Journal of Aquaculture Sciences 12(23): 78-90 (2024)
Print ISSN: 2322-5351
www.aquaculturesciences.ir

**نشریه علوم آبزی‌پروری**
دوره ۱۲، شماره ۲۳: ۷۸-۹۰ (۱۴۰۳)

# ارزیابی مدل هیبریدی رگرسیون بردار پشتیبان در تحلیل کیفیت آب رودخانه (مطالعه موردی: رودخانه کشکان)

**حمیدرضا باباعلی[1]*، ابراهیم نوحانی[2]، رضا دهقانی[3]**

**[1]گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد، خرم‌آباد، ایران.**
**[2]گروه عمران، مرکز تحقیقات مواد و انرژی، واحد دزفول، دانشگاه آزاد اسلامی، دزفول، ایران.**
**[3]گروه علوم و مهندسی آب، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران.**

**تاریخ دریافت: ۱۴۰۳/۰۸/۰۶** **تاریخ پذیرش: ۱۴۰۳/۱۰/۱۸**

**چکیده**

پیش‌بینی مواد جامد محلول در آب (TDS) در مسائل آبی از جمله رودخانه‌ها، دریاچه‌ها و سلامت آبزیان چالش‌برانگیز است اما برای مدیریت مؤثر منابع آب در بخش‌های کشاورزی، صنعت و آب آشامیدنی ضروری است. در این مطالعه، مدل هوشمند ترکیبی مبتنی بر رویکرد مدل رگرسیون بردار پشتیبان برای پیش‌بینی میزان مواد جامد محلول در آب رودخانه توسعه داده‌شده است. بدین‌منظور در این پژوهش سه الگوریتم بهینه‌سازی شامل موجک، کرم شب‌تاب و گرگ خاکستری برای مدل‌سازی مواد جامد محلول در آب رودخانه بکار برده شد. جهت مدل‌سازی از آمار و اطلاعات ایستگاه هیدرومتری رودخانه کشکان واقع در استان لرستان به‌عنوان مطالعه موردی طی ۸ سناریو ترکیبی از پارامترهای ورودی در طی سال‌های ۱۳۸۲ تا ۱۴۰۲ استفاده شد. به‌منظور ارزیابی عملکرد مدل‌ها از معیارهای ارزیابی ضریب همبستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش‌ساتکلیف استفاده شد. همچنین جهت تحلیل نتایج مدل‌ها از نمودار سری زمانی و باکس پلات و تیلور استفاده شد. نتایج نشان داد سناریوهای ترکیبی در مدل‌های موردبررسی باعث بهبود عملکرد مدل می‌شود. همچنین نتایج حاصل از معیار ارزیابی نشان داد مدل رگرسیون بردار پشتیبان–موجک دارای ضریب همبستگی ۰/۹۸۰، ریشه میانگین مربعات خطا (mg/l) ۰/۸۸۱، میانگین قدر مطلق خطا (mg/l) ۰/۴۷۳ و ضریب نش‌ساتکلیف ۰/۹۹۰ در مرحله صحت‌سنجی است. در مجموع نتایج نشان داد استفاده از مدل‌های هوشمند مبتنی بر رویکرد رگرسیون بردار پشتیبان می‌تواند رویکردی مؤثر در پایداری کیفیت رودخانه جهت سلامت آبزیان باشد.

**کلید واژگان:** رگرسیون بردار پشتیبان، کشکان، مواد جامد محلول در آب، مدل‌سازی

*نویسنده مسئول hr.babaali91@gmail.com

**مقدمه**

رودخانه‌ها برای حفظ اکوسیستم‌ها، حفظ تنوع زیستی، حمایت از کشاورزی، و تسهیل سکونت‌گاه‌های انسانی، حیاتی هستند و به‌عنوان مجرای ضروری برای آب، مواد مغذی و رسوبات عمل می‌کنند (Karimi *et al*., 2019). مواد جامد محلول در آب (Total Dissolved Solids) یک پارامتر حیاتی برای ارزیابی کیفیت آب رودخانه است این مواد شامل مواد محلول شده‌ای است که برای ارزیابی استانداردهای آب ضروری می‌باشد (Bui *et al*., 2020) به‌گونه‌ای که سطوح TDS مستقیماً بر مناسب بودن آب برای اهداف کشاورزی، صنعتی و آشامیدنی تأثیر می‌گذارد. غلظت بالای TDS می‌تواند منجر به رسوب و خوردگی در سیستم‌های خنک‌کننده شود و باعث تغییرات شناختی نامطلوب از جمله تغییر رنگ یا طعم و بو آب شود ( Butler *et al*., 2018). همچنین بالا بودن این پارامتر می‌تواند شوری را افزایش داده و ترکیب یونی را تغییر دهد و به‌طور بالقوه باعث ایجاد مسمومیت در جوامع زیستی شود. مدیریت مؤثر سطوح مواد جامد محلول در آب برای حفظ منابع آب و حفظ سلامت اکوسیستم بسیار مهم است ( Wen *et al*., 2024).

در سال‌های اخیر به‌دلیل ماهیت غیرخطی و پیچیده مسائل هیدرولوژیکی از مدل‌های مبتنی بر رویکرد هوش مصنوعی استفاده شده است. این مدل‌ها از طبیعت موجودات زنده الهام گرفته و قادرند مسائل با پیچیدگی و گستردگی فراوان را حل نمایند. این مدل‌ها درزمینه پیش‌بینی پارامترهای کیفی رودخانه به‌ویژه مواد جامد محلول در آب مورد توجه محققین قرارگرفته است که می‌توان به موارد زیر اشاره نمود. Adjovu و همکاران (۲۰۲۳) در پژوهشی جهت پیش‌بینی میزان مواد جامد محلول در آب دریاچه مید واقع در ترکیه از مدل‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی، شبکه عصبی با الگوریتم نزدیک‌ترین همسایگی، شبکه عصبی توابع پایه شعاعی و رگرسیون خطی چندگانه استفاده کردند. نتایج نشان داد مدل ماشین بردار پشتیبان دقت مناسبی نسبت به سایر مدل‌های مورد بررسی در پیش‌بینی پارامتر کیفی رودخانه دارد. Hijji و همکاران (۲۰۲۳) در پژوهشی جهت پیش‌بینی میزان مواد جامد محلول در آب رودخانه تجن در استان مازندران از تکنیک‌های یادگیری ماشین مبتنی بر فازی استفاده کردند. در این پژوهش پارامترهای کلسیم، منیزیم، سدیم و کربنات را به‌عنوان پارامترهای ورودی مدل‌های یادگیری ماشین قراردادند. نتایج نشان داد که مدل رگرسیون بردار پشتیبان–الگوریتم ملخ بهترین عملکرد را در مدل‌سازی مواد جامد محلول در آب دارد. Pourhosseini و همکاران (۲۰۲۳) در پژوهشی جهت پیش‌بینی میزان مواد جامد محلول در آب از مدل هیبریدی بهینه‌سازی شده بر مبنای ماشین بردار پشتیبان استفاده کردند. در این پژوهش از پارامترهای کلسیم، سدیم، منیزیم، کلر، سولفات سدیم کربنات به‌منظور پیش‌بینی مواد جامد محلول در آب رودخانه بابلرود بهره گرفتند. نتایج نشان داد مدل هیبریدی ماشین بردار پشتیبان–الگوریتم بهینه‌سازی مبتنی بر یادگیری بهترین عملکرد را در مدل‌سازی مواد جامد محلول در آب از خود نشان داده است. Sayadi و همکاران (۲۰۲۴) در پژوهشی جهت پیش‌بینی میزان مواد جامد محلول در آب رودخانه یالقوز اقاج حوضه دریاچه ارومیه از مدل هیبریدی رگرسیون بردار پشتیبان–گرگ خاکستری استفاده نمودند در این پژوهش به منظور ارزیابی نتایج مدل از مدل‌های مانند شبکه عصبی مصنوعی، رگرسیون فرآیند گاوسی، ماشین بردار پشتیبان، رگرسیون خطی، درخت طبقه‌بندی و رگرسیون و درختان رگرسیون تقویت‌شده بهره گرفتند. نتایج مطالعه آنها نشان داد مدل هیبریدی رگرسیون بردار پشتیبان–گرگ خاکستری از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است. در مجموع با توجه به پژوهش‌های انجام‌شده، مدل هوش مصنوعی رگرسیون بردار پشتیبان به‌عنوان ابزاری کارآمد در برآورد مواد جامد محلول در آب رودخانه‌ها و مسائل هیدرولوژیکی شناخته شده است. امروزه به‌منظور افزایش کارایی و بهبود عملکرد مدل رگرسیون بردار پشتیبان، از ترکیب این مدل با الگوریتم‌های فرا ابتکاری به‌عنوان یک راهکاری مناسب جهت پیش‌بینی مواد جامد محلول در آب رودخانه‌ها استفاده می‌شود. در این پژوهش نیز از مدل‌های هیبریدی رگرسیون بردار پشتیبان–کرم شب‌تاب و رگرسیون بردار پشتیبان–گرگ خاکستری جهت تخمین مواد جامد محلول در آب رودخانه کشکان واقع در استان لرستان استفاده شد.

رودخانه کشکان استان لرستان یکی از مهم‌ترین رودخانه‌های غرب کشور ایران است. این رودخانه در رشد و نمو محصولات کشاورزی، تولید محصولات آبزی، موقعیت

جغرافیایی و گردشگری تأثیر به‌سزایی دارد. همچنین این رودخانه در طی سال‌های اخیر با کمبود جریان و افزایش رسوبات مواجه شده است و این امر سبب کاهش تولید محصولات کشاورزی و تولید آبزیان و کاهش درآمد اقتصادی ساکنین این منطقه می‌گردد. بنابراین تحلیل و بررسی مواد جامد محلول در آب این رودخانه امری لازم و ضروری است. از طرف دیگر، اگرچه استفاده از مدل رگرسیون بردار پشتیبان به‌طور گسترده برای تخمین میزان مواد جامد محلول در آب رودخانه‌ها استفاده شده است. تاکنون پژوهشی در زمینه استفاده و مقایسه الگوریتم‌های فرا ابتکاری گرگ خاکستری و کرم شب‌تاب در این رودخانه انجام نشده است. بنابراین در این پژوهش از الگوریتم‌های بهینه‌سازی با هدف ترکیب با مدل رگرسیون بردار پشتیبان برای برآورد مواد جامد محلول در آب رودخانه کشکان استفاده شد.

## مواد و روش‌ها

**منطقه مورد مطالعه:** رودخانه کشکان یکی از مهم‌ترین رودخانه‌های استان لرستان و غرب کشور ایران می‌باشد. این رودخانه در بین طول‌های جغرافیایی ″۳۴ ′۳۱ °۴۷ درجه تا ″۶ ′۱۲ °۴۸ شرقی و عرض‌های جغرافیایی ″۴۵ ′۵ °۳۳ تا ″۴۱ ′۴۴ °۳۳ درجه شمالی در استان لرستان واقع شده است. حوضه آبریزی که این رودخانه را تحت پوشش قرار می‌دهد حدود ۶۶/۹۷ کیلومترمربع می‌باشد. از جمله مشکلات و چالش‌های این رودخانه وجود رسوبات در بستر رودخانه بوده که سلامت آبزیان را با مخاطره جدی روبه‌رو کرده است. بنابراین در این پژوهش به‌منظور جلوگیری از این پیامدها به برآورد کیفیت آب این رودخانه با استفاده از مدل‌های هوش مصنوعی مبتنی بر رویکرد مدل رگرسیون بردار پشتیبان پرداخته شد. در شکل ۱ موقعیت منطقه مورد مطالعه نشان داده شده است.

**روش‌شناسی:** در این پژوهش ابتدا داده‌های مورد استفاده شامل هدایت الکتریکی(EC)، هیدروژن کربنات (HCO3)، کلرید(Cl)، سولفات (SO4)، کلسیم (Ca)، منیزیم (Mg) و سدیم (Na) و میزان مواد جامد محلول در آب (TDS) در طی سال‌های ۱۴۰۲-۱۳۸۲ به‌صورت ماهانه (از ایستگاه هیدرومتری کشکان واقع در استان لرستان) از شرکت آب منطقه‌ای استان لرستان اخذ شد (قابل ذکر است در طی دوره بررسی‌شده سری زمانی داده‌ها فاقد داده گمشده و همگن بوده و دارای داده خارج از حد نیز نبوده است). سپس به‌منظور یکپارچه‌سازی آمار و اطلاعات فرآیند نرمال‌سازی بر روی داده‌های اخذشده صورت گرفت.

امروزه به‌دلیل افزایش کارایی مدل‌های هوشمند ازجمله رگرسیون بردار پشتیبان از الگوریتم‌های بهینه‌سازی جهت بهینه نمودن پارامترهای تنظیم مدل استفاده می‌شود در این پژوهش نیز از الگوریتم‌های موجک، گرگ خاکستری و کرم شب‌تاب جهت بهینه نمودن پارامترهای تنظیم مدل رگرسیون بردار پشتیبان استفاده شد. مدل رگرسیون بردار پشتیبان دارای توابع محرک یا فعال‌سازی بنام کرنل بوده و این توابع از متغیرهای t، d و δ تشکیل‌شده است که در فرآیند هیبریدی نمودن مدل این متغیرها توسط الگوریتم‌های بهینه‌سازی ذکرشده به بهینه‌ترین مقدار ممکن برآورد می‌شوند سپس ساختار مدل هیبریدی شکل می‌گیرد درنهایت پارامترهای ورودی وارد مدل شده و منجر به پاسخ (خروجی) می‌گردد در مجموع نتایج مدل‌ها براساس معیارهای ارزیابی و نمودارهای سری زمانی، باکس‌پلات و تیلور بررسی می‌گردد. به‌اختصار مدل‌ها و الگوریتم‌های مورد بررسی در زیر تشریح می‌گردد.

**رگرسیون بردار پشتیبان ( Support Vector Regression):** 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 شامل تابعی 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 در این مدل نیز رابطه جبری بین متغیرهای مستقل و وابسته وجود دارد و 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 (Polynomial) و کرنل توابع پایه

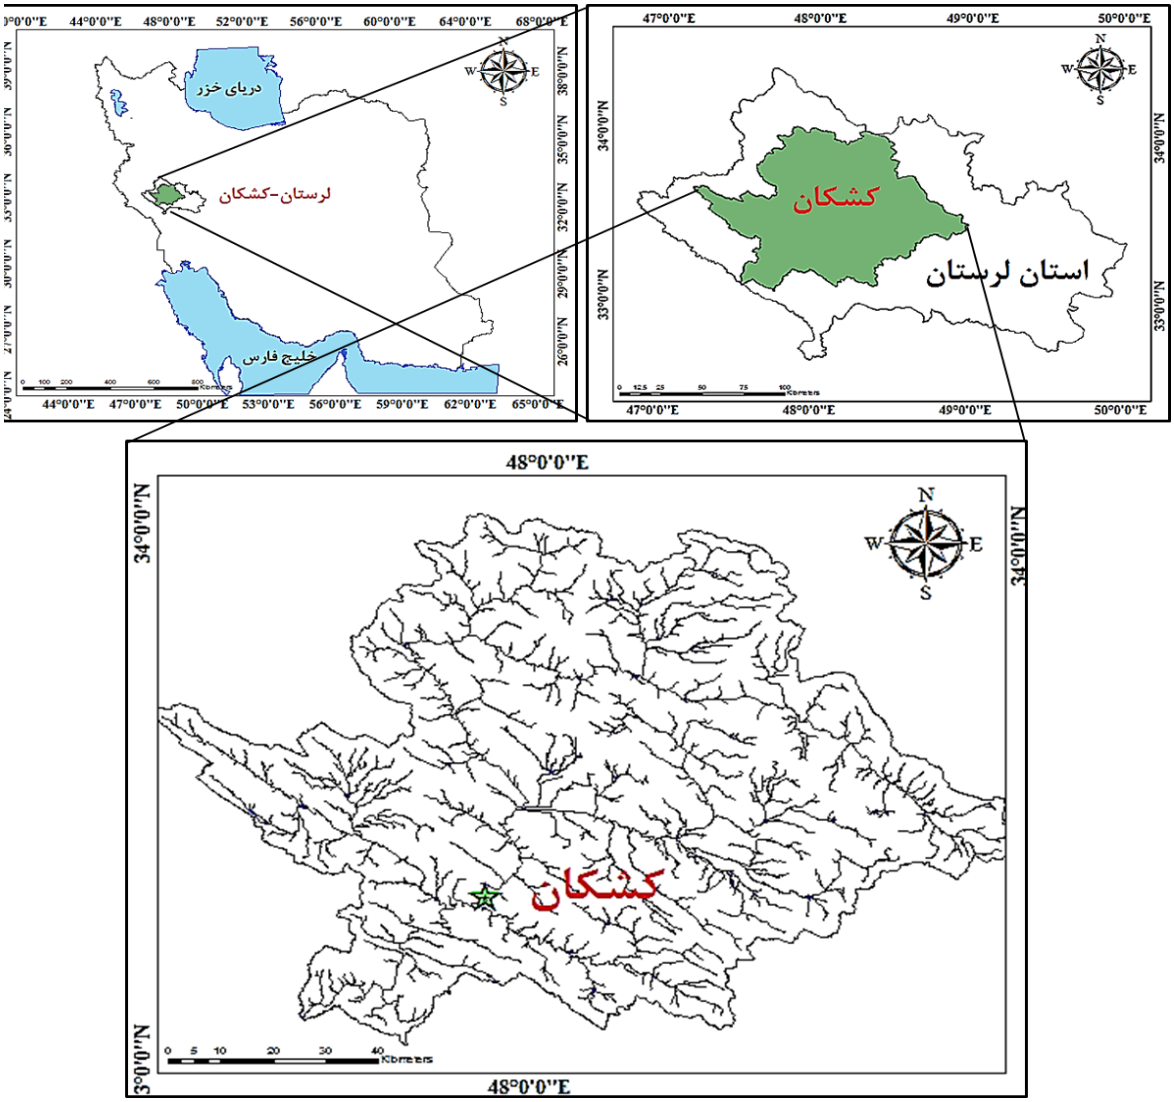


**شکل ۱- منطقه مورد مطالعه**

شعاعی (Radial Basis Functions) 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.

$$k(x,x_j)=(t+x_i.x_j)^d \quad (۳)$$

$$K(x,x_i)=\exp\left(-\frac{\|x-x_i\|^2}{2\sigma^2}\right) \quad (۴)$$

$$k(x,x_j)=x_i.x_j \quad (۵)$$

**سناریوی گرگ خاکستری (Grey Wolf Optimization):** گرگ خاکستری GWO یک الگوریتم شبیه‌سازی بوده که از رفتار اجتماعی گرگ‌های خاکستری و فرآیند سلسله‌مراتبی بهره گرفته است (Ostu, 1979). این الگوریتم بر مبنای جمعیت بوده و به‌سادگی به مسائل با ابعاد قابل گسترش قابل‌تعمیم است. در این الگوریتم شکارچیان رأس، گرگ‌های خاکستری هستند که در بالای هرم قرار می‌گیرند. این گرگ‌ها در یک دسته قرار دارند، که هر گروه ۱۲-۵ عضو به‌طور متوسط دارد. گرگ‌های واقع در رأس هرم دارای وظایف خاصی بوده و سلسله‌مراتب تسلط اجتماعی دقیقی دارند. در هر گله گرگ‌ها ۴ درجه جهت شکار کردن وجود دارد در شکل ۲ نمای کلی فرآیند سلسله مراتبی این الگوریتم نشان داده شد. در این سناریو بهینه‌سازی، از رفتار گرگ‌های خاکستری و سلسله‌مراتب رهبری و روش شکار آنها سناریوبرداری می‌شود. در این سناریو از چهار نوع گرگ خاکستری شامل آلفا (α)، بتا (β)، دلتا (δ) و امگا (ω) برای شبیه‌سازی سلسله‌مراتب رهبری استفاده شده است که آلفا (α): مناسب‌ترین جواب، β (بتا): مناسب‌ترین جواب با فاکتور گرفتن از α ، دلتا: مناسب‌ترین جواب با فاکتور گرفتن از α و β و امگا: مابقی راه‌حل‌های کاندید شده می‌باشد. در شکل

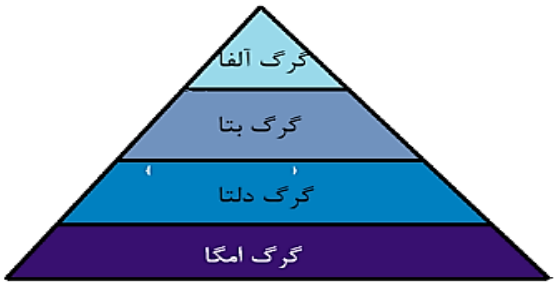


**شکل ۲- سناریو سلسله‌مراتبی گرگ‌ها**

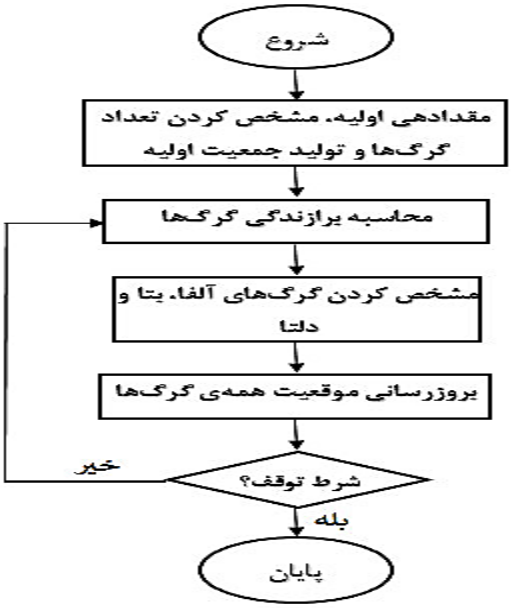


**شکل ۳- نمودار جریانی سناریو گرگ خاکستری**

۳ فلوچارت الگوریتم گرگ خاکستری نشان داده شده است.

**تبدیل موجک (Wavelet Transform):** تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه ارائه شده است و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هرکدام از این پنجره‌ها به‌صورت جداگانه صورت 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. به‌عبارت‌دیگر، 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 به‌معنای 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 انتقال‌یافته (Translation) و مقیاس شده (Dilation) سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و دامنه سیگنال کاهش می‌یابد (Nourani *et al.*, 2018). براساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نا مانا و گذرا (Transient) را به‌صورت موضعی مورد تجزیه‌وتحلیل قرارداد (Shin *et al.*, 2005).

**الگوریتم کرم شب‌تاب (Firefly Algorithm):** الگوریتم کرم شب‌تاب ازجمله الگوریتم‌های بهینه‌سازی می‌باشد که از رفتار موجودات زنده الهام گرفته‌شده است. این

الگوریتم از جمله الگوریتم‌های فرا ابتکاری بوده که در حل مسائل پیچیده بسیار کارایی دارد. این الگوریتم از رویکرد گروهی الهام گرفته به‌صورتی‌که از حالت نورافشانی کرم‌های شب‌تاب 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 شب‌تاب را به‌سمت خود جذب نمایند. این الگوریتم، یک الگوریتم بهینه‌سازی جمعیت محور و تصادفی می‌باشد که اولین بار توسط Yan و همکاران (۲۰۱۲) به جامعه علمی معرفی شد. این الگوریتم بر مبنای رفتار کرم‌های شب‌تاب در جذب جفت عمل می‌کند. سه فرضیه اساسی این الگوریتم به‌صورت زیر است:

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

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

ج) در مسائل بیشینه‌سازی میزان شدت نور با تابع هدف رابطه مستقیم دارد و در مسائل کمینه‌سازی 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.

$$\beta(r) = \beta_0 e^{-\gamma r_{ij}^2} \quad (۶)$$

در این رابطه β، میزان جذابیت کرم درخشیان‌تر در r=۰ است. r: فاصله کرم شب‌تاب کم‌نور نسبت به کرم شب‌تاب پرنورتر است. موقعیت کرم i ام پس از حرکت به سمت کرم jام که درخشان‌تر است از رابطه زیر محاسبه می‌گردد

$$X_{id}(t+1) = X_{id}(t) + \beta_0 e^{-\gamma r_{ij}^2}\left(X_{jd}(t) - X_{id}(t)\right) + \alpha\left(rand - \frac{1}{2}\right) \quad (۷)$$

$$r_{ij} = \|X_i - X_j\| \quad (۸)$$

Rand: عدد تصادفی بین ۰ و ۱ است و $\alpha$: بین ۰ و ۱ است و پارامتر تصادفی‌سازی نامیده می‌شود.

**معیار ارزیابی:** در این پژوهش جهت ارزیابی مدل‌های مورد بررسی به‌منظور تخمین کیفیت آب رودخانه کشکان از شاخص‌های ارزیابی زیر استفاده شد.

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

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

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

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

در روابط بالا، R: ضریب همبستگی، $RMSE$: ریشه میانگین مربعات خطا برحسب mg/l، $NS$: معیار نش‌ساتکلیف، $x_i$ و $y_i$ به‌ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی iام، N: تعداد گام‌های زمانی، $\bar{x}$ و $\bar{y}$ نیز به‌ترتیب 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 مواد جامد محلول در آب رودخانه کشکان واقع در استان لرستان از مدل رگرسیون بردار پشتیبان با الگوریتم‌های موجک، کرم شب‌تاب و گرگ خاکستری استفاده شد. پارامتر هدایت الکتریکی (EC)، هیدروژن کربنات (HCO3)، کلرید (Cl)، سولفات (SO4)، کلسیم (Ca)، منیزیم (Mg) و سدیم (Na) به‌عنوان ورودی و میزان مواد جامد محلول در آب (TDS) به‌عنوان پارامتر خروجی مدل در دوره زمانی ماهانه، سال‌های ۱۴۰۲-۱۳۸۲ برای ایستگاه‌های هیدرومتری رودخانه کشکان 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. مواد جامد محلول در آب از پارامترهای مهم هیدرولوژیکی از جمله کیفیت آب است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر مواد جامد محلول در آب با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکرشده مورد استفاده قرار گرفت که در مقایسه با روش‌های تقریبی به‌مراتب عملکرد بهتری را ارائه می‌نماید. در جدول ۱ ویژگی‌های آماری پارامتر استفاده شده، ارائه شده است. لازم به ذکر است جهت مدل‌سازی۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت تست، به‌صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (Nagy *et al.*,

**جدول ۱- مشخصات آماری پارامترهای مور بررسی**

| پارامتر | آموزش | | | صحت‌سنجی | | |
|---|---|---|---|---|---|---|
| | کمینه | میانگین | بیشینه | کمینه | میانگین | بیشینه |
| هدایت الکتریکی (EC) | ۲۸۵ | ۵۳۹/۳ | ۱۸۳۵ | ۳۶۰ | ۸۲۶/۳۳ | ۱۷۱۵ |
| هیدروژن کربنات (HCO3) | ۱/۲۵ | ۲/۹۳ | ۶ | ۲/۲ | ۳/۷۹ | ۴/۷ |
| کلرید (Cl) | ۰/۳۵ | ۲/۴۵ | ۱۳/۷ | ۰/۵ | ۱/۴۳ | ۵/۵ |
| سولفات (SO4) | ۰/۰۱ | ۰/۹۵ | ۱۲/۳۷ | ۰/۲۴ | ۱/۶۲ | ۹/۷۸ |
| کلسیم (Ca) | ۱/۱۵ | ۲/۳۵ | ۱۲ | ۱/۵ | ۴/۰۷ | ۱۰/۳ |
| منیزیم (Mg) | ۰/۱۵ | ۱/۶۷ | ۸/۱ | ۰/۳ | ۲/۲۲ | ۵/۸ |
| سدیم (Na) | ۰/۱۲ | ۱/۳۱ | ۵/۷۸ | ۰/۱۳ | ۱/۵۱ | ۳/۱ |
| مواد جامد محلول در آب (TDS) | ۱۶۰ | ۳۴۷/۸۷ | ۹۳۷ | ۲۳۵ | ۴۷۰/۳۱ | ۸۳۰ |

**جدول۲- ترکیبات ورودی مدل‌های موردبررسی**

| شماره | ورودی | خروجی |
|---|---|---|
| ۱ | EC(t) | TDS(t) |
| ۱ | EC(t), HCO3(t) | TDS(t) |
| ۳ | EC(t), HCO3(t), Cl(t) | TDS(t) |
| ۴ | EC(t), HCO3(t), Cl(t), SO4(t) | TDS(t) |
| ۵ | EC(t), HCO3(t), Cl(t), SO4(t), Ca(t) | TDS(t) |
| ۶ | EC(t), HCO3(t), Cl(t), SO4(t), Ca(t) | TDS(t) |
| ۷ | EC(t), HCO3(t), Cl(t), SO4(t), Ca(t), Mg(t) | TDS(t) |
| ۸ | EC(t), HCO3(t), Cl(t), SO4(t), Ca(t), Mg(t), Na(t) | TDS(t) |

2002; Kisi and Karhan, 2006). یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. در مدل‌های هوشمند انتخاب ورودی‌های اولیه مناسب و تأثیرگذار در پدیده به‌منظور آموزش ماهیت سازوکار حاکم بر پدیده باعث بهبود عملکرد خواهد شد. بنابراین در سناریوسازی میزان مواد جامد محلول در آب نیز سعی گردید تا مؤثرترین داده‌های مشاهداتی به‌عنوان داده‌های آموزشی انتخاب شود (Dehghani *et al.*, 2020). بدین‌منظور ترکیب‌های مختلفی از پارامتر ورودی به‌منظور دستیابی به مدل بهینه جهت تخمین مواد جامد محلول در آب استفاده شد که در جدول ۲ ارائه شده است.

به‌منظور مدل‌سازی میزان مواد جامد محلول در آب رودخانه کشکان از مدل رگرسیون بردار پشتیبان با الگوریتم‌های موجک، گرگ خاکستری 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، چندضلعی و خطی می‌باشد که در این پژوهش مورد بررسی قرار گرفت. بدین‌منظور مقادیر پارامترهای کیفی رودخانه کشکان نرمال‌سازی شده سپس وارد مدل رگرسیون بردار پشتیبان می‌شود. در سال‌های اخیر به‌دلیل آنکه در مدل رگرسیون بردار پشتیبان مقادیر پارامترهای تنظیم توابع کرنل به‌صورت تصادفی انتخاب می‌شدند از الگوریتم‌های بهینه‌سازی جهت افزایش دقت و کاهش خطای مدل استفاده شده است (Dehghani and Torabi, 2021). در این پژوهش نیز جهت افزایش عملکرد مدل از الگوریتم‌های موجک، گرگ خاکستری و کرم شب‌تاب جهت بهینه نمودن مقادیر پارامترهای تنظیم استفاده شد. مقادیر بهینه پارامترهای تنظیم مدل رگرسیون بردار پشتیبان که توسط الگوریتم‌های بهینه‌سازی مورد بررسی، تجزیه‌وتحلیل گردید در جدول ۴ نشان داده شده است. بنابراین در این پژوهش بعد از ورود اطلاعات پارامترهای ورودی به مدل و بهینه نمودن پارامترهای تنظیم ،ساختار مدل هیبریدی شکل گرفته و منجر به پاسخ محاسباتی مدل می‌گردد. از آنجا که معیار توقف در آموزش

**جدول ۳- میزان خطای مدل‌های مورد بررسی تحت سناریوهای مختلف**

| مدل | سناریو | آموزش | صحت سنجی |
|---|---|---|---|
| | | RMSE(mg/l) | RMSE(mg/l) |
| GWO-SVR | ۱ | ۱/۷۶۴ | ۱/۵۰۱ |
| | ۲ | ۱/۸۵۴ | ۱/۴۸۶ |
| | ۳ | ۱/۷۳۳ | ۱/۳۶۵ |
| | ۴ | ۱/۷۰۵ | ۱/۲۵۸ |
| | ۵ | ۱/۶۸۶ | ۱/۱۹۷ |
| | ۶ | ۱/۵۹۳ | ۱/۱۱۱ |
| | ۷ | ۱/۵۴۲ | ۱/۰۹۵ |
| | ۸ | ۱/۴۶۲ | ۱/۰۸۰ |
| FA-SVR | ۱ | ۱/۷۵۵ | ۱/۴۹۵ |
| | ۲ | ۱/۷۲۰ | ۱/۴۷۳ |
| | ۳ | ۱/۶۹۵ | ۱/۳۵۷ |
| | ۴ | ۱/۶۷۵ | ۱/۲۴۸ |
| | ۵ | ۱/۵۸۴ | ۱/۱۸۶ |
| | ۶ | ۱/۵۳۶ | ۱/۰۸۶ |
| | ۷ | ۱/۴۶۲ | ۱/۰۴۱ |
| | ۸ | ۱/۵۰۴ | ۰/۹۳۲ |
| WSVR | ۱ | ۱/۸۲۲ | ۱/۴۸۶ |
| | ۲ | ۱/۷۱۶ | ۱/۴۵۶ |
| | ۳ | ۱/۶۸۹ | ۱/۳۴۲ |
| | ۴ | ۱/۶۴۴ | ۱/۲۳۶ |
| | ۵ | ۱/۵۷۸ | ۱/۱۷۴ |
| | ۶ | ۱/۵۲۳ | ۱/۰۵۵ |
| | ۷ | ۱/۴۵۸ | ۰/۹۹۵ |
| | ۸ | ۱/۴۴۱ | ۰/۸۸۱ |

**جدول ۴-مقادیر بهینه‌شده پارامترهای تنظیم الگوریتم‌های موردبررسی**

| شماره | الگوریتم | t | d | * |
|---|---|---|---|---|
| ۱ | موجک | ۱۰ | ۰/۱ | ۰/۱۷ |
| ۲ | کرم شب‌تاب | ۱۰ | ۰/۲ | ۰/۲۲ |
| ۳ | گرگ خاکستری | ۱۰ | ۰/۴ | ۰/۲۸ |

مدل‌های هوش مصنوعی میزان خطا می‌باشد بنابراین مدل در کمترین میزان خطا متوقف و خروجی حاصل می‌گردد.

همان‌طور که در جدول ۳ مشخص است مدل‌های هیبریدی در سناریو شماره ۸ که شامل کلیه پارامترهای ورودی به مدل می‌باشد از خطای کمتری نسبت به سایر سناریوها برخوردار است بنابراین افزایش تعداد پارامترهای مؤثر در مدل‌های هیبریدی مبتنی بر رگرسیون بردار پشتیبان منجر به افزایش عملکرد مدل می‌شود. همچنین کلیه مدل ها در تابع کرنل پایه شعاعی از دقت بهتری برخوردار هستند. نتایج مدل‌های مورد بررسی در سناریو شماره ۸ در جدول ۵ نشان داده شده است همان‌طور که در جدول مشخص است مدل رگرسیون بردار پشتیبان-موجک با بیشترین ضریب همبستگی (۰/۹۸۰)، کمترین ریشه میانگین مربعات ((mg/l) ۰/۸۸۱)، کمترین میانگین قدر مطلق خطا (mg/l) ۰/۴۷۳) و بیشترین ضریب نش‌ساتکلیف (۰/۹۹۰) در مرحله صحت‌سنجی، عملکرد بهتری از خود نشان داده است.

در شکل ۴ نمودار سری زمانی مقادیر مشاهداتی و محاسباتی نشان داده شده است همان‌طور که مشاهده می‌گردد مدل رگرسیون بردار پشتیبان-موجک نسبت به مدل‌های هیبریدی رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-کرم شب‌تاب در تخمین اکثر نقاط از جمله بیشینه، کمینه و میانی دقت قابل

**جدول ۵- نتایج مدل‌های موردبررسی**

| مدل | کرنل | آموزش | | | | صحت سنجی | | | |
|---|---|---|---|---|---|---|---|---|---|
| | | R | RMSE (mg/l) | MAE (mg/l) | NS | R | RMSE (mg/l) | MAE (mg/l) | NS |
| GWO-SVR | RBF | ۰/۹۲۰ | ۱/۷۵۱ | ۰/۹۸۰ | ۰/۹۳۰ | ۰/۹۴۶ | ۱/۰۸۰ | ۰/۶۶۲ | ۰/۹۵۰ |
| | Poly | ۰/۹۱۰ | ۱/۸۸۵ | ۱/۲۶۱ | ۰/۹۲۰ | ۰/۹۳۳ | ۱/۲۲۱ | ۰/۷۹۱ | ۰/۹۳۰ |
| | Line | ۰/۹۰۰ | ۱/۹۳۶ | ۱/۳۷۳ | ۰/۹۱۰ | ۰/۹۱۲ | ۱/۳۷۶ | ۰/۸۶۵ | ۰/۹۲۰ |
| FA-SVR | RBF | ۰/۹۴۰ | ۱/۵۰۴ | ۰/۸۸۲ | ۰/۹۵۰ | ۰/۹۶۰ | ۰/۹۳۲ | ۰/۵۱۱ | ۰/۹۷۰ |
| | Poly | ۰/۹۲۲ | ۱/۶۶۳ | ۱/۰۴۴ | ۰/۹۳۰ | ۰/۹۴۴ | ۱/۰۲۰ | ۰/۶۲۴ | ۰/۹۵۰ |
| | Line | ۰/۹۰۸ | ۱/۷۵۴ | ۱/۲۲۲ | ۰/۹۲۰ | ۰/۹۳۰ | ۱/۱۴۴ | ۰/۷۱۷ | ۰/۹۴۰ |
| WSVR | RBF | ۰/۹۵۰ | ۱/۴۴۱ | ۰/۸۲۶ | ۰/۹۶۰ | ۰/۹۸۰ | ۰/۸۸۱ | ۰/۴۷۳ | ۰/۹۹۰ |
| | Poly | ۰/۹۳۵ | ۱/۵۶۰ | ۰/۹۵۷ | ۰/۹۵۰ | ۰/۹۶۸ | ۰/۹۶۲ | ۰/۵۳۱ | ۰/۹۷۰ |
| | Line | ۰/۹۱۵ | ۱/۶۸۵ | ۱/۱۲۶ | ۰/۹۳۰ | ۰/۹۴۲ | ۱/۰۴۱ | ۰/۶۵۰ | ۰/۹۵۰ |

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–گرگ خاکستری در تخمین مقادیر میانی عملکرد نسبتاً مطلوبی داشته است و در تخمین مقادیر کمینه و بیشینه ضعیف عمل نموده است.

در شکل ۵ نمودار باکس‌پلات مدل‌های مورد بررسی نشان داده شد. همان‌طور که مشاهده می‌گردد مدل رگرسیون بردار پشتیبان–موجک در تخمین مقادیر چارک اول و میانه نسبت به داده‌های مشاهداتی عملکرد بهتری از خود نشان داده است در صورتی‌که مدل رگرسیون بردار پشتیبان–گرگ خاکستری ضعیف عمل نموده است و مدل رگرسیون بردار پشتیبان–کرم شب‌تاب نیز از دقت مطلوبی برخوردار است و در رتبه دوم می‌باشد. همچنین در شکل ۶ نمودار تیلور مدل‌های مورد بررسی قابل مشاهده است. مدل رگرسیون بردار پشتیبان–موجک از عملکرد بهتری برخوردار است زیرا انحراف معیار پیش‌بینی‌شده میزان مواد جامد محلول در آب نزدیک‌ترین فاصله به انحراف استاندارد داده‌های مشاهداتی را دارد و ضریب همبستگی نیز بالاترین مقدار را نشان می‌دهد. بنابراین مدل رگرسیون بردار پشتیبان–موجک نسبت به سایر مدل‌های مورد بررسی از عملکرد بهتری برخوردار است که این نتایج با پژوهش‌های Zeidalinejad و Dehghani (۲۰۲۳) و Dehghani و Babaali (۲۰۲۳) مطابقت دارد. در تحلیل این نتایج می‌توان بیان داشت برتری این مدل ناشی از تبدیل موجک می‌باشد که سیگنال‌های دریافتی را به دو دسته بالاگذر و پایین‌گذر تقسیم نموده و در دسته بالاگذر 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 قابل قبول 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 به‌عنوان راهکاری نوین در پیش‌بینی میزان مواد جامد محلول در آب رودخانه به‌منظور اتخاذ تصمیمات مدیریتی مناسب برای بهبود منابع آبی، آماده‌سازی زمین و سرمایه‌گذاری اقتصادی و تولید محصولات آبزی استفاده شود.

## نتیجه‌گیری

تخمین میزان مواد جامد محلول در آب رودخانه توسط مدل‌های ترکیبی مبتنی بر رگرسیون بردار پشتیبان به‌عنوان ابزاری کارآمد در طراحی سیستم‌های هیدرولوژیکی و مهندسی رودخانه شناخته شده است. نتایج تحقیق طبق ارزیابی سناریوهایی متشکل از پارامترهای ورودی نشان داد

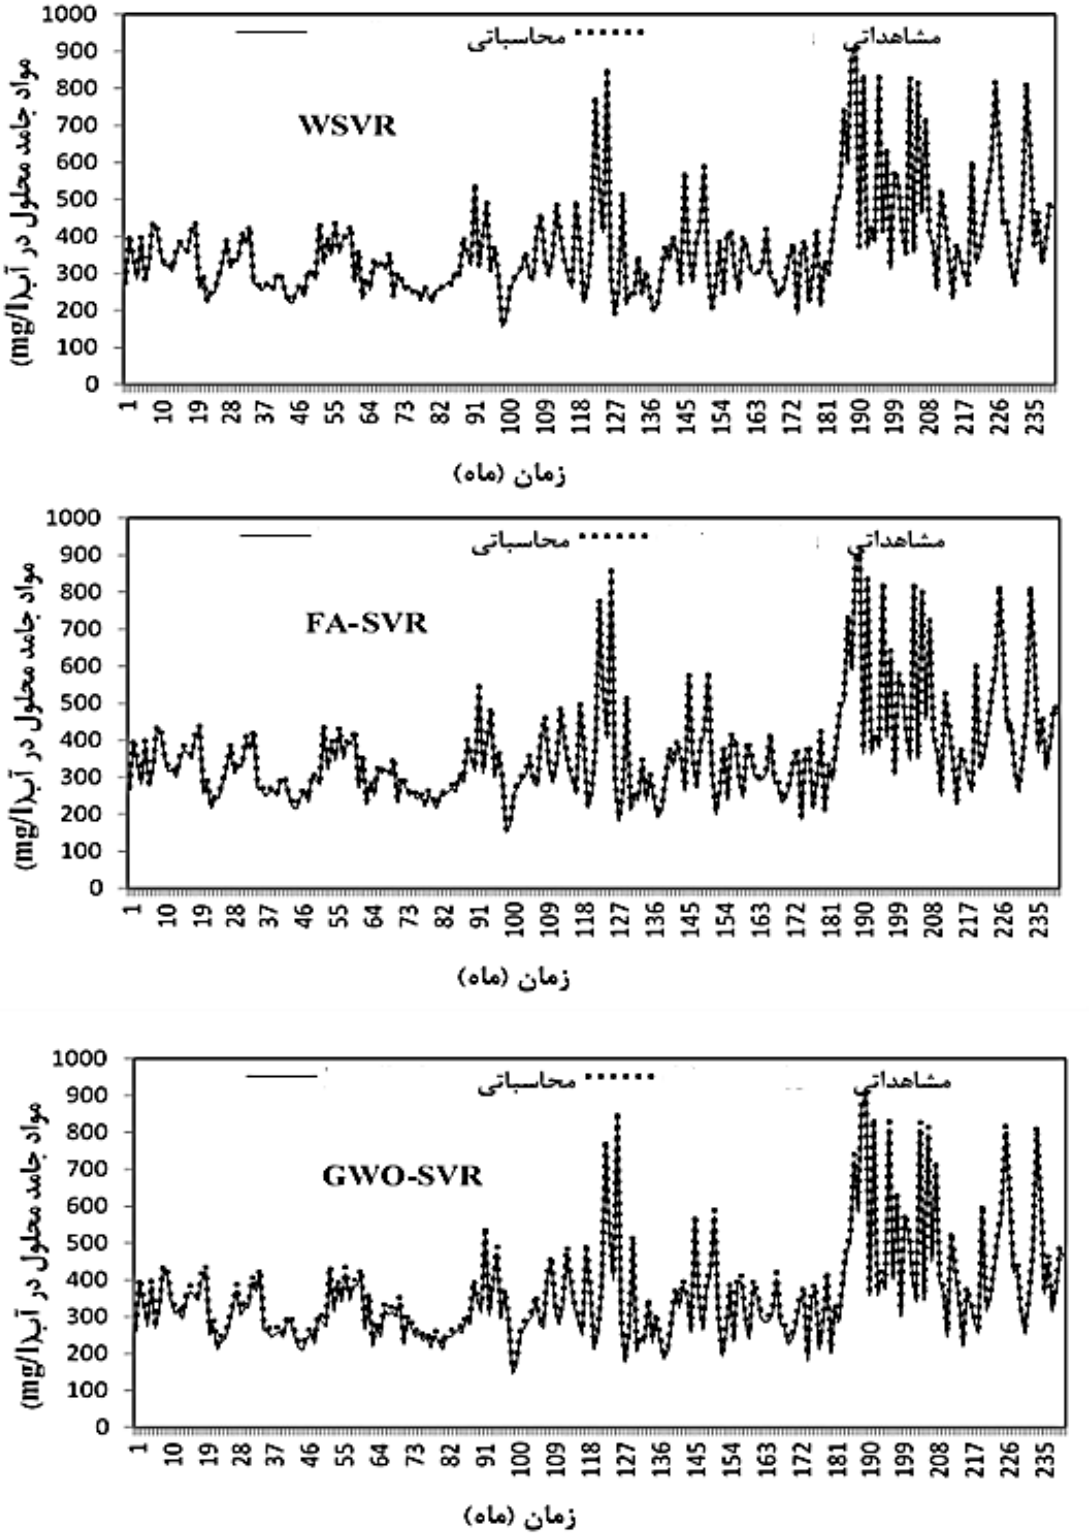


**شکل ۴- نمودار سری زمانی مدل‌های مورد بررسی**

که در کلیه مدل‌های مورد بررسی افزایش تعداد پارامترهای مؤثر در مدل‌های مختلف مدل‌سازی منجر به عملکرد بهتر در تخمین مواد جامد محلول در آب رودخانه می‌شود. علاوه بر این، نتایج حاصل از معیارهای ارزیابی نشان داد مدل رگرسیون بردار پشتیبان–موجک از دقت بالا و خطای ناچیزی برخوردار است. همچنین مطابق نمودارهای مورد بررسی مدل رگرسیون بردار پشتیبان –موجک مقادیر مواد جامد محلول در آب را نزدیک به مقدار واقعی برآورد نموده

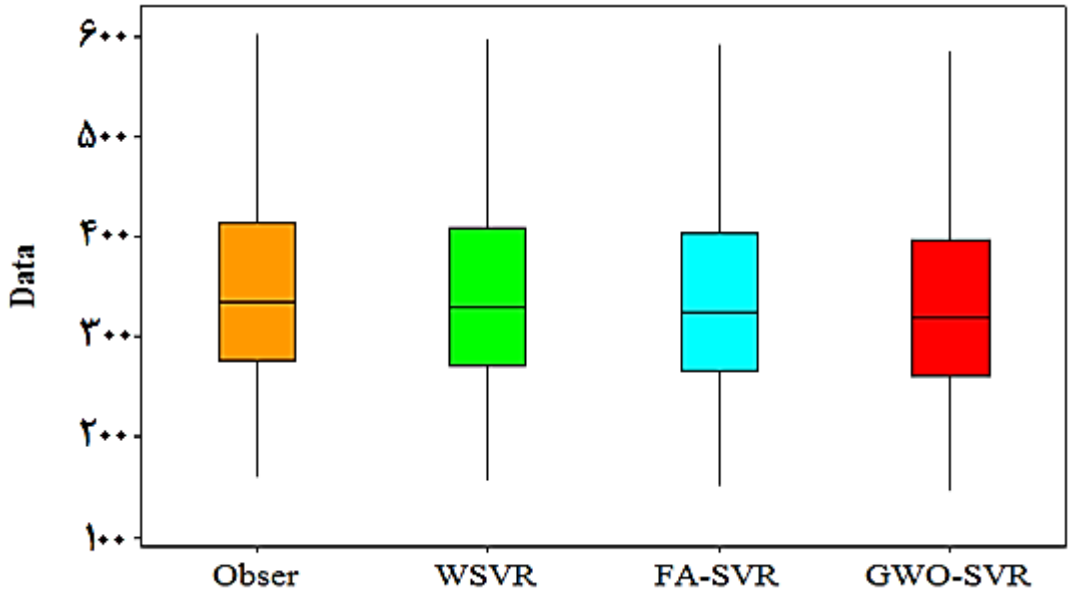


شکل ۵- نمودار باکس‌پلات مدل‌های مورد بررسی

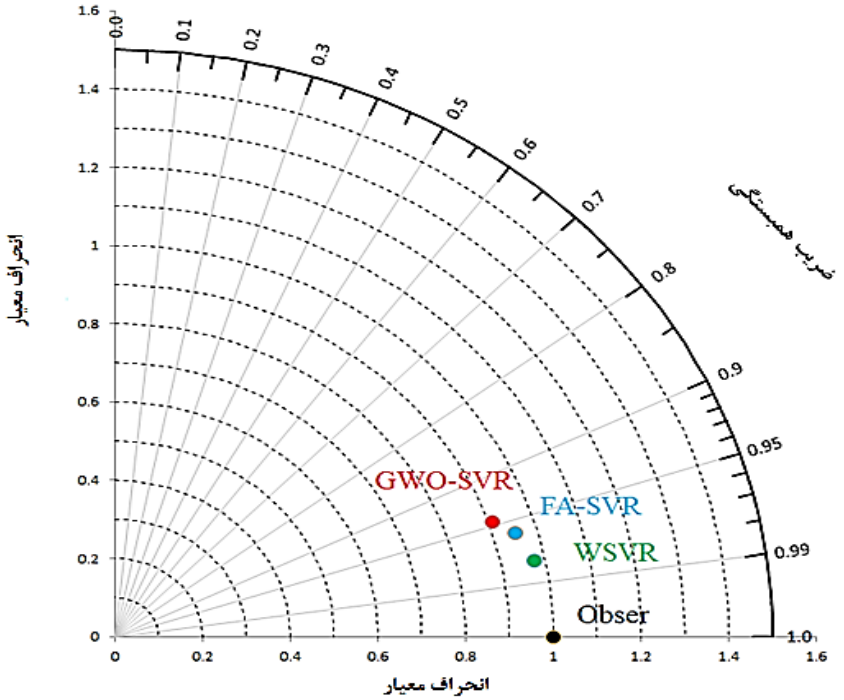


شکل۶- نمودار تیلور مدل‌های مورد بررسی

است که در اشکال باکس‌پلات و تیلور مشهود می‌باشد. در مجموع، نتایج این تحقیق نشان می‌دهد که استفاده از مدل‌های هوش مصنوعی مبتنی بر رویکرد مدل رگرسیون بردار پشتیبان می‌تواند در زمینه تخمین میزان مواد جامد محلول در آب رودخانه طی ۲۰ سال آماری برای سایر مناطق کشور و گامی در جهت اتخاذ تصمیمات مدیریتی مناسب مورد استفاده قرار گیرد.

## منابع

**Adjovu G.E., Stephen H., James D., Ahmad S. 2023.** Measurement of total dissolved solids and total suspended solids in water systems: A review of the issues, conventional, and remote sensing techniques.

*Remote Sensing* 15(2), 353-374.

**Basak D., Pal S., Patranabis D.C. 2007.** Support vector regression. *Neural INF Process* 11(2), 203-225.

**Bui D.T., Khosravi K., Tiefenbacher J., Nguyen H., Kazakis N. 2020.** Improving prediction of water quality indices using novel hybrid machine-learning algorithms. *Science of The Total Environment* 721(1), 137-152.

**Butler B.A., Ford R.G. 2018.** Evaluating relationships between total dissolved solids (TDS) and total suspended solids (TSS) in a mining-influenced watershed. *Mine Water Environ* 37(3), 18-44.

**Dehghani R., Babaali H. 2023.** Evaluation of Statistical Models and Modern Hybrid Artificial Intelligence in Simulation of Runoff Precipitation Process. *Sustain. Water Resources Management* 8(2), 154-172.

**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.

**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.

**Hijji M., Chen T.C., Ayaz M., Abosinnee A.S., Muda I., Razoumny Y., Hatamiafkoueieh J. 2023.** Optimization of state of the art fuzzy-based machine learning techniques for total dissolved solids prediction. *Sustainability* 15(4), 601-622.

**Karimi S., Amiri B.J., Malekian A. 2019.** Similarity metrics-based uncertainty analysis of river water quality models. *Water Resources Management* 33(2), 1927-1945.

**Kisi O., Karahan M., Sen Z. 2006.** River suspended sediment modeling using fuzzy logic approach. *Hydrological Process* 20(2), 4351-4362.

**Nagy H., Watanabe K., Hirano M. 2002.** Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulics Engineering* 128(1), 558-559.

**Nourani V., Tajbakhsh A.D., Molajou A. 2018.** Data mining based on wavelet and decision tree for rainfall-runoff simulation. *Hydrology Research* 50(2), 75-84.

**Ostu N.A. 1979.** Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man and Cybernetics* 9 (1), 62-66.

**Pourhosseini F.A., Ebrahimi K., Omid M.H. 2023.** Prediction of total dissolved solids, based on optimization of new hybrid SVM models. Eng. *Applied Artificial Intelligence* 126(1), 106-122.

**Sayadi M., Hessari B., Montaseri M., Naghibi A. 2024.** Enhanced TDS Modeling Using an AI Framework Integrating Grey Wolf Optimization with Kernel Extreme Learning Machine. *Water* 16(19), 662-678

**Shin S., Kyung D., Lee S., Taik Kim J., Hyun J. 2005.** An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications* 28(4), 127-135.

**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.

**Vapnik V.N. 1995.** The nature of statistical learning theory. *Springer, New York* 3(1), 250-320.

**Vapnik V.N. 1998.** Statistical learning theory. Wiley, *New York* 4(1), 250-320.

**Wang D., Safavi A.A., Romagnoli J.A. 2000.** Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal* 46(4), 1607-1615.

**Wen, Z., Han, J., Shang, Y., Tao, H., Fang, C., Lyu, L., Li, S., Hou, J., Liu, G., Song, K., 2024.** Spatial variations of DOM in a diverse range of lakes across various frozen ground zones in China: Insights into molecular composition. *Water Research* 252(2), 121-142.

**Yan X., Zhu Y., Wu, J., Chen H. 2012.** An improved firefly algorithm with adaptive strategies. *Advanced Science Letters* 16(1), 249-254.

**Yang X.S. 2008.** Firefly algorithm, nature-inspired meta-heuristic algorithms. *Wiley Online Libr* 20(2), 7990

**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.

**Journal of Aquaculture Sciences** Vol. 12, No 23, 78-90
**Print ISSN: 2322-5351**
**www.aquaculturesciences.ir**

# Evaluation of hybrid support vector regression models in river water quality analysis (Case study: Kashkan River)

**Hamidreza Babaali*[1], Ebrahim Nohani[2], Reza Dehghani[3]**

[1]Department of Civil Engineering, Islamic Azad University, Khorramabad branch, Khorramabad, Iran.
[2]Department of Civil Engineering, Materials and Energy Research Center, Dezful Branch, Islamic Azad University, Dezful, Iran.
[3]Department of Soil Conservation and Watershed Management, Lorestan Province Agriculture and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization, Khorramabad, Iran.

*Corresponding author: hr.babaali91@gmail.com
**Received: 27.Oct.2024** **Accepted: 7.Jan.2025**

## Abstract
Predicting Total Dissolved Solids (TDS) in water bodies such as rivers and lakes is challenging but essential for effective water resource management in agriculture, industry, and drinking water sectors. This study develops a hybrid intelligent model based on the Support Vector Regression (SVR) approach to predict the TDS levels in river water. Three optimization algorithms—Wavelet, Firefly, and Grey Wolf—were employed to model the TDS in river water. The study utilized hydrometric station data from the Kashkan River in Lorestan Province as a case study, using eight scenarios combining input parameters from 2003 to 2023. Model performance was evaluated using correlation coefficient, root mean square error (RMSE), mean absolute error (MAE), and Nash-Sutcliffe efficiency coefficient. Time series plots, box plots, and Taylor diagrams were used to analyze the model results. The findings indicated that the combined scenarios improved model performance. The evaluation criteria showed that the Wavelet-SVR model achieved a correlation coefficient of 0.980, RMSE of 0.881 mg/l, MAE of 0.473 mg/l, and a Nash-Sutcliffe efficiency of 0.990 during the validation phase. Overall, the results suggest that intelligent models based on the SVR approach can be an effective strategy for maintaining river quality for aquatic health.

**Keywords**: Support vector regression, Kashkan, Total dissolved solids, Modeling