شریه پژوهش‌های اقلیم شناسی
سال شانزدهم | شماره شصت و سه | پاییز ۱٤۰٤
وصول: ۱٤۰۳/۰۹/۲٦ پذیرش: ۱٤۰٤/۰۲/۱٦
صص ۱۱۹-۱۰۹

ارزیابی مدل‌های هیبریدی فرا ابتکاری در برآورد دبی سیلابی ناشی از بارش مؤثر (مطالعه موردی: رودخانه کاکارضا استان لرستان)

حمیدرضا علی بابا*[۱]، ابراهیم نوحانی[۲]، امین پورحقی[۳]
۱- دانشیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم آباد، لرستان، ایران.
۲- استادیار گروه عمران، مرکز تحقیقات مواد و انرژی، واحد دزفول، دانشگاه آزاد اسلامی، دزفول، ایران.
۳- کارشناسی ارشد زمین شناسی، دانشکده علوم پایه، دانشگاه لرستان، ایران.

چکیده

کشور ایران تقریباً هرساله با خسارات جانی و مالی قابل‌توجهی از سیل روبرو می‌شود .بنابراین، هدف این مطالعه ارائه اطلاعات به‌موقع و بسیار دقیق پیش‌بینی سیل با استفاده از یک مدل ترکیبی توسعه‌یافته با ترکیب مدل بارش-رواناب و مدل مبتنی بر هوش مصنوعی است.در این پژوهش، بمنظور برآورد دبی سیلابی رودخانه کاکارضا واقع در استان لرستان از مدل هیبریدی رگرسیون بردار پشتیبان با الگوریتم‌های موجک، کرم شب‌تاب و خفاش در طی دوره زمانی ۱۴۰۲-۱۳۹۲ استفاده شد. پارامترهای بارش متناظر با هر دبی سیلابی در مقیاس زمانی روزانه بعنوان ورودی مدل بکار برده شد. به‌منظور ارزیابی عملکرد مدل‌ها از معیارهای ارزیابی ضریب همبستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش ساتکلیف استفاده شد. همچنین جهت تحلیل نتایج مدل‌ها از نمودار سری زمانی، باکس پلات و تیلور استفاده شد. نتایج نشان داد سناریوهای ترکیبی در مدل‌های موردبررسی باعث بهبود عملکرد مدل می‌شود. مقایسه نتایج نشان داد مدل رگرسیون بردار پشتیبان – کرم شب‌تاب عملکرد بهتری نسبت به مدل رگرسیون بردار پشتیبان-خفاش در مدل‌سازی دارد، بگونه ای که مدل رگرسیون بردار پشتیبان – موجک با ضریب همبستگی ۰/۹۸۰، کمترین ریشه میانگین مربعات (m^3/s) ۰/۱۶۸، کمترین میانگین قدر مطلق خطا (m^3/s) ۰/۰۸۸ و بیشترین ضریب نش ساتکلیف ۰/۹۸۵ در مرحله صحت سنجی در اولویت قرار گرفت. درمجموع نتایج نشان داد استفاده از مدل‌های هوشمند مبتنی بر رویکرد رگرسیون بردار پشتیبان می‌تواند رویکردی مؤثر در مدیریت سیلاب‌ها باشد.

کلید واژه‌ها: پیش‌بینی، دبی سیلابی، رگرسیون بردار پشتیبان، کاکارضا.

* نویسنده مسئول: ۰۹۰۳۵۸۲۶۹۱۱
Email: hr.babaali91@gmail.com

مقدمه

سیل یک پدیده طبیعی است که می‌تواند اثرات مخربی بر جوامع و اکوسیستم‌ها داشته باشد و آن را به نگرانی قابل توجهی برای آمادگی و مدیریت بلایا تبدیل می‌کند (Jonkman.2005). این پدیده می‌تواند آسیب قابل‌توجهی به محیط زیست و زندگی انسان وارد کند و درنتیجه به اموال و زیرساخت‌ها آسیب وارد نموده و نیز می‌تواند به‌تدریج یا ناگهانی رخ دهد و منجر به سیل ناگهانی شود (Bhusal et al.,2022). عوامل مختلفی مانند گرم شدن کره زمین، تغییر کاربری زمین و پوشش زمین و شهرنشینی می‌توانند تأثیر و فراوانی رویدادهای سیل را تشدید کنند (Jordan and Mitchell.,2015). یکی از جنبه‌های مهم درک و مدیریت سیل، گرفتن دینامیک رواناب است که یکی از عوامل اصلی رویدادهای سیل است. ارزیابی دقیق خطر سیل به تخمین دقیق اوج رواناب، که از طریق شبیه‌سازی بارش-رواناب تعیین می‌شود، متکی است (Asefa et al.,2006). پیش‌بینی دبی دقیق یک عامل حیاتی در کنترل سیل و کاهش آسیب به محیط‌زیست و زیرساخت‌ها است (Halwatura et al.,2013). باگذشت زمان، محققان روش‌های مختلفی را برای شبیه‌سازی رواناب در حوزه‌های آبخیز کشف کرده‌اند . در سالهای اخیر بدلیل ماهیت غیرخطی و پیچیده مسائل هیدرولوژیکی از مدل‌های مبتنی بر رویکرد هوش مصنوعی استفاده نمودند. این مدل‌ها از طبیعت موجودات زنده الهام گرفته و قادرند مسائل با پیچیدگی و گستردگی فراوان را حل نمایند. این مدل‌ها درزمینهٔ پیش‌بینی دبی سیلابی زیرزمینی موردتوجه محققین قرارگرفته است که می‌توان به موارد زیر اشاره نمود.

Samantary et al (2023) در پژوهشی به ارزیابی عملکرد مدل‌های ماشین بردار پشتیبان(SVM) ، شبکه عصبی پس انتشار (BPNN) و ادغام SVM با مدل‌های بهینه‌سازی ازدحام ذرات(PSO-SVM) جهت پیش‌بینی دبی سیلابی پرداختند در این پژوهش از آمار و اطلاعات تخلیه ماهانه جریان رودخانه باراک واقع در کشور هند برای یک دوره ۱۹۶۹ – ۲۰۱۸ بهره گرفتند نتایج نشان داد مدل هیبریدی رگرسیون بردار پشتیبان نسبت به سایر مدل‌های موردبررسی و مدل منفرد خود از دقت بیشتری برخوردار است.

Rajab et al (2023) در پژوهشی جهت پیش‌بینی دبی سیلابی رودخانه کشور بنگلادش از مدل‌های رگرسیون چندجمله‌ای، رگرسیون جنگل تصادفی، حافظه کوتاه‌مدت بلندمدت(LSTM) و رگرسیون بردار پشتیبان استفاده نمودند نتایج نشان داد مدل رگرسیون بردار پشتیبان عملکرد قابل قبولی در پیش‌بینی دبی سیلابی دارد.

Kim et al (2024) در پژوهشی جهت بررسی عملکرد مدل‌های هوش مصنوعی هیبریدی مبتنی بر رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی از الگوریتم‌های ژنتیک، کرم شب تاب و جستجوی الگو جهت پیش‌بینی دبی سیلابی رودخانه هیماچال واقع در ویتنام استفاده کردند نتایج نشان داد مدل رگرسیون بردار پشتیبان-کرم شب‌تاب نسبت به سایر مدل‌های موردبررسی از عملکرد بهتری برخوردار است.

Asadollahi et al (2024) در پژوهشی به منظور پیش‌بینی دبی سیلابی رودخانه دوپیچ واقع در ایالات‌متحده از مدل‌های یادگیری ماشین(ML)، شبکه عصبی مصنوعی (ANN) و رگرسیون بردار پشتیبان(SVR) استفاده کردند. در این پژوهش داده‌های تاریخی از سال ۲۰۰۶ تا ۲۰۲۱ برای ارزیابی عملکرد مدل‌ها مورداستفاده قرار گرفت .نتایج نشان داد مدل رگرسیون بردار پشتیبان عملکرد بهتری نسبت به سایر مدل‌های مورد بررسی در پیش‌بینی دبی سیلابی دارد. درمجموع با توجه به پژوهش‌های انجام‌شده، مدل هوش مصنوعی رگرسیون بردار پشتیبان بعنوان ابزاری کارآمد در برآورد دبی سیلابی می‌باشد. امروزه بمنظور افزایش کارایی و بهبود عملکرد مدل رگرسیون بردار پشتیبان، از ترکیب این مدل با الگوریتم‌های فرا ابتکاری بعنوان یک راهکاری مناسب جهت پیش‌بینی دبی سیلابی استفاده می‌شود. در این پژوهش نیز از مدل‌های هیبریدی رگرسیون بردار پشتیبان-کرم شب‌تاب و رگرسیون بردار پشتیبان-گرگ خاکستری جهت تخمین دبی سیلابی رودخانه کاکارضا واقع در استان لرستان استفاده شد. این رودخانه ازجمله مهم‌ترین رودخانه‌های استان لرستان به لحاظ گردشگری، تولید محصولات کشاورزی، محصولات آبزی و شرب است که در سیلاب‌های سال‌های گذشته اثرات زیانبار اقتصادی ساکنین نواحی این رودخانه متحمل شده‌اند. بنابراین تحلیل و بررسی دبی سیلابی این رودخانه امری لازم و ضروری است. از طرف دیگر اگرچه استفاده از مدل رگرسیون بردار پشتیبان بطور گسترده برای پیش‌بینی دبی سیلابی این منطقه استفاده‌شده است. تاکنون پژوهشی درزمینهٔ استفاده و مقایسه الگوریتم‌های فرا ابتکاری گرگ خاکستری و کرم شب‌تاب در این منطقه انجام‌نشده است. بنابراین در این

پژوهش از الگوریتم‌های بهینه‌سازی باهدف ترکیب با مدل رگرسیون بردار پشتیبان برای برآورد دبی سیلابی استفاده شد.

مواد و روش‌ها

منطقه موردمطالعه و داده‌های مورداستفاده

منطقه موردمطالعه ایستگاه کاکارضا واقع در استان لرستان می‌باشد. این ایستگاه در رودخانه‌ای بنام کاکارضا در استان لرستان که از رودخانه‌های دائمی استان لرستان بوده و از کوه‌های جنوب شرقی شهرستان الشتر و بخش چغلوندی (هرود) سرچشمه گرفته و در محدوده شهرستان الشتر بنام کاکارضا معروف است، قرارگرفته است. این رودخانه بین ″۱۵ ° ۴۸ تا ° ۴۹ درجه طول شرقی و ″ ۲۲ ° ۳۲ الی″ ۵۲ ° ۳۳ درجه عرض شمالی و در استان لرستان و شرق شهرستان خرم‌آباد واقع‌شده است و قسمتی از سرشاخه‌های رودخانه کرخه را در زاگرس تشکیل می‌دهد. رودخانه کاکارضا در ارتفاع ۱۵۵۰ متری از سطح آب‌های آزاد قرار دارد. مساحت حوضه کاکارضا ۱۱۴۸ کیلومترمربع و دارای رودخانه‌ای به طول ۸۵ کیلومتر می‌باشد. رودخانه کاکارضا پس از پیوستن به رودخانه‌های کشکان، سیمره و کرخه، درنهایت به خلیج‌فارس می‌ریزد. که در شکل (۱) موقعیت جغرافیایی منطقه موردمطالعه نشان داده‌شده است. در این پژوهش به‌منظور مدل‌سازی دبی سیلابی حوزه آبخیز کاکارضا واقع در استان لرستان آمار و اطلاعات روزانه شامل دبی و بارش ایستگاه هیدرومتری کاکارضا در طی دوره آماری ۱۴۰۲-۱۳۹۲ استفاده شد بدین منظور ۳۶۵۰ داده ایجاد شد و جهت شبیه‌سازی دبی سیلابی و برآورد آن سیلاب‌های این دوره زمانی ده‌ساله استخراج و بررسی گردید، بگونه ای که بارش متناظر با سیلاب نیز از آمار و اطلاعات استخراج و مجموعاً ۱۲۲ مقادیر سیلابی حاصل شد. لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت آزمون، به‌صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد.

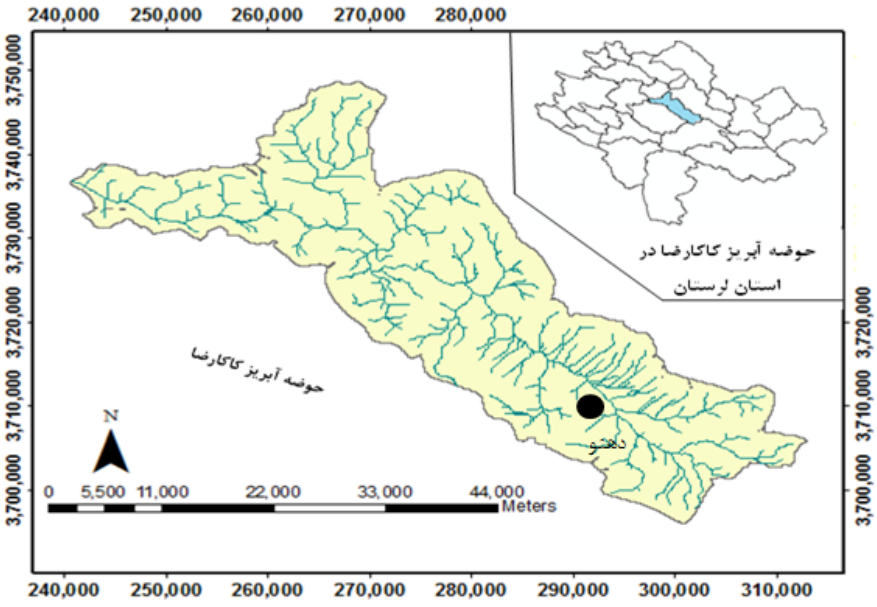

شکل ۱- منطقه موردمطالعه

رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان یکی از روش‌های هوش مصنوعی می‌باشد که بر مبنای تئوری بهینه‌سازی و از قانون کمینه‌سازی خطا پیروی می‌نماید که این امر سبب می‌گردد به یک جواب بهینه کلی منجر شود (vapnik.1995). در مدل رگرسیون SVR که شامل تابعی است با متغیرهای وابسته Y می‌باشد که این متغیر وابسته از چند متغیر مستقل X و مقداری خطا تشکیل‌شده است . همانطور که در مسائل رگرسیون مشاهده می‌شود میان متغیر وابسته و مستقل رابطه جبری مانند زیر وجود دارد که در ساختار مدل رگرسیون بردار پشتیبان به‌صورت زیر می‌باشد(Vapnik.1998).

$$f(x)=W^{T}.\emptyset(x)+b \quad (۱)$$

$$y=f(x)+noise \quad (۲)$$

رگرسیون بردار پشتیبان همانند مدل‌های هوش مصنوعی دارای توابع محرکی بوده که کرنل نام دارند این کرنل‌ها شامل کرنل چندجمله‌ای و کرنل توابع پایه شعاعی (RBF) و کرنل خطی می‌باشند و مطابق روابط زیر برآورد می‌شوند(Vapnik and Chervonenkis.1991; Basak et al.,2007). در این پژوهش نیز از این سه تابع کرنل استفاده شد. همچنین مدل رگرسیون بردار پشتیبان در نرم‌افزار متلب کد نویسی شد.

$$k(x,x_j)=(t+x_i.x_j)^d \quad (۳)$$

$$K(x,x_i)=\exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (٤)$$

$$k(x,x_j)=x_i.x_j \quad (۵)$$

سناریو خفاش

هوش جمعی یکی از قوی‌ترین تکنیک‌های بهینه‌سازی می‌باشد که بر مبنای رفتارهای گروهی است (Amuda, 2013). سناریو خفاش از دسته سناریوهای فراشناختی است که الهام گرفته از رفتار جمعی خفاش‌ها در محیط طبیعی است که در سال ۲۰۱۰ توسط یانگ ارائه شد. این سناریو برمبنای استفاده از خاصیت انعکاس صدا توسط خفاش‌ها است. خفاش‌ها مسیر و محل دقیق طعمه خود را بوسیله 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 ببیند. با استفاده از این سیستم، خفاش‌ها می‌توانند اجسام متحرک مثل حشرات و اجسام بی‌حرکت مثل درختان را تشخیص دهند(Amuda,2013).

سناریو خفاش مبتنی بر ویژگی پژواکیابی 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. پژواکیابی 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(Amuda,2013).

قوانین سناریو خفاش این قوانین می‌تواند به زبان ساده به صورت زیر بیان شود:

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

خفاش‌ها به‌صورت تصادفی با سرعت Vi در موقعیت Xi با فرکانس ثابت fmin با طول‌موج متغیر λ و بلندی صدای A0 در جست‌وجوی شکار هستند. آن‌ها می‌توانند به‌طور اتوماتیک طول موج پالس‌های منتشرشده از خود را تنظیم کرده و نرخ انتشار پالس خود یعنی $r \in (۱,۰)$ 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 (مثبتA0) تا یک مقدار مینیمم ثابت یعنی Amin تغییر کند.

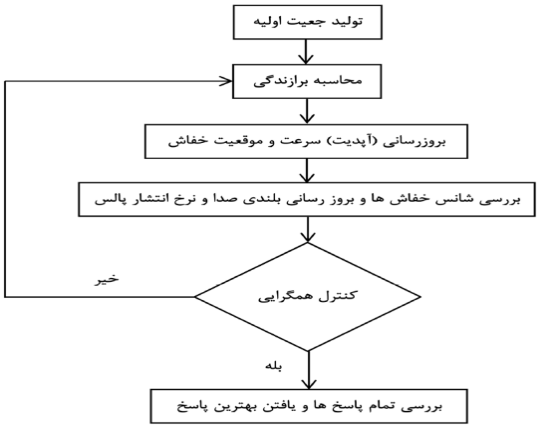

شکل ۲- فلوچارت سناریو بهینه‌سازی خفاش

الگوریتم کرم شب‌تاب

الگوریتم کرم شب‌تاب ازجمله الگوریتم‌های بهینه‌سازی می‌باشد که از رفتار موجودات زنده الهام گرفته شده است. این الگوریتم ازجمله الگوریتم‌های فرا ابتکاری بوده که در حل مسائل پیچیده بسیار کارایی دارد. این الگوریتم از رویکرد گروهی الهام گرفته بصورتی که از حالت نور افشانی کرم‌های شب تاب جهت حل مسائل استفاده می‌شود(Yang.2008). در الگوریتم کرم شب‌تاب هر راه‌حل مسئله به‌صورت یک کرم شب‌تاب در نظر گرفته می‌شود و کرم‌های شب‌تاب برحسب شایستگی می‌توانند از خود نور تولید و سایر کرم‌های شب تاب را به سمت خود جذب نمایند. این الگوریتم، یک الگوریتم بهینه‌سازی جمعیت محور و تصادفی می‌باشد که اولین بار توسط یانگ به جامعه علمی معرفی شد (Yan et al.,2012). این الگوریتم بر مبنای رفتار کرم‌های شب‌تاب در جذب جفت عمل می-کند. سه فرضیه اساسی این الگوریتم بصورت زیر است.

الف) برای کرم‌های شب‌تاب جنسیت خاصی در نظر گرفته نمی‌شود.

ب) هر کرم شب‌تاب به کرم‌های شب‌تاب دیگر با توجه به شدت نور آن‌ها جذب می‌شود.

ج) در مسائل ماکزیمم سازی میزان شدت نور با تابع هدف رابطه مستقیم دارد و در مسائل مینیمم سازی شدت نور با تابع هدف رابطه عکس دارد.

میزان جذابیت کرم‌های شب‌تاب نسبی بوده و به فاصله بین دو کرم شب‌تاب و ضریب جذب نور بستگی دارد که از رابطه زیر قابل محاسبه است.

$$\beta(r) = \beta_0 e^{-\gamma r_{ij}^2} \quad (٦)$$

در ای رابطه β، میزان جذابیت کرم درخشیان تر در r=0 است r (فاصله کرم شب‌تاب کم‌نور نسبت به کرم شب‌تاب پرنورتر است). موقعیت کرم i ام پس از حرکت به سمت کر j ام که درخشان‌تر است از رابطه زیر محاسبه می‌گردد

$$X_{id}(t+1) = X_{id}(t) + \beta_0 e^{-\gamma r_{ij}^2}\left(X_{jd}(t) - X_{id}(t)\right) + \alpha\left(rand - \frac{1}{2}\right) \quad (٧)$$

$$r_{ij} = \|X_i - X_j\| \quad (٨)$$

Rand عدد تصادفی بین ۰ و ۱ است و α بین ۰ و ۱ است و پارامتر تصادفی سازی نامیده می‌شود. در شکل زیر فلوچارت این الگوریتم نشان داده شده است.

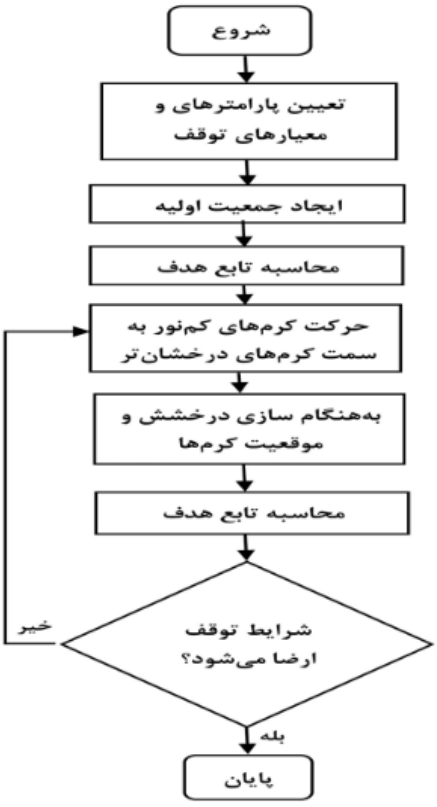

شکل ۳- فلوچارت الگوریتم کرم شب‌تاب

تبدیل موجک

تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه‌ی زمان کوتاه ارائه شده است و هدف از ارائه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه زمان کوتاه، سیگنال موردنظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هرکدام از این پنجره‌ها به‌صورت جداگانه انجام می‌گیرد(Wang et al.,2000). 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 به‌جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان – مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط‌شده و جزئیات سیگنال قابل تجزیه‌وتحلیل است و در مقیاس‌های پایین سیگنال منقبض‌شده و کلیات سیگنال قابل بررسی می‌باشد. 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 مقیاس شده سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند(Nourani et al.,2018). بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نا مانا و گذرا را به‌صورت موضعی مورد تجزیه‌وتحلیل قرارداد(shin et al.,2005).

معیار ارزیابی

در این پژوهش جهت ارزیابی مدل‌های موردبررسی بمنظور پیش‌بینی دبی سیلابی از شاخص‌های ارزیابی زیر استفاده شد.

$$R=\frac{\sum_{i=1}^{N}(x_i-\bar{x})\,(y_i-\bar{y})}{\sqrt{\sum_{i=1}^{N}(x_i-\bar{x})^2\ \sum_{i=1}^{N}\ (y_i-\bar{y})^2}}\quad 1\le R\le 1 \qquad (۹)$$

$$RMSE=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\ (x_i-y_i)^2} \qquad (۱۰)$$

$$MAE=\frac{\sum_{i=1}^{n}|x_i-y_i|}{n} \qquad (۱۱)$$

$$NS=1-\frac{\sum_{i=1}^{N}(x_i-y_i)^2}{\sum_{i=1}^{N}(x_i-\bar{y})^2}\quad \infty\le NS\le 1 \qquad (۱۲)$$

در روابط بالا،R ضریب همبستگی، $RMSE$ ریشه میانگین مربعات خطا برحسب mm، NS معیار نش ساتکلیف، x_i وy_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی iام، Nتعداد گام‌های زمانی، $\bar{x}$ و$\bar{y}$ 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 مقایسه و تحلیل بیشتر استفاده می‌گردد.

نتایج و بحث

در این پژوهش به‌منظور مدل‌سازی دبی سیلابی رودخانه کاکارضا واقع در استان لرستان از مدل رگرسیون بردار پشتیبان با الگوریتم‌های موجک، خفاش و کرم شب‌تاب استفاده شد. پارامتر بارش متناظر با دبی سیلابی بعنوان ورودی مدل و پارامتر دبی سیلابی بعنوان خروجی مدل در دوره زمانی روزانه، سال ۱٤۰۲-۱۳۹۲ بکار برده شد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آن‌ها در طبیعت کاری دشوار با عدم قطعیت بالا است. دبی سیلابی از پارامترهای مهم هیدرولوژیکی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر دبی سیلابی با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکرشده مورداستفاده قرار گرفت که در مقایسه با روش‌های تقریبی به‌مراتب عملکرد بهتری را ارائه می‌نماید. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هیدرولوژیکی و ارائه مدل جهت پیش‌بینی در آینده است و ازآنجایی‌که دبی سیلابی از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر به‌عنوان متغیر هدف انتخاب شد. جهت مدل‌سازی۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد(Nagy et al.,2002; Kisi et al.,2006).

به منظور مدل‌سازی دبی سیلابی رودخانه کاکارضا واقع در استان لرستان از مدل رگرسیون بردار پشتیبان با الگوریتم‌های

موجک، خفاش و کرم شب‌تاب استفاده شد. همچنین در مدل رگرسیون بردار پشتیبان از توابع محرکی که کرنل نام دارند، استفاده شد این توابع شامل توابع پایه شعاعی، پلیگونی و خطی می‌باشد که در این پژوهش موردبررسی قرار گرفت. بدین منظور مقادیر پارامتر بارش ایستگاه هیدرومتری کاکارضا نرمال‌سازی شده سپس وارد مدل رگرسیون بردار پشتیبان می‌شود. در سالهای اخیر به دلیل آنکه در مدل رگرسیون بردار پشتیبان مقادیر پارامترهای تنظیم توابع کرنل بصورت تصادفی انتخاب می‌گردند از الگوریتم‌های بهینه‌سازی جهت افزایش دقت و کاهش خطای مدل استفاده‌شده است(Dehghani and Torabi.2021). در این پژوهش نیز جهت افزایش عملکرد مدل از الگوریتم‌های موجک، خفاش و کرم شب‌تاب جهت بهینه نمودن مقادیر پارامترهای تنظیم استفاده شد. بنابراین در این پژوهش بعد از ورود اطلاعات پارامترهای ورودی به مدل و بهینه نمودن پارامترهای تنظیم ساختار مدل هیبریدی شکل‌گرفته و منجر به پاسخ محاسباتی مدل می‌گردد از انجاییکه معیار توقف در آموزش مدل‌های هوش مصنوعی میزان خطا می‌باشد بنابراین مدل در کمترین میزان خطا متوقف و خروجی حاصل می‌گردد.

همان‌طور که در جدول ۱ مشخص است کلیه مدل‌ها در تابع کرنل پایه شعاعی از دقت بهتری برخوردار هستند. نتایج مدل‌های مورد بررسی در جدول ۱ نشان داده شده است همان طور که در جدول مشخص است مدل رگرسیون بردار پشتیبان- موجک با بیشترین ضریب همبستگی ۰/۹۸۰، کمترین ریشه میانگین مربعات **(m^3/s)** ۰/۱۶۸، کمترین میانگین قدر مطلق خطا **(m^3/s)** ۰/۰۸۸ و بیشترین ضریب نش ساتکلیف ۰/۹۸۵ در مرحله صحت سنجی عملکرد بهتری از خود نشان داده است.

در شکل ٤ نمودار سری زمانی مقادیر مشاهداتی و محاسباتی نشان داده‌شده است همان‌طور که مشاهده می‌گردد مدل رگرسیون بردار پشتیبان- موجک نسبت به مدل‌های هیبریدی رگرسیون بردار پشتیبان- خفاش و رگرسیون بردار پشتیبان- کرم شب‌تاب در تخمین اکثر نقاط ازجمله مینیمم، ماکزیمم و میانی دقت قابل قبولی از خود نشان داده است همچنین مدل رگرسیون بردار پشتیبان- کرم شب‌تاب نیز از عملکرد مناسبی در تخمین اکثر نقاط برخوردار است اما مدل رگرسیون بردار پشتیبان- خفاش در تخمین مقادیر میانی عملکرد نسبتاً مطلوبی داشته است و در تخمین مقادیر مینیمم و ماکزیمم ضعیف عمل نموده است.

همانطور که در شکل ٤ قابل‌مشاهده است مدل رگرسیون بردار پشتیبان-موجک نسبت به خط نیمساز (Y=X) کلیه مقادیر را نزدیک به مقدار واقعیشان تخمین زده است. این مدل نسبت به سایر مدل‌های موردبررسی عملکرد بهتری داشته زیرا تبدیل موجک WT با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل‌توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد، بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرمتر می‌شود (Wang et al,2000)، بر همین اساس مدل رگرسیون بردار پشتیبان-موجک نسبت به سایر مدل‌ها ارجح‌تر است.

نمودار جعبه‌ای دبی سیلابی در شکل ۵ نشان می‌دهد که مدل رگرسیون بردار پشتیبان-موجک مطابقت مناسبی با دبی سیلابی مشاهداتی دارد. همچنین رگرسیون بردار پشتیبان- خفاش و رگرسیون بردار پشتیبان- کرم شب‌تاب کمترین تطابق و همخوانی را دارا می‌باشند. همین نتیجه برای پیش‌بینی حداقل دبی سیلابی مشاهداتی مشاهده گردید.

همچنین طبق شکل ۵ مدل رگرسیون بردار پشتیبان-موجک در برآورد کلیه مقادیر (مینیمم، ماکزیمم، میانه، چارک اول و سوم) نسبت به سایر مدل‌ها از عملکرد بهتری برخوردار بود زیرا این مقادیر را نزدیک به مقادیر محاسباتی برآورد نموده است. همانطور که در این شکل مشهود است مدل رگرسیون بردار پشتیبان-کرم شب‌تاب در تخمین مقادیر چارک سوم عملکرد مطلوبی داشته است اما مدل رگرسیون بردار پشتیبان- خفاش ضعیف عمل کرده است و مدل‌های موردبررسی در تخمین نقاط میانه عملکرد مطلوبی نداشته‌اند.

نمودار عملکرد مدل تیلور مدل‌های موردبررسی در شکل ٦ نشان می‌دهد که مدل رگرسیون بردار پشتیبان-موجک دارای بالاترین کارایی و عملکرد بوده است، زیرا انحراف معیار

پیش‌بینی‌شده دبی سیلابی نزدیک‌ترین فاصله به انحراف استاندارد داده‌های مشاهداتی را دارد و ضریب همبستگی نیز بالاترین میزان را نشان می‌دهد. با توجه به تمام معیارهای ارزیابی در کنار هم، مدل رگرسیون بردار پشتیبان–موجک بالاترین قدرت پیش‌بینی و مدل رگرسیون بردار پشتیبان– خفاش و رگرسیون بردار پشتیبان– کرم شب‌تاب قابلیت پیش‌بینی کمتری دارد. همانطور که در شکل ٦ مشاهده می‌گردد مدل رگرسیون بردار پشتیبان–موجکبیشترین ضریب همبستگی را داشته و مدل‌های رگرسیون بردار پشتیبان– کرم شب‌تاب و رگرسیون بردار پشتیبان– خفاش عملکرد مطلوبی نداشته و به ترتیب در رتبه دوم و سوم قرار می‌گیرند.

بنابراین مدل رگرسیون بردار پشتیبان–موجک نسبت به سایر مدل‌های موردبررسی از عملکرد بهتری برخوردار است که این نتایج با پژوهش‌های فوق مطابقت دارد(Zeidalinejad and Dehghani.2023; Babaali and Dehghani.2023).

در تحلیل این نتایج می‌توان بیان داشت برتری این مدل ناشی از تبدیل موجک می‌باشد که سیگنال‌های دریافتی را به دودسته بالا گذر و پایین گذر تقسیم نموده و در دسته بالاگیر قدرت تفکیک افزایش‌یافته که سبب می‌گردد مقادیر بیشینه سیگنال با دقت مطلوبی تجزیه‌وتحلیل گردد.

مدل رگرسیون بردار پشتیبان– الگوریتم کرم شب‌تاب ترکیبی از بهینه‌سازی پیوسته و گسسته است که زمان رسیدن به یک راه‌حل بهینه را در یک منطقه جستجوی وسیع کاهش می‌دهد زیرا از راه‌حل‌های بهینه محلی اجتناب می‌کند. این امر باعث می‌شود که الگوریتم برای حل مسائل غیرخطی با ابعاد بزرگ با سرعت مناسب در همگرایی به سمت یک جواب بهینه قابل‌قبول باشد. که این امر سبب گردیده این مدل از دقت بالایی نسبت به سایر مدل‌ها برخوردار باشد.

به‌طورکلی پیشنهاد می‌شود از مدل هیبریدی رگرسیون بردار پشتیبان–موجک و کرم شب‌تاب به‌عنوان مدلی با خطای ناچیز برای حل مسائل غیرخطی با ابعاد بزرگ با سرعت مناسب در همگرایی به سمت یک جواب بهینه استفاده شود . همچنین می‌توان بعنوان راهکاری نوین در پیش‌بینی دبی سیلابی منظور اتخاذ تصمیمات مدیریتی مناسب برای بهبود مدیریت سیلاب دانست.

جدول ۱- نتایج مدل‌های موردبررسی

مدل	کرنل	آموزش				صحت سنجی			
		R	RMSE (m^3/s)	MAE (m^3/s)	NS	R	RMSE (m^3/s)	MAE (m^3/s)	NS
WSVR	RBF	۰/۹۵۱	۰/۳٤٤	۰/۱۷۱	۰/۹۷۰	۰/۹۸۰	۰/۱٦۸	۰/۰۸۸	۰/۹۸۵
	Poly	۰/۹٤۲	۰/۳۵۲	۰/۱۷۸	۰/۹٦۰	۰/۹٦٦	۰/۱۷۳	۰/۰۹۵	۰/۹۷۰
	Line	۰/۹۳۵	۰/۳٦۱	۰/۱۸٤	۰/۹٤۰	۰/۹۵۲	۰/۱۸۲	۰/۱۰۲	۰/۹٦۰
FA-SVR	RBF	۰/۹٤٤	۰/۳٤۸	۰/۱۷۵	۰/۹۵۵	۰/۹٦۰	۰/۱۷٤	۰/۰۹٤	۰/۹٦۵
	Poly	۰/۹۲۷	۰/۳۵۵	۰/۱۸۸	۰/۹۳۷	۰/۹٤۰	۰/۱۸۵	۰/۱۰۱	۰/۹۵۵
	Line	۰/۹۱۵	۰/۳٦۷	۰/۱۹۳	۰/۹۲۵	۰/۹۳۳	۰/۱۹۱	۰/۱۱۲	۰/۹٤۰
BAT-SVR	RBF	۰/۹۳٦	۰/۳۵٦	۰/۱۸۲	۰/۹٤۸	۰/۹٤۰	۰/۱۸۰	۰/۱۰۰	۰/۹٤۵
	Poly	۰/۹۲۰	۰/۳٦۸	۰/۱۹۰	۰/۹۲۵	۰/۹۳۲	۰/۱۹۲	۰/۱۰۸	۰/۹۳۰
	Line	۰/۹۱۰	۰/۳۷۲	۰/۱۹۸	۰/۹۲۰	۰/۹۲۲	۰/۲۰۲	۰/۱۲۰	۰/۹۲۵

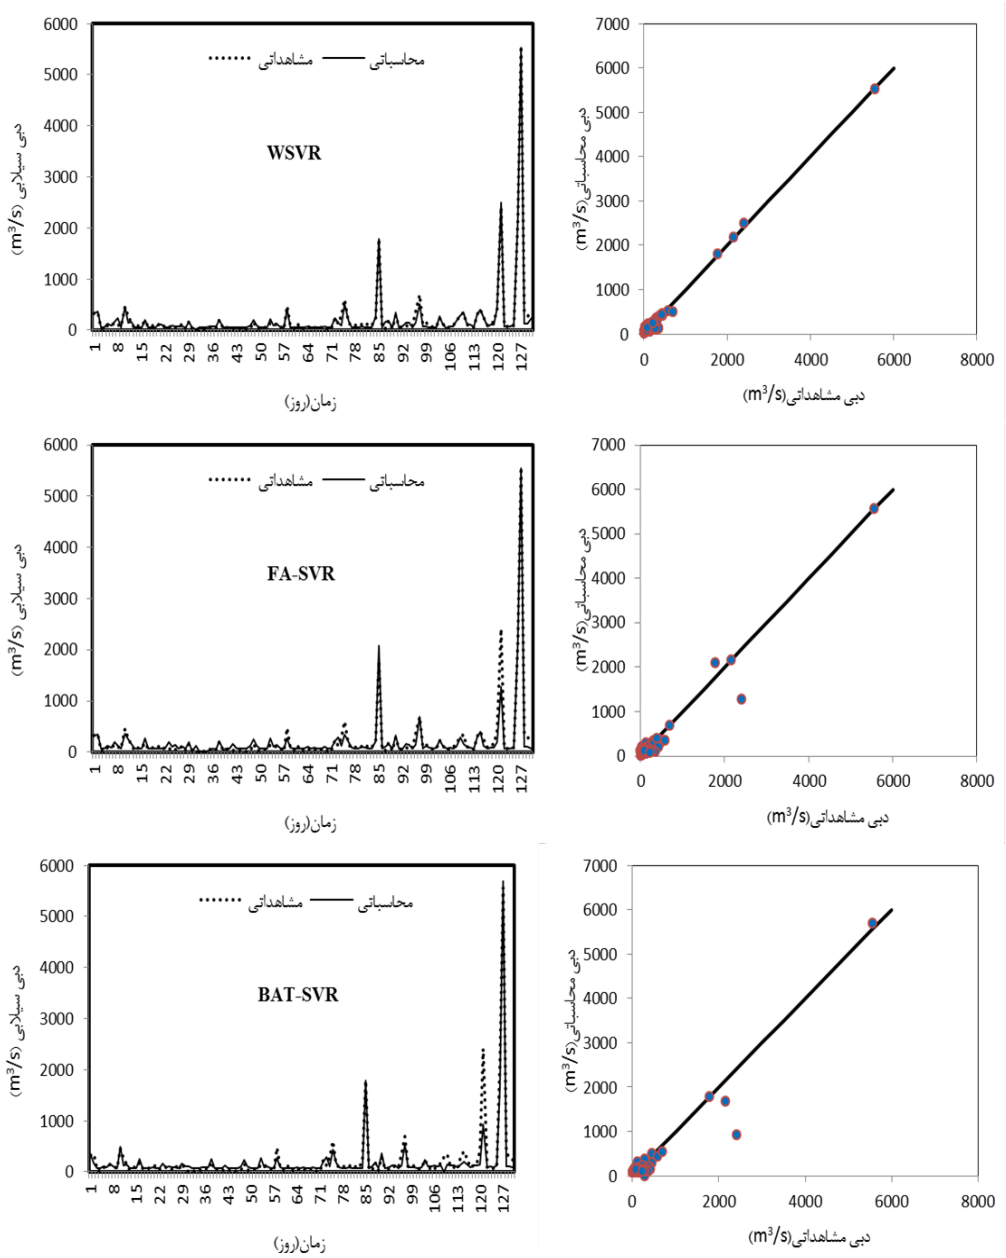

شکل ٤- نمودار سری زمانی مدل‌های موردبررسی

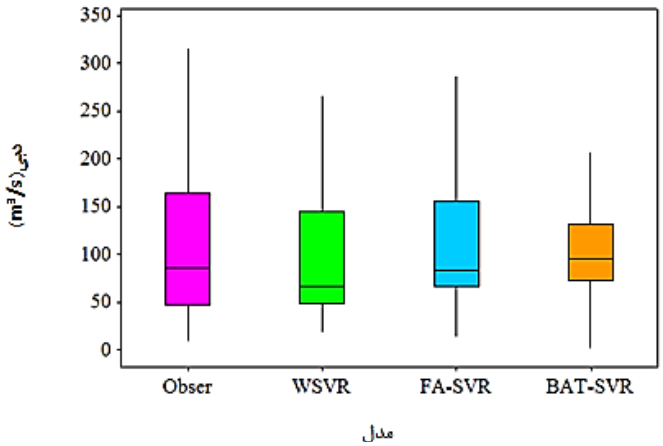

شکل۵- نمودار باکس پلات مدل‌های موردبررسی

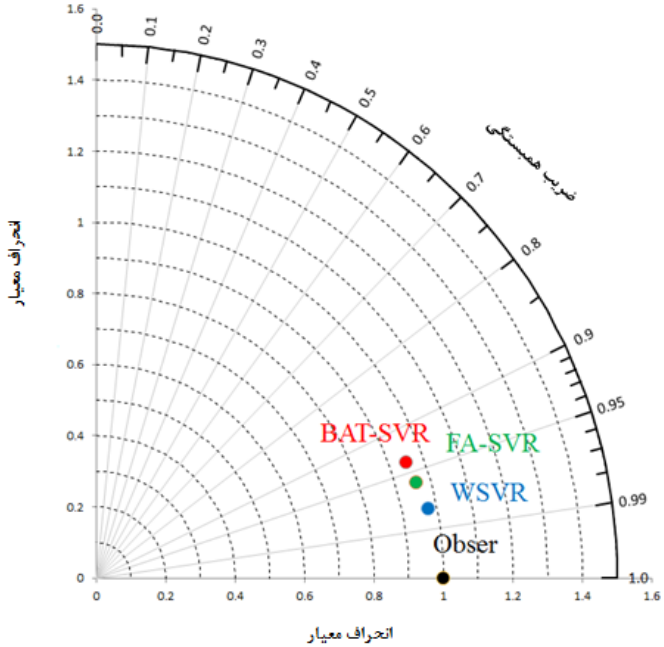

شکل ٦- نمودار تیلور مدل‌های موردبررسی

نتیجه‌گیری

تخمین دبی سیلابی توسط مدل‌های ترکیبی مبتنی بر رگرسیون بردار پشتیبان بعنوان ابزاری کارآمد در طراحی سیستم‌های هیدرولوژیکی می‌باشد. در پژوهش حاضر مطالعه موردی جهت ارزیابی عملکرد مدل فرا ابتکاری هیبریدی رگرسیون بردار پشتیبان بمنظور برآورد دبی سیلابی حوزه آبخیز کاکارضا واقع در استان لرستان صورت گرفت. بدین منظور از الگوریتم‌های الهام گرفته از طبیعت شامل موجک، کرم شب‌تاب و خفاش که با مدل رگرسیون بردار پشتیبان ترکیب شده، استفاده گردید. همچنین جهت مدل‌سازی از پارامتر بارش متناظر با دبی سیلابی به‌عنوان ورودی و دبی سیلابی بعنوان خروجی مدل استفاده شد. بمنظور ساخت مدل هیبریدی بهینه رگرسیون بردار پشتیبان ۸۰ درصد دادها جهت آموزش و ۲۰ درصد باقی‌مانده جهت آزمون بررسی و انتخاب شدند. جهت ارزیابی مدل‌های موردبررسی از شاخص‌های آماری ضریب همبستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش ساتکلیف استفاده شد همچنین جهت تحلیل نتایج از نمودارهای سری زمانی، باکس پلات و تیلور استفاده گردید. نتایج حاصل از معیارهای ارزیابی نشان داد مدل رگرسیون بردار پشتیبان–موجک از دقت بالا و خطای ناچیزی برخوردار است. همچنین مطابق نمودارهای موردبررسی مدل رگرسیون بردار پشتیبان–موجک مقادیر دبی سیلابی را نزدیک به مقدار واقعیشان برآورد نموده است. در مجموع، نتایج این تحقیق نشان می‌دهد که استفاده از مدل‌های هوش مصنوعی مبتنی بر رویکرد مدل رگرسیون بردار پشتیبان می‌تواند در زمینه تخمین دبی سیلابی برای سایر مناطق کشور و گامی در جهت اتخاذ تصمیمات مدیریتی مناسب مورداستفاده قرار گیرد.

منابع

1- 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

2- Asadollahi, A., Ale Magar, B., Poudel, B., Sohrabifar, A., Kalra, A. 2024. Application of Machine Learning Models for Improving Discharge Prediction in Ungauged Watershed: A Case Study in East DuPage, Illinois. Geographies 2024, 4(2), 363-377

3- Asefa, T.; Kemblowski, M.; McKee, M.; Khalil, A. Multi-Time Scale Stream Flow Predictions: The Support Vector Machines Approach. Hydrology 2006, 318, 7–16.

4- Dehghani, R., Babaali, H. (2023). Evaluation of Statistical Models and Modern Hybrid Artificial Intelligence in Simulation of Runoff

Precipitation Process. Sustain. Water Resour. Manag, 8, 154-172. https://doi.org/10.1007/s40899-022-00743-9.
5- Dehghani, R., Torabi Poudeh, H., Younesi, H., Shahinejad, B. (2020). Daily Streamflow Prediction Using Support Vector Machine-Artificial Flora (SVM-AF) Hybrid Model. Acta Geophysica,68(6), 51-66. https://doi.org/10.1007/s11600-020-00472-7
6- Dehghani, R., Torabi, H. (2021). Dissolved oxygen concentration predictions for running waters with using hybrid machine learning techniques. Modeling Earth Systems and Environment, 6(2), 64-78. https://doi.org/10.1007/s40808-021-01253-x.
7- Halwatura, D.; Najim, M.M.M. Application of the HEC-HMS model for runoff simulation in a tropical catchment. Environ. Model. Softw. 2013, 46, 155–162.
8- Jonkman, S. Global Perspectives on Loss of Human Life Caused by Floods. Nat. Hazards 2005, 34, 151–175 Bhusal, A.; Parajuli, U.; Regmi, S.; Kalra, A. Application of Machine Learning and Process-Based Models for Rainfall-Runoff Simulation in DuPage River Basin, Illinois. Hydrology 2022, 9, 117.
9- Jordan, M.I.; Mitchell, T.M. Machine learning: Trends, perspectives, and prospects. Science 2015, 349, 255–260.
10- Kim, D., Han, H., Lee, H., Kang, Y., Wang, W., Kim, H. 2024. Predicting Flood Water Level Using Combined Hybrid Model of Rainfall-Runoff and AI-Based Models. KSCE J Civ Eng 28, 1580–1593 (2024). https://doi.org/10.1007/s12205-023-1147-0
11- Kisi, O., Karahan, M., Sen, Z. (2006). River suspended sediment modeling using fuzzy logic approach. Hydrol Process, 20(2),4351-4362.
12- Nagy, H., Watanabe, K., Hirano, M. (2002). Prediction of sediment load concentration in rivers using artificial neural network model. Journal of Hydraulics Engineering, 128, 558-559.
13- Nourani, V., Tajbakhsh, A.D., Molajou, A. (2018). Data mining based on wavelet and decision tree for rainfall-runoff simulation. Hydrol. Res, 50, 75–84. https://doi.org/ 10.2166/nh.2018.049.
14- Ostu, N. A. (1979). Threshold Selection Method from Gray-Level Histograms [J]. IEEE Transactions on Systems Man and Cybernetics,9 (1), 62-66.
15- Rajab, A., Farman, H., Islam, N., Syed, D., Elmagzoub, M.A., Shaikh, A., Akram, M., Alrizq, M. 2023. Flood Forecasting by Using Machine Learning: A Study Leveraging Historic Climatic Records of Bangladesh.Water 2023, 15(22), 3970;
16- Samantaray, S., Sahoo, A., Agnihotri, A.2023.Prediction of Flood Discharge Using Hybrid PSO-SVM Algorithm in Barak River Basin.MethodsX, 10(4),223-245.
17- 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.
18- Vapnik, V., 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.
19- Vapnik, V.N. (1995). The nature of statistical learning theory. Springer, New York, 3(1), 250-320.
20- Vapnik, V. N. (1998). Statistical learning theory. Wiley, New York, 4(1), 250-320.
21- 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.
22- Yan, X., Zhu, Y., Wu, J., Chen, H. (2012). An improved firefly algorithm with adaptive strategies. Adv Sci Lett, 16(1), 249–254.
23- Yang, X. S. (2008). Firefly algorithm, nature-inspired meta-heuristic algorithms. Wiley Online Libr, 20, 79–90
24- Zeidalinejad, N., Dehghani, R. (2023). Use of meta-heuristic approach in the estimation of aquifer's response to climate change under shared socioeconomic pathways. Groundwater for Sustainable Development, 20(4), 112-132.