ثبت شده طی بازه‌ی زمانی (۱۳۸۹-۱۳۹۹)، در مقیاس زمانی روزانه می‌باشد، استفاده شد. در نهایت تعداد ۲۹۲۰ رکورد برای آموزش و تعداد ۷۳۰ رکورد باقی‌مانده برای صحت‌سنجی مدل‌های مورد بررسی انتخاب شد. لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت آزمون، به صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (کیسی و همکاران، ۲۰۰۶؛ ناگای و همکاران، ۲۰۰۲).

جدول (۱): ترکیب‌های منتخب پارامترهای ورودی

Table (1): Selected compositions input parameter models

شماره	ساختار ورودی	خروجی
۱	$Q(t-1)$	$Q(t)$
۲	$Q(t-1), Q(t-2)$	$Q(t)$
۳	$Q(t-1), Q(t-2), Q(t-3)$	$Q(t)$
۴	$Q(t-1), Q(t-2), Q(t-3), Q(t-4)$	$Q(t)$

۳-۱- نتایج بررسی عملکرد مدل‌های هیبریدی

مدل‌ها و الگوریتم‌های این تحقیق با یک مجموعه داده آزمایش مورد ارزیابی قرار گرفتند و بیشترین کارایی برای مدل سازی و تحلیل بیشتر انتخاب شد. این مرحله دارای شش فاز اصلی است که در جدول ۲ بیان شده است. به عبارتی ساده‌تر این فازها همان بهترین ترکیب ورودی هستند که بر اساس ضریب همبستگی انتخاب شده بودند. همچنین برای هر مدل، از هر چهار ترکیب در مراحل آموزش و تست استفاده می‌شود. عموماً اساس کار شبکه‌های هوش مصنوعی جهت ارزیابی عملکرد آن‌ها نسبت به یکدیگر بر اساس ضریب RMSE که محققان بسیاری این شاخص‌ها را مورد تأیید قرار دادند. هدف اصلی در سیستم‌های مبتنی بر هوش مصنوعی کاهش میزان خطای برآوردی است و لذا در این تحقیق ملاک برتری مدل‌ها RMSE می‌باشد. همانطور که در جدول ۲ و ۳ قابل مشاهده است مدل ترکیبی رگرسیون بردار پشتیبان-موجک از خطای کمتری نسبت به سایر مدل‌های هیبریدی مورد بررسی برخوردار است که این امر را میتوان ناشی از جدا نمودن سیگنال به سیگنالهای بالاگذر و پایین گذر جهت تجزیه و تحلیل نقاط اکسترمم بیان نمود که با نتایج دهقانی و همکاران (۱۴۰۰) و باباعلی و دهقانی (۱۴۰۰) همخوانی دارد.

در این تحقیق جهت شبیه‌سازی دبی رودخانه‌ی کشکان واقع در استان لرستان از مدل‌های توسعه‌یافته (SVR-BA, SVR-GWO, WSVR) و نمودارهای پراکندگی و گراف تغییرات زمانی بین داده‌های مشاهداتی و محاسباتی استفاده شد.

پس از انتخاب بهترین ترکیب ورودی برای هر مدل و ترسیم نمودارهای پراکندگی و گراف تغییرات زمانی بین داده‌های مشاهداتی و محاسباتی برای ایستگاه هیدرومتری مورد بررسی، آمار عملکرد مدل‌ها برای داده‌های تست و آزمون در جدول ۳ نشان داده شد.

بنابراین بطور خلاصه می‌توان گفت پس از انتخاب بهترین ترکیب ورودی برای هر مدل، مدل‌های پیش‌بینی برای شبیه‌سازی دبی روزانه رودخانه مورد بررسی، طبق جدول ۳ نشان می‌دهد مدل هیبریدی رگرسیون بردار پشتیبان-موجک (WSVR) از عملکرد بهتری به ترتیب نسبت به سایر مدل‌های هیبریدی از جمله رگرسیون بردار پشتیبان-گرگ خاکستری (GWO-SVR) و رگرسیون بردار پشتیبان-خفاش (BA-SVR) دارد بگونه‌ای که طبق شاخص‌های ارزیابی مدل‌ها، مدل رگرسیون بردار پشتیبان-موجک دارای مقادیر $R=0/960$ ، $RMSE=0/045$ ، $MAE=0/024$ ، $NS=0/968$ و $BIAS=0/001$ می‌باشد. در مجموع می‌توان بیان نمود مدل رگرسیون بردار پشتیبان-موجک بهترین عملکرد و مدل رگرسیون بردار پشتیبان-خفاش ضعیف‌ترین عملکرد را دارا هستند. همچنین مقدار درصد بایاس برای ایستگاه هیدرومتری کشکان واقع در استان لرستان مقداری

مثبت داشته است و این به معنای ناچیز بودن خطای مدل می‌باشد. همچنین در اشکال ۵ و ۶ نمودار ضریب همبستگی و خطای مدل‌های هیبریدی مورد بررسی نشان می‌دهد مدل رگرسیون بردار پشتیبان-موجک نسبت به مدل‌های رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش دارای بیشترین ضریب همبستگی و کمترین میزان خطای محاسباتی می‌باشد. در شکل ۴ نمودار تغییرات سری زمانی و پراکنش مقادیر مشاهداتی و محاسباتی بیان شد در این شکل مدل رگرسیون بردار پشتیبان-موجک در برآورد نقاط ماکزیمم و مینیمم خطای کمتری دارد و همچنین مدل‌های رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش در برآورد مقادیر میانی و مینیمم از دقت مطلوبی برخوردار است بگونه ای که هر سه مدل هیبریدی مقادیر محاسباتی را نزدیک به مقادیر مشاهداتی برآورد نموده، که در این بین مدل WSVR عملکرد مناسب‌تری نسبت به سایر مدل‌ها دارد.

جدول (۲): انتخاب ترکیب ورودی بهینه بر اساس RMSE


Table (2): Selection of the optimal input combination based on RMSE

مدل	مرحله	۱	۲	۳	۴
WSVR	آموزش	۰/۰۹۴	۰/۰۸۶	۰/۰۷۵	۰/۰۶۳
	صحت‌سنجی	۰/۰۷۳	۰/۰۶۵	۰/۰۵۲	۰/۰۴۵
GWO-SVR	آموزش	۰/۱۰۱	۰/۰۹۷	۰/۰۸۴	۰/۰۷۸
	صحت‌سنجی	۰/۰۸۶	۰/۰۷۳	۰/۰۶۶	۰/۰۵۶
BA-SVR	آموزش	۰/۱۲۲	۰/۱۰۸	۰/۰۹۸	۰/۰۹۲
	صحت‌سنجی	۰/۱۰۱	۰/۰۹۶	۰/۰۸۸	۰/۰۸۲

جدول (۳): تحلیل نتایج مدل‌های هیبریدی مورد بررسی در ایستگاه هیدرومتری کشکان


Table (3): Analysis of the results of hybrid models studied in Kashkan hydrometric station

مدل	آموزش				صحت‌سنجی				
	MAE (m)	RMSE (m)	PBIAS	NS	MAE (m)	RMSE (m)	PBIAS	NS	
WSVR	۰/۰۳۷	۰/۰۶۳	۰/۹۴۵	۰/۰۰۲	۰/۰۲۴	۰/۰۴۵	۰/۹۶۰	۰/۹۶۸	۰/۰۰۱
GWO-SVR	۰/۰۴۸	۰/۰۷۸	۰/۹۲۷	۰/۰۰۳	۰/۰۳۲	۰/۰۵۶	۰/۹۴۷	۰/۹۵۲	۰/۰۰۲
BA-SVR	۰/۰۵۷	۰/۰۹۲	۰/۹۱۷	۰/۰۰۳	۰/۰۴۵	۰/۰۸۲	۰/۹۳۶	۰/۹۴۷	۰/۰۰۲




شکل (۴): نمودار پراکنش و مقادیر محاسباتی و مشاهداتی مدل های مورد بررسی

Figure (4): Distribution diagram and computational and observational values of the studied models



شکل (۵): نمودار ضریب همبستگی مدل‌های مورد بررسی

Figure (5): diagram of the correlation coefficient of the studied models



شکل (۶): نمودار درصد میزان خطای مدل‌های مورد بررسی

Figure (6): Graph percentage error of the studied models

۴- نتیجه‌گیری

در این تحقیق سعی بر آن شد عملکرد مدل‌هایی جهت شبیه‌سازی جریان روزانه رودخانه کشکان واقع در استان لرستان با استفاده از داده‌های روزانه مورد ارزیابی قرار گیرد. مدل‌های به کار گرفته شده شامل مدل‌های هیبریدی رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش است. مقادیر جریان مشاهداتی با جریان پیش‌بینی‌شده در مدل‌های مذکور (رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش)، با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج تحقیق را می‌توان به صورت زیر خلاصه نمود: نتایج نشان داد که در هر سه مدل موردبررسی شامل مدل هیبریدی رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش، در ساختاری متشکل از ۱ تا ۴ تأخیر زمانی نتایج بهتری نسبت به سایر ساختارها ارائه می‌دهد. همچنین با توجه به معیارهای ارزیابی نتیجه شد که هر سه مدل موردبررسی، می‌توانند با دقت نسبتاً بالایی میزان جریان روزانه رودخانه را پیش‌بینی نمایند. در این میان، مدل هیبرید ماشین بردار پشتیبان-موجک دقت بیشتر و خطای کمتری نسبت به مدل رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش از خود نشان داده است. همچنین دقت بالای مدل ترکیبی ناشی از استفاده از اصل استقرار کمینه‌سازی خطای ساختاری و تجزیه سیگنال است که با بکارگیری روش یادگیری با نظارت در توابع پایه شعاعی باعث می‌شود تخمین پارامتر از سرعت بالا و خطای کمتری نسبت به سایر کرنل‌ها برخوردار باشد. درمجموع این تحقیق نشان می‌دهد استفاده از مدل ترکیبی ماشین بردار پشتیبان-موجک می‌تواند در زمینه پیش‌بینی جریان روزانه رودخانه‌ها مؤثر باشد. همچنین، این مدل می‌تواند به نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های سطحی مفید باشد. و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود کمیت جریان رودخانه‌ها می‌باشد.

۵- منابع

- Adnan, R., Liang, Z., Heddarn, S., Kermani, M., Kisi, O., Li, B. (2019). Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology*, 19(4): 432-448.
- Alizadeh, F., Gharamaleki, A., Jalilzadeh, M., Akhoundzadeh, A. (2020). Prediction of river stage-discharge process based on a conceptual model using EEMD-WT-LSSVM. *Approach Water Resources*, 47: 41-53.
- Amuda, A., Brest, J., Mezura-Montes, E. (2013). Structured Population Size Reduction Differential Evolution with Multiple Mutation Strategies on CEC 2013 real parameter optimization. *In Proceedings of the IEEE Congress on Evolutionary Computation*, Cancun, Mexico, 1925-1931.
- Babaali, H., Dehghani, R. (2017). The Prediction of the Flood Peak Discharge Using a Wavelet Neural Network. *Journal of Hydrogeomorphology*, 4(11): 149-168. (In Persian).
- Basak, D., Pal, S., and Patranabis, D.C. (2007). Support vector regression. *Neural Inf Process*, 11(2): 203-225.
- Dehghani, R., Torabi, H. (2021). Applying hybrid artificial algorithms to the estimation of river flow: a case study of Karkheh catchment area. *Arabian Journal of Geosciences*, 14: 768-780
- Dehghani, R., Torabi, H., Younesi, H., Shahinejad, B. (2020). Application of Hybrid Support Vector machine models in Predicting River Flow Karkhe basin. *Journal of Hydrogeomorphology*, 7(22): 155-175. (In Persian).
- Dehghani, R., Younesi, H., Torabi Poudeh, H. (2016). Comparing the performance of Support Vector Machines, Gene Expression Programming and Bayesian networks in predicting river flow (Case study: Kashkan River), *Journal of Soil and Water Conservation Research*, 24(4):161-177. (in Persian).
- Ghorbani, M.A., Deo, R., Karimi, V., Yassen, Z.M., Terzi, O. (2018). Implementation of a hybrid MLP-FFA model for water level prediction of Lake Egirdir, Turkey, *Stochastic, Environmental Research and Risk Assessment*, 32(6), 1683-1697.
- Ghorbani, M.A., Khatibi, R., Karimi, V., Yaseen, Z.M., Zounemat-Kermani, M. (2018). Learning from multiple models using artificial intelligence to improve model prediction accuracies: Application to River Flows, *Water Resour Management*, 32(13): 4201-4215.
- Hamel, L. (2009). *Knowledge discovery with support vector Machines*, Hoboken, N.J. John Wiley.
- Kisi, O., Karahan, M., and Sen, Z. (2006). River suspended sediment modeling using fuzzy logic approach, *Hydrology of Process*, 20(2): 4351-4362.

- Misra, D., Oommen, T., Agarwa, A., Mishra, S.K., and Thompson, A.M. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield, *Biosyst Eng*, 103(3): 527-535.
- Nagy, H., Watanabe, K., and Hirano, M. (2002). Prediction of sediment load concentration in rivers using artificial neural network model, *Journal of Hydraulics Engineering*, 128(3): 558-559.
- Ostu, N. (1979). A Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man and Cybernetics*, 9 (1): 62-66.
- Salehi, M., Radmanesh, F., Zarei, H., Mansouri, B., Solgi, A. (2016). A combined Time Series – Wavelet Model for Prediction of Ground Water Level (Case Study: Firuzabad Plain), *Irrigation Science and Engineering*, 41(4): 1-16. (in Persian)
- Shin, S., Kyung, D., Lee, S., Taik & Kim, J., and Hyun, J. (2005). An application of support vector machines in bankruptcy prediction model, *Expert Systems with Applications*, 28(4): 127-135.
- Vapnik, V., and Chervonenkis, A. (1991). The necessary and sufficient conditions for consistency in the empirical risk minimization method, *Pattern Recognition and Image Analysis*, 1(3): 283-305.
- Vapnik, V.N. (1995). *The Nature of Statistical Learning Theory*. Springer, New York
- Vapnik, V.N. (1998). *Statistical learning theory*. Wiley, New York.
- Wang, D., Safavi, A.A., and Romagnoli, J.A. (2000). Wavelet-based adaptive robust M-estimator for non-linear system identification, *AIChE Journal*, 46(4): 1607-1615.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O., and Lee, K.K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer, *Journal of Hydrol*, 396(4): 128-138.