

## ارزیابی مدل‌های هیبریدی فراکاوشی در شبیه‌سازی اکسیژن محلول در آب رودخانه

حجت‌اله یونسی<sup>۱\*</sup>، احمد گودرزی<sup>۲</sup>

۱. استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه لرستان، خرم‌آباد

۲. دانشجوی دکتری سازه‌های آبی، دانشکده کشاورزی، دانشگاه لرستان، خرم‌آباد

(تاریخ دریافت ۱۴۰۰/۰۶/۱۵؛ تاریخ تصویب ۱۴۰۰/۱۱/۱۱)

## چکیده

آب یکی از عناصر ضروری در طبیعت است که اساس زندگی انسان را تشکیل می‌دهد و به رشد و توسعه اقتصادی جوامع کمک می‌کند. آب سالم ارتباط تنگاتنگی با سلامت محیط زیست و فعالیت‌ها دارد. زندگی همه جانوران روی کره زمین به آب و اکسیژن بستگی دارد. علاوه بر این، اکسیژن محلول کافی (DO) برای بقای جانوران آبی بسیار مهم است. از این رو، در این پژوهش برای شبیه‌سازی اکسیژن محلول در آب رودخانه کامبرلند واقع در ایالات متحده از مدل ترکیبی شبکه عصبی مصنوعی (ANN) با موجک و الگوریتم‌های فراابتکاری گرگ خاکستری (GWO) و خفاش (BA) در مقیاس زمانی ماهانه طی دوره آماری ۲۰۱۰-۲۰۲۰ استفاده شد. معیارهای ضریب همبستگی ( $R^2$ )، مجذور میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) و ضریب بهره‌وری نش-ساتکلیف (NSE) برای ارزیابی و مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج نشان داد هر سه مدل هیبریدی، در الگوهای ترکیبی نتایج بهتری نسبت به سایر الگوهای تعیین شده دارند. همچنین، با توجه به معیارهای ارزیابی مشخص شد که از بین مدل‌های به‌کاررفته در شبیه‌سازی اکسیژن محلول در آب رودخانه، مدل شبکه عصبی مصنوعی-موجک با ضریب تعیین ( $R^2=0/958$ )، ریشه میانگین مربعات خطا ( $RMSE=0/651$ )، میانگین قدرمطلق خطا ( $MAE=0/334$ ) و ضریب نش-ساتکلیف ( $NS=0/962$ ) در مرحله صحت‌سنجی عملکرد بهتری نسبت به سایر مدل‌ها از خود نشان داده است.

**کلمات کلیدی:** اکسیژن محلول در آب، الگوریتم فراابتکاری، شبیه‌سازی، مدل هیبریدی.

## مقدمه

توسعه فعالیت‌های کشاورزی و صنعتی و افزایش حجم فاضلاب شهری، رودخانه‌ها را آلوده کرده است، به طوری که کیفیت این منابع حیاتی به طور جدی به خطر می‌افتد. استفاده بیش از حد از مواد شیمیایی در کشاورزی شدت آلودگی منابع آب در مناطق روستایی و شهری را تشدید کرده است [۱-۶]. DO یکی از شاخص‌های مهم کیفی برای ارزیابی سلامت رودخانه است [۷]. DO مقدار اکسیژن محلول در آب به عنوان یک عامل مهم و در زندگی موجودات آبی و آلودگی آب است [۸]. سطوح بالای DO باعث شرایط نامساعد زندگی برای گیاهان و حیوانات رودخانه‌ای می‌شود [۹]. امروزه، از دستگاه‌های متحرک کوچک مجهز به الکترودهای غشایی برای اندازه‌گیری اکسیژن محلول در محل نمونه‌برداری استفاده می‌شود. الکترودهای غشایی بر اساس میزان نفوذ مولکول‌های اکسیژن از یک غشا ساخته شده است. این روش فیزیکی ساده و سریع است. از سوی دیگر، دقیق‌ترین روش اندازه‌گیری اکسیژن محلول، روش یدومتری است. این روش یک روش تیتراسیون بر اساس ویژگی‌های اکسیدکننده اکسیژن محلول است [۱۰-۱۴]. از آنجا که کیفیت آب رودخانه تحت تأثیر ویژگی‌های مختلفی قرار می‌گیرد که دارای رفتار پیچیده و غیرخطی هستند، مدل‌های ریاضی ممکن است عملکرد خوبی نداشته باشند. به‌تازگی، از مدل‌های ترکیبی که زیرمجموعه هوش مصنوعی (AI) هستند، برای تخمین کیفیت آب رودخانه‌ها استفاده شده است. این تکنیک‌های هوش مصنوعی ساده و قدرتمند هستند و به راحتی می‌توانند فرایندهای پیچیده غیر خطی را کنترل کنند. از آنجا که این مدل‌ها غیر پارامتری هستند، مزیت اصلی آنها عدم نیاز به مفهوم پیش‌بینی و رابطه بین متغیرهای ورودی و داده‌های خروجی است [۱۵]. یکی از ویژگی‌های کلاسیک هوش مصنوعی این است که این مدل‌ها قادر به انجام تحلیل تصادفی از دینامیک، الگوها و ویژگی‌های متغیرهای ورودی هستند که برای شبیه‌سازی متغیرهای سطح آب‌های زیرزمینی استفاده می‌شوند. بنابراین، آنها بیش از سایر روش‌های مفهومی و آماری (مانند رویکردهای تجربی و مدل‌های مبتنی بر فیزیک) امکان‌پذیر هستند. به طور کلی، مدل‌های مبتنی بر هوش مصنوعی برای موارد

استفاده محلی قابل اجرا هستند. بنابراین، مدل‌های مبتنی بر هوش مصنوعی پتانسیل بالایی برای کاربردهای مختلف از جمله پدیده‌های هیدرولوژیکی و هیدروژئولوژیکی دارند. بسیاری از محققان کاربرد بالقوه تکنیک‌های هوش مصنوعی برای شبیه‌سازی کیفیت آب رودخانه‌ها را تأیید کرده‌اند [۱۶-۲۶].

علیزاده و همکاران [۲۷] از مدل شبکه عصبی مصنوعی موجک برای پیش‌بینی مقادیر پارامترهای کیفی در خلیج اقیانوس آرام استفاده کرد و نتیجه گرفت که مدل شبکه عصبی مصنوعی موجک از شبکه عصبی مصنوعی بهتر عمل می‌کند.

رجایی و همکاران [۲۸] مدل‌های ANN-ARIMA، GA-ANN، WANN، WNF، WSVR و WLGP را برای برآورد پارامتر اکسیژن محلول در آب رودخانه ترکیب کرد. در این مطالعه، اطلاعات و آمار به‌دست‌آمده از ۵۱ مقاله علمی طی سال‌های ۲۰۰۰ تا ۲۰۱۶ به دست آمد. نتایج نشان داد مدل‌های مبتنی بر تبدیل موجک WT عملکرد بهتری نسبت به سایر مدل‌های مورد مطالعه دارد. همچنین، مدل WDVR نسبت به سایر مدل‌ها از دقت بیشتری برخوردار بود.

زو و همکاران [۲۹] از مدل‌های ترکیبی WT-ANN، WT-SVM، WT-MLR و WT-RF برای پیش‌بینی غلظت اکسیژن محلول در آب رودخانه دانگجیانگ چین استفاده کرد. نتایج نشان داد مدل‌های ترکیبی از مدل‌های موجک بهتر عمل می‌کنند. با توجه به اینکه الگوهای ترکیبی حافظه مدل را افزایش می‌دهند، می‌توان عملکرد مدل‌ها را افزایش داد.

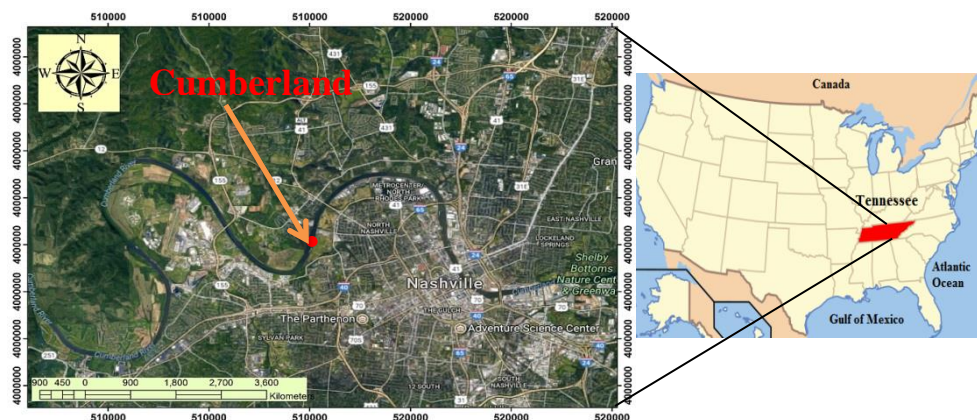
به طور کلی، با توجه به مواد یادشده و یافته‌های تحقیق و افزایش جمعیت و رشد شهرنشینی همراه با توسعه فعالیت‌های صنعتی و کشاورزی، منجر به افزایش تعداد منابع آلاینده و میزان پساب‌های تخلیه‌شده از سوی آنها به منابع آب سطحی از جمله رودخانه‌ها شده است. تخلیه فاضلاب‌ها در بدنه‌های آبی عموماً منجر به افت کیفیت آب در محل تخلیه و پایین‌دست رودخانه می‌شود. هم‌زمان با رشد روزافزون جمعیت و در نتیجه، لزوم کنترل کیفیت منابع محدود آب، نیاز به استفاده از ابزارهای مدیریتی از جمله مدل‌های شبیه‌سازی کیفیت آب به طور چشمگیری افزایش یافته است. مدل‌های ریاضی این فرصت

### مواد و روش‌ها

#### منطقه مطالعه شده

رودخانه کامبرلند از رودخانه‌های مهم جنوب ایالات متحده بوده که طول آن ۱۱۰۶ کیلومتر است. این رودخانه در حوضه آبریز جنوب ایالت کنتاکی ۸ در مساحتی حدود ۴۷۰۰ کیلومترمربع واقع شده است. همچنین، رودخانه کامبرلند از شهرستان لچر در کنتاکی شرقی در دشت کامبرلند آغاز می‌شود و به رودخانه اوهایو در اسمیث‌لند می‌ریزد. این رودخانه بین طول‌های جغرافیایی " ۵۷' ۵۱° و ۸۲ درجه تا " ۲۲' ۳۶° ۸۴ شرقی و عرض‌های جغرافیایی " ۵۰' ۷' ۳۷ تا " ۲۸' ۵۲° ۳۸ درجه شمالی در ایالت تنسی واقع شده است. در شکل ۱ موقعیت ایستگاه مطالعه شده در طول جغرافیایی " ۵۶' ۴۹° ۸۶ درجه و عرض جغرافیایی " ۵۹' ۱۰° ۳۶ نشان داده شده است. در این پژوهش برای تخمین میزان اکسیژن محلول در آب از داده‌های ماهانه اکسیژن محلول در آب (میلی گرم در لیتر)، بارش (میلی متر)، دبی جریان (مترمکعب بر ثانیه) و دما (درجه سانتی گراد) مربوط به ایستگاه کامبرلند طی سال آماری ۲۰۱۰-۲۰۲۰ که از سازمان زمین‌شناسی ایالات متحده اخذ شد، استفاده شد.

را فراهم می‌آورند که با پیاده‌سازی ساختار شماتیکی از یک حوضه آبریز واقعی، فرایندهای طبیعی و هیدرولوژیکی مرتبط با سیستم منابع آب و روابط حاکم بین عرضه و تقاضا شبیه‌سازی شود تا از این طریق شیوه مدیریتی ارزیابی شده و روش‌ها و تکنولوژی‌های مناسب برای کاهش و کنترل آلاینده‌های ورودی شناسایی و استفاده شوند. از سوی دیگر، کاهش کیفیت آب رودخانه کامبرلند، که مهم‌ترین منبع تأمین آب در بخش‌های مختلف و مناطق مجاور از جمله تنسی است، به دلیل تأثیر مواد شیمیایی احیاکننده، به‌ویژه مواد آلی و تخلیه فاضلاب مشکلات زیادی ایجاد کرده است. به بیان دیگر، پساب‌های صنعتی و خانگی مشکلات زیادی را ایجاد کرده است. بنابراین، نیاز به مدل‌سازی اکسیژن محلول در آب در این رودخانه برای بهبود کیفیت آن ضروری است. در این مطالعه، از مدل‌های شبکه عصبی مصنوعی- موجک، شبکه عصبی مصنوعی- خفاش و شبکه عصبی مصنوعی- گرگ خاکستری برای برآورد غلظت اکسیژن محلول در رودخانه کامبرلند، تنسی بر اساس متغیرهای اندازه‌گیری شده مانند اکسیژن محلول، سرعت جریان و دما استفاده شد. از ایستگاه کامبرلند در مقیاس زمانی ماهانه به دست آمده است.



شکل ۱. منطقه مطالعه شده


مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس‌انتشار خطا با ساختار

#### شبکه عصبی مصنوعی

امروزه، شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد [۳۰]. ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل

برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد [۳۲]. نمونه‌ای از ساختار شبکه سه‌لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی و یک لایه خروجی در شکل ۲ نشان داده شده است.

شبکه پیش‌خور و تعداد سه لایه به طور رضایت‌بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد [۳۱]. از رایج‌ترین توابع محرک استفاده‌شده در شبکه‌های انتشار



شکل ۲. نمای کلی یک شبکه عصبی مصنوعی سه‌لایه

موجک‌ها نمونه‌های انتقال یافته<sup>۱</sup> و تفکیک شده سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و به‌شدت میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرار داد [۳۵].

تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته تابع  $f(t)$  به صورت روابط ۱ و ۲ تعریف می‌شود [۳۳].

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

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi \left( \frac{t-\tau}{s} \right) \quad (2)$$

رابطه ۲ یک رابطه با دو متغیر  $s$  و  $\tau$  است که  $s$  پارامتر مقیاس (عکس فرکانس) و  $\tau$  پارامتر انتقال هستند. علامت \* نیز نشان‌دهنده مزدوج مختلط است.  $\psi$  تابع پنجره یا موجک مادر و  $\frac{1}{\sqrt{|s|}} \psi \left( \frac{t-\tau}{s} \right)$  موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند [۳۴]. واژه مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال‌یافته و مقیاس‌شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر

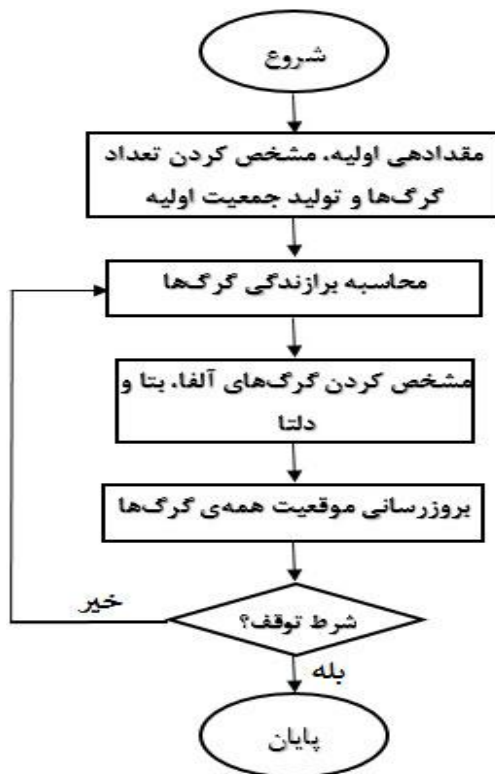
### تبدیل موجک

تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه ارائه شده 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 روی هر یک از این پنجره‌ها به صورت جداگانه انجام می‌گیرد [۳۳]. 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 بیان 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 است [۳۴]. 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،

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

**ترتیب الگوریتم**

- برازندگی کلیهٔ جواب‌ها محاسبه شده و سه جواب برتر به عنوان alpha, beta, delta تا پایان الگوریتم انتخاب می‌شوند.
- در هر تکرار سه جواب برتر (گرگ‌های alpha, beta, delta) قابلیت تخمین موقعیت شکار را دارد و این کار را در هر iteration با استفاده از رابطهٔ زیر انجام می‌دهند:
- در هر تکرار بعد از تعیین موقعیت گرگ‌های alpha, beta, delta، آپدیت موقعیت بقیه جواب‌ها با تبعیت از آنها انجام می‌شود.
- در هر تکرار بردار (a و به تبع آن) A و C آپدیت می‌شوند.
- در پایان تکرارها موقعیت گرگ alpha به عنوان نقطهٔ بهینه معرفی می‌شود.



شکل ۳. فلوچارت الگوریتم گرگ خاکستری

پنجره‌هاست. علامت (...) نیز نشان‌دهندهٔ ضرب برداری دو تابع در فضای سیگنال است.

**الگوریتم گرگ خاکستری**

الگوریتم گرگ خاکستری GWO یک الگوریتم فراکاوشی است که از ساختار سلسله‌مراتبی و رفتار اجتماعی گرگ‌های خاکستری هنگام شکار کردن الهام گرفته است [۳۶]. این الگوریتم مبتنی بر جمعیت بوده، فرایند ساده‌ای دارد و به‌سادگی قابلیت تعمیم به مسائل با ابعاد بزرگ را دارد. گرگ‌های خاکستری به عنوان شکارچیان رأس در نظر گرفته می‌شوند، که در بالای هرم زنجیرهٔ غذایی هستند. گرگ‌های خاکستری ترجیح می‌دهند در یک گروه (دسته) زندگی کنند، هر گروه به طور متوسط ۵-۱۲ عضو دارد. همهٔ اعضای این گروه دارای سلسله‌مراتب تسلط اجتماعی بسیار دقیق هستند و وظایف خاصی دارند. در هر گله از گرگ‌ها برای شکار کردن ۴ درجه وجود دارد که مانند شکل ۳ به صورت یک ساختار هرمی مدل می‌شود [۳۶].

- 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 سلسله‌مراتب 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 است که به صورت زیر تشریح می‌شود.
- مشاهدهٔ 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)

## الگوریتم خفاش

هوش جمعی از قوی‌ترین تکنیک‌های بهینه‌سازی است که بر مبنای رفتارهای گروهی است [۳۷]. الگوریتم خفاش از دسته الگوریتم‌های فراشناختی است که الهام‌گرفته 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 به وسیله 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 روبه‌روی محیط اطراف خود رسم کند و محیط اطراف را حتی در تاریکی مطلق به خوبی ببیند. با استفاده از این سیستم، خفاش‌ها می‌توانند اجسام متحرک مثل حشرات و اجسام بی‌حرکت مثل درختان را تشخیص دهند [۳۷].

الگوریتم 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 ریزخفاش‌ها نام دارند. ریزخفاش‌ها از این ویژگی برای پرواز در شب و شکار استفاده می‌کنند. پژواک‌یابی ریزخفاش‌ها در عمل یک سامانه ادراکی است که در آن موج‌های فراصوتی برای به

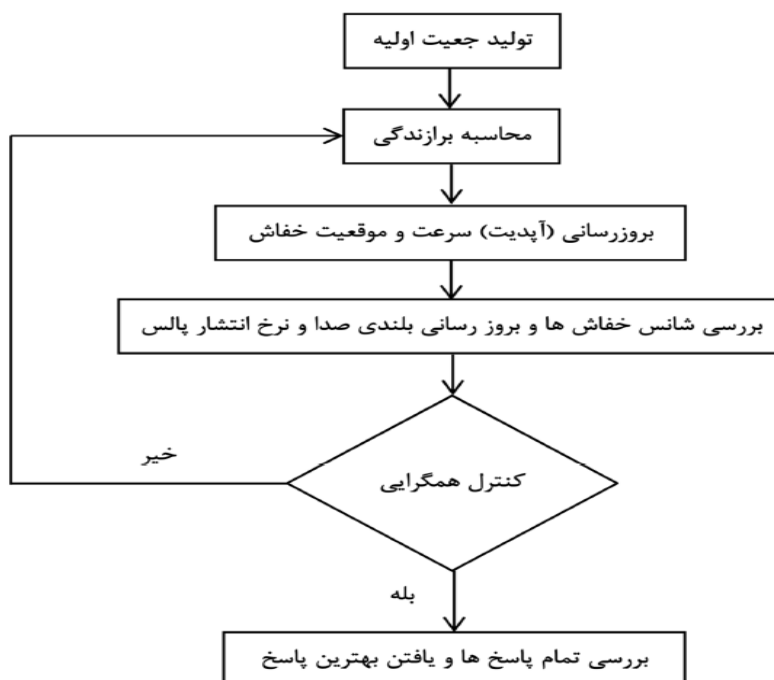
دست آوردن پژواک، تولید می‌شوند. مغز و دستگاه عصبی خفاش با مقایسه موج‌های فرستاده‌شده و موج‌های بازتاب‌شده می‌تواند تصویری از فضای پیرامون و جزئیاتش را برای خود بسازد. این توانایی به ریزخفاش‌ها اجازه می‌دهد تا در تاریکی مطلق شکارشان را شناسایی کنند [۳۷].

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

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

خفاش‌ها به صورت تصادفی با سرعت  $V_i$  در موقعیت  $X_i$  با فرکانس ثابت  $f_{min}$  با طول موج متغیر  $\lambda$  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  $r \in (0, 1)$  را طبق نزدیکی طعمه خود مطابقت دهند.

اگرچه بلندی صدا می‌تواند به شیوه‌های 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 ۴. فلوچارت الگوریتم بهینه‌سازی خفاش

## نتایج و بحث

انتخاب ترکیب مناسب پارامترهای ورودی از مهم‌ترین اقدامات فرایند مدل‌سازی است. انتخاب پارامترهای ورودی اولیه تأثیرگذار برای آموزش ماهیت سازوکار حاکم بر پدیده سبب عملکرد مطلوب مدل‌های هوش مصنوعی خواهد شد. بنابراین، برای شبیه‌سازی میزان اکسیژن محلول در آب رودخانه کامبرلند سعی شد مؤثرترین پارامتر برای آموزش مدل‌ها انتخاب شود که در جدول ۲ نشان داده شده است [۳۸]. در این پژوهش به منظور تخمین میزان اکسیژن محلول در آب رودخانه از داده‌های ماهانه ایستگاه کامبرلند طی دوره آماری ۲۰۱۰ تا ۲۰۲۰ استفاده شد. که در جدول ۱ مقادیر داده‌های مورد استفاده نشان داده شده است. برای مدل‌سازی، پارامترهای دبی جریان (Q) و دما (T) در گام‌های زمانی t و t-1 به عنوان ورودی و میزان اکسیژن محلول در آب (DO) به عنوان پارامتر خروجی مدل‌ها به کار برده شد. همچنین، در جدول ۲ ترکیب‌های مختلف ورودی نشان داده شد. درخور یادآوری است برای مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده برای تست، به صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد [۳۹ و ۴۰]. در ادامه، نتایج مدل‌های استفاده‌شده ارائه می‌شود.

## ارزیابی و عملکرد مدل‌ها

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب تبیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب نش-ساتکلیف (NS) طبق روابط ۳-۶ استفاده شد. بهترین مقدار برای این سه معیار به ترتیب یک، صفر، صفر و یک است.

$$R^2 = \left[ \frac{\sum_{i=1}^n (M_{oi} - \bar{M}_0)(M_{ei} - \bar{M}_e)}{\sqrt{\sum_{i=1}^n (M_{oi} - \bar{M}_0)^2 \cdot \sum_{i=1}^n (M_{ei} - \bar{M}_e)^2}} \right]^2, 0 \leq R^2 \leq 1 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (M_{ei} - M_{oi})^2}, 0 \leq RMSE \leq +\infty \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |M_{ei} - M_{oi}|, 0 \leq MAE \leq +\infty \quad (5)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (M_{ei} - M_{oi})^2}{(\sum_{i=1}^n (M_{ei} - \bar{M}_e))^2}, -\infty < NSE < 1 \quad (6)$$

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

جدول ۱. خصوصیات آماری پارامتر استفاده‌شده طی دوره آماری (۲۰۱۰-۲۰۲۰)

Parameter	Training			Testing		
	Minimum	Mean	Maximum	Minimum	Mean	Maximum
Q(m <sup>3</sup> /s)	1.203	25.692	156.139	4.295	32.347	70.593
T(°C)	5.33	17.204	28.41	5.62	16.272	26.18
DO(mg/l)	5.53	9.588	14.96	6.03	9.424	13.02

جدول ۲. ترکیب‌های منتخب پارامترهای ورودی به مدل‌های هیبریدی بررسی‌شده

Number	Input	Output
1	Q(t)	DO(t)
2	Q(t), T(t)	DO(t)
3	Q(t), T(t), Q(t-1)	DO(t)
4	Q(t), T(t), Q(t-1), T(t-1)	DO(t)

کاهش سرعت و دقت شبکه می‌شود [۴۱]. برای نرمال‌سازی داده‌ها از رابطه ۷ استفاده شد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

در این میان، یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل است این عمل به خصوص وقتی دامنه تغییرات ورودی‌ها زیاد باشد، کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث

## نتایج بررسی عملکرد مدل‌های هیبریدی

در این پژوهش برای شبیه‌سازی میزان اکسیژن محلول در آب رودخانه کامبرلند، مدل‌ها و الگوریتم‌های نوین با یک مجموعه داده مشاهده‌ای مورد تجزیه و تحلیل قرار گرفتند و بیشترین کارایی برای مدل‌سازی و تحلیل بیشتر انتخاب شد. این مرحله دارای چهار الگو که به عنوان بهترین الگوهای ترکیبات ورودی انتخاب شدند که در جدول ۲ بیان شد. همچنین، برای هر مدل هیبریدی شامل شبکه عصبی مصنوعی- موجک، شبکه عصبی مصنوعی- خفاش و شبکه عصبی مصنوعی- گرگ خاکستری از هر چهار

ترکیب در مراحل آموزش و تست استفاده می‌شود [۴۲]. معمولاً در پژوهش‌های اخیر ارزیابی عملکرد شبکه‌های هوش مصنوعی نسبت به یکدیگر بر اساس ضریب RMSE قرار می‌دهند که محققان بسیاری این شاخص‌ها را مورد تأیید قرار دادند. هدف اصلی در سیستم‌های مبتنی بر هوش مصنوعی کاهش میزان خطای برآوردی است و بنابراین در این تحقیق ملاک برتری مدل‌ها RMSE است. همان‌طور که در جدول ۳ قابل مشاهده است مدل ترکیبی شبکه عصبی مصنوعی- موجک از خطای کمتری نسبت به سایر مدل‌های هیبریدی مورد بررسی برخوردار است.

جدول ۳. انتخاب ترکیب ورودی بهینه بر اساس RMSE

مدل	شاخص ارزیابی	مرحله	۱	۲	۳	۴
شبکه عصبی مصنوعی- موجک	RMSE(mg/l)	آموزش	۰/۸۵۶	۰/۸۳۲	۰/۷۹۴	۰/۷۶۲
		صحت‌سنجی	۰/۷۷۳	۰/۷۱۲	۰/۶۸۶	۰/۶۵۱
شبکه عصبی مصنوعی- گرگ خاکستری	RMSE(mg/l)	آموزش	۰/۸۹۲	۰/۸۶۶	۰/۸۳۸	۰/۷۹۷
		صحت‌سنجی	۰/۷۹۰	۰/۷۵۵	۰/۷۲۱	۰/۶۸۸
شبکه عصبی مصنوعی- خفاش	RMSE(mg/l)	آموزش	۰/۹۲۴	۰/۸۹۵	۰/۸۷۶	۰/۸۴۲
		صحت‌سنجی	۰/۸۰۴	۰/۷۷۸	۰/۷۴۲	۰/۷۱۲

می‌کنند. از طرفی دیگر، تأثیر دبی رودخانه روی میزان اکسیژن محلول در آب سبب می‌شود که با افزایش دبی رودخانه غلظت آب ناشی از ورود پساب افزایش نیافته و اکسیژن محلول در آب کاهش نیابد.

## ارزیابی عملکرد مدل

در این تحقیق به منظور شبیه‌سازی میزان اکسیژن محلول در آب رودخانه کامبرلند واقع در ایالات متحده از مدل‌های نوین و توسعه‌یافته (GWO-ANN, BA-ANN, WANN) استفاده شد.

به منظور ارزیابی دقیق مدل‌های مورد بررسی شامل شبکه عصبی مصنوعی- موجک، شبکه عصبی مصنوعی- خفاش و شبکه عصبی مصنوعی- گرگ خاکستری پس از نرمال‌سازی داده‌های مشاهده‌ای و بهینه کردن وزن‌های مدل شبکه عصبی مصنوعی با استفاده از الگوریتم‌های بهینه‌سازی از شاخص‌های  $R2$ ،  $RMSE$ ،  $MAE$  و  $NSE$  استفاده شد.

بنابراین، به طور خلاصه می‌توان گفت که پس از انتخاب بهترین ترکیب ورودی برای هر مدل، نتایج مدل‌های ترکیبی برای شبیه‌سازی اکسیژن محلول در آب

در جدول ۳ با توجه به ساختارهای مختلف هر مدل، ترکیب متغیر ورودی بهینه بین مدل‌ها متفاوت است. که برای هر مدل مقادیر RMSE برای دو بخش آموزش و صحت‌سنجی برآورد شد. همان‌طور که از جدول ۳ مشخص است برای تمامی مدل‌ها الگوی چهارم بهترین عملکرد را داشته است، زیرا ضریب دارای کمترین RMSE است و این امر را میزان ناشی از افزایش تعداد پارامترهای ورودی دانست که سبب افزایش عملکرد مدل‌ها می‌شود [۴۳]. با توجه به نرمال‌سازی داده‌ها و دامنه صفر تا یک، خطاها بسیار دقیق محاسبه می‌شود. همچنین، با توجه به این که الگوی ترکیبی ۴ تعداد پارامترها یا متغیرهای مؤثر بیشتری را شامل می‌شود، به همان میزان خطا کاهش پیدا می‌کند و بنابراین، الگوی ۴ نسبت به بقیه الگوها دارای ارجحیت است. به گونه‌ای که با افزایش دمای آب رودخانه منجر به کاهش اکسیژن محلول در آب می‌شود. همچنین، کاهش نور، سبب کاهش مقدار اکسیژن آزادشده توسط گیاهان می‌شود، به طوری که اگر نور به شکل کامل به گیاهان کف نرسد، تولید اکسیژن توسط این گیاهان متوقف‌شده و باکتری‌های موجود، اکسیژن را مصرف




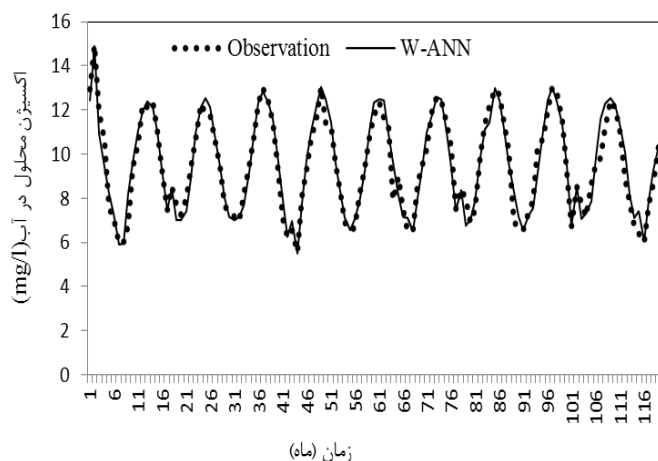
هر سه مدل هیبریدی مقادیر محاسباتی را نزدیک به مقادیر مشاهداتی برآورد کرده، که در این بین مدل W-ANN عملکرد مناسب‌تری نسبت به سایر مدل‌ها داشته است که این عملکرد مناسب در مدل W-ANN ناشی از برابری مقادیر مشاهداتی و محاسباتی است. که این امر با نتایج دهقانی و همکاران [۴۳] و باباعلی و دهقانی [۴۴] مطابقت دارد در تبیین این نتایج می‌توان بیان کرد تبدیل موجکی با جدا کردن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چندمقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی، 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.

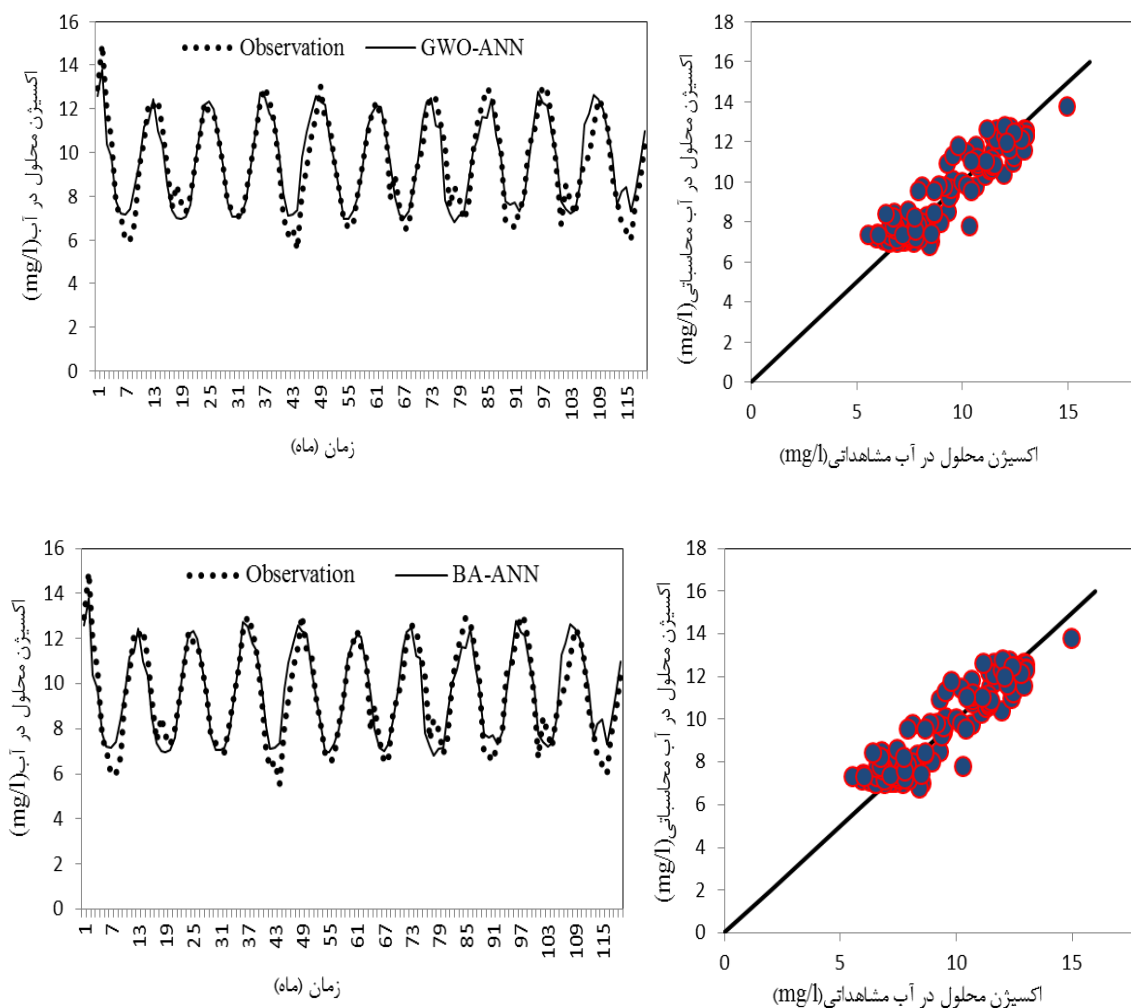
رودخانه مشاهداتی مورد بررسی، طبق جدول ۴ نشان می‌دهد مدل هیبریدی شبکه عصبی مصنوعی- موجک (W-ANN) از عملکرد بهتری به ترتیب نسبت به سایر مدل‌های هیبریدی از جمله شبکه عصبی مصنوعی- گرگ خاکستری (GWO-ANN) و شبکه عصبی مصنوعی- خفاش (BA-ANN) دارد، به گونه‌ای که طبق شاخص‌های ارزیابی مدل شبکه عصبی مصنوعی- موجک دارای مقادیر  $RMSE=0.651$  (mg/l),  $R^2=0.958$  و  $MAE=0.334$  و  $NS=0.962$  در مرحله تست است.

در شکل ۵ نمودار تغییرات سری زمانی و پراکنش مقادیر مشاهداتی و محاسباتی بیان شد. در این شکل مدل شبکه عصبی مصنوعی- موجک در برآورد نقاط ماکزیمم و مینیمم خطای کمتری دارد و همچنین، مدل‌های شبکه عصبی مصنوعی- گرگ خاکستری و شبکه عصبی مصنوعی- خفاش در برآورد مقادیر میانی از دقت مطلوبی برخوردار است و در برآورد مقادیر مینیمم و ماکزیمم دقت مطلوبی ندارند، به گونه‌ای که طبق پراکنش  $Y=X$

جدول ۴. عملکرد مدل‌های هیبریدی بررسی شده در شبیه‌سازی اکسیژن محلول در آب رودخانه

صحت‌سنجی				آموزش				مدل
NS	MAE (mg/l)	RMSE (mg/l)	R <sup>2</sup>	NS	MAE (Mg/l)	RMSE (mg/l)	R <sup>2</sup>	
۰/۹۶۲	۰/۳۳۴	۰/۶۵۱	۰/۹۵۸	۰/۹۳۵	۰/۴۵۶	۰/۷۶۲	۰/۹۴۱	شبکه عصبی مصنوعی- موجک
۰/۹۴۸	۰/۳۴۸	۰/۶۸۸	۰/۹۴۴	۰/۹۲۳	۰/۴۷۲	۰/۷۹۷	۰/۹۲۸	شبکه عصبی مصنوعی- گرگ خاکستری
۰/۹۱۸	۰/۳۷۸	۰/۷۱۲	۰/۹۲۵	۰/۸۷۳	۰/۵۲۷	۰/۸۴۲	۰/۹۰۱	شبکه عصبی مصنوعی- خفاش





شکل ۵. نمودار پراکنش و مقادیر مشاهداتی- محاسباتی مدل‌های هیبریدی بررسی شده

**جمع‌بندی**

به طور کلی، می‌توان بیان کرد که مدل‌های توسعه‌یافته برای شبیه‌سازی اکسیژن محلول در آب رودخانه کامبرلند واقع در ایالات متحده به نتایج پیش‌بینی مطلوب رسیده‌اند. نتایج تحقیق نشان می‌دهد هر چه تعداد پارامترهای مؤثر (متغیرهای وابسته) بیشتر باشد عملکرد شبکه بهتر خواهد بود. همچنین، هرچه میزان ورودی به شبکه بیشتر باشد، کارایی و دقت مدل افزایش خواهد یافت.

در این تحقیق از مدل هیبریدی شبکه عصبی مصنوعی برای شبیه‌سازی اکسیژن محلول در آب رودخانه استفاده شد. مطالعات محققان مختلف در سراسر دنیا نشان می‌دهد عموماً شبکه عصبی مصنوعی به دلیل وجود ماهیت سعی و خطا در برآورد وزن‌ها و بایاس‌ها عملکرد مطلوبی برای برآورد پدیده‌های هیدرولوژیکی ندارد. به

بیانی، ساده‌تر محاسبه وزن‌ها و بایاس‌ها در مدل شبکه عصبی مصنوعی بر مبنای روش سعی و خطا صورت می‌گیرد که در این تحقیق نیز برای بهبود عملکرد مدل مستقل و منفرد شبکه عصبی مصنوعی در پیدا کردن وزن‌ها و بایاس‌های بهینه از سه الگوریتم بهینه‌ساز فراابتکاری در تحقیق استفاده شد. نتایج نشان داد مدل‌های هیبریدی عملکرد قابل قبولی در افزایش توانایی برآورد مدل شبکه عصبی مصنوعی دارند.

همچنین، با توجه به معیارهای ارزیابی نتیجه شد که هر سه مدل مورد بررسی، می‌توانند با دقت نسبتاً بالایی‌سازی اکسیژن محلول در آب رودخانه را برآورد کنند. در این میان، مدل W-ANN دقت بیشتر و خطای کمتری نسبت به مدل‌های GWO-ANN و BA-ANN از خود نشان داده است.

- [9]. Radwan M, Willems P, El-Sadek A, Berlamont J. Modelling of dissolved oxygen and biochemical oxygen demand in river water using a detailed and simplified model. *Int J River Basin Manage.* 2003; 1(4):97-103.
- [10]. Ahmed AAM, Shah SMA. Application of adaptive neuro-fuzzy inference system (ANFIS) to estimate the biochemical oxygen demand (BOD) of Surma River. *Journal of King Saud University-Engineering Sciences.* 2017; 29(3):237-243.
- [11]. Yaseen ZM, Ehteram M, Sharafati A, Shahid S, Al-Ansari N, El-Shafie A. The integration of nature-inspired algorithms with least square support vector regression models: application to modeling river dissolved oxygen concentration. *Water.* 2018; 10(3):11-24.
- [12]. Diaz RJ, Rosenberg R. Spreading dead zones and consequences for marine ecosystems. *Science.* 2008; 321(4):926-929.
- [13]. Salcedo-Sanz S, Deo RC, Carro-Calvo L, Saavedra-Moreno B. Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theoretical and Applied Climatology.* 2016; 125(4):13-25.
- [14]. Afan HA, El-Shafie A, Yaseen ZM, Hameed MM, Mohtar HW, Hussain A. ANN based sediment prediction model utilizing different input scenarios. *Water Resources Management.* 2015; 29(4):1231-1245.
- [15]. Gocić M, Motamedi S, Shamshirband S, Petković D, Ch S, Hashim R, Arif M. Soft computing approaches for forecasting reference evapotranspiration. *Comput. Electron. Agric.* 2015; 113(4):164-173
- [16]. Ross AC, Stock AC. An assessment of the predictability of column minimum dissolved oxygen concentrations in Chesapeake Bay using a machine learning model. *Estuarine, Coastal and Shelf Science.* 2019; 221:53-65
- [17]. Shi P, Li G, Yuan Y, Huang G, Kuang L. Prediction of dissolved oxygen content in aquaculture using Clustering-based Softplus Extreme Learning Machine. *Computers and Electronics in Agriculture.* 2019; 157(4):329-338
- [18]. Li W, Fang H, Qin G, Tan X, Huang Z, Zeng F, Du H, Li S. Concentration estimation of dissolved oxygen in Pearl River Basin using input variable selection and machine learning techniques. *Science of The Total Environment.* 2020; 731:128-139
- [19]. Adhaileh MH, Alsaade FW. Modelling and Prediction of Water Quality by Using Artificial Intelligence. *Sustainability.* 2021; 13(4):42-59
- در مجموع، نتایج این تحقیق نشان‌دهنده برتری مدل شبکه عصبی مصنوعی-موجک در مقایسه با سایر الگوریتم‌ها داشته است (بر اساس معیار RMSE). در مجموع، این تحقیق نشان می‌دهد استفاده از مدل شبکه عصبی مصنوعی-موجک می‌تواند در زمینه برآورد اکسیژن محلول در آب رودخانه مؤثر باشد. همچنین، این مدل می‌تواند به نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های سطحی مفید باشد. و گامی در اتخاذ تصمیم‌های مدیریتی برای بهبود کمیت منابع آب‌های سطحی است.

### منابع

- [1]. Krishna RS, Mishra J, Ighalo JO. Rising Demand for Rain Water Harvesting System in the World: A Case Study of Joda Town, India. *World Scientific News,* 2020; 146(4): 47-59.
- [2]. Forstinus NO, Ikechukwu NE, Emenike MP, Christiana AO. Water and waterborne diseases: A review, *International Journal of Tropical Diseases and Health.* 2016; 12(4): 1-14.
- [3]. Ighalo JO, Adeniyi AG, Adeniran JA, Ogunniyi S. A systematic literature analysis of the nature and regional distribution of water pollution sources in Nigeria”, *Journal of Cleaner Production.* 2020; 124(3):566-576.
- [4]. Khalil B, Adamowski J, Abdin A, Elsaadi A. A statistical approach for the estimation of water quality characteristics of ungauged streams/watersheds under stationary conditions. *Journal of Hydrology.* 2019; 569(4):106-116.
- [5]. Dizaji AR, Hosseini SA, Rezaverdinejad V, Sharafati A. Groundwater contamination vulnerability assessment using DRASTIC method, GSA, and uncertainty analysis. *Arabian Journal of Geosciences.* 2020; 13(4):1-15.
- [6]. Kisi O, Ay M. Comparison of ANN and ANFIS techniques in modeling dissolved oxygen. *Sixteenth International Water Technology Conference, IWTC-16, Istanbul, Turkey,* 2012: 1-10.
- [7]. Dogan E, Lent Sengorur B, Koklu R. Modeling biological oxygen demand of the Melen River in Turkey using an artificial neural network technique. *Journal of Environmental Management.* 2009; 90(5):19-35.
- [8]. Chapman D. *Water Quality Assessments*, ed f, editor. London: Chapman and Hall Ltd. 1992:88-104.

- [20]. Asadollah SB, Sharafati A, Motta D, Yaseen ZM. River water quality index prediction and uncertainty analysis: A comparative study of machine learning models. *Journal of Environmental Chemical Engineering*.2021; 9 (4): pp.228-245
- [21]. Ahmed MH, Lin LS. Dissolved oxygen concentration predictions for running waters with different land use land cover using a quantile regression forest machine learning technique. *Journal of Hydrology*.2021; 597:324-341
- [22]. Guo H, Hung JJ, Zhu X, Wang B, Tiang S, Xu W, Mai Y. A generalized machine learning approach for dissolved oxygen estimation at multiple spatiotemporal scales using remote sensing. *Environmental Pollution*.2021; 288(4): 58-69
- [23]. Zhu N, Ji X, Tan J, Jiang Y, Gou Y. Prediction of dissolved oxygen concentration in aquatic systems based on transfer learning. *Computers and Electronics in Agriculture*.2021;180: 385-399
- [24]. Tiyasha T, Tung TM, Bhagat SK, Tan ML, Jawad AH, Mohtar W, Yassen ZM. "Functionalization of remote sensing and on-site data for simulating surface water dissolved oxygen: Development of hybrid tree-based artificial intelligence models. *Marine Pollution Bulletin*.2021; 170:412-431
- [25]. Huang J, Liu S, Gha Hassan S, Xu L, Hunag C. A hybrid model for short-term dissolved oxygen content prediction. *Computers and Electronics in Agriculture*. 2021; 186(4): 325-339
- [26]. Liu H, Yang R, Duan Z, Wu H. A hybrid neural network model for marine dissolved oxygen concentrations time-series forecasting based on multi-factor analysis and a multi-model ensemble. *Engineering*.2021;19(4):112-128
- [27]. Alizadeh MJ, Kavianpour MR. Development of wavelet-ANN models to predict water quality parameters in Hilo Bay, Pacific Ocean. *Marine Pollution Bulletin*.2015; 98(1-2):171-182
- [28]. Rajaei T, Khani S, Ravansalar M. Artificial intelligence-based single and hybrid models for prediction of water quality in rivers: A review. *Chemometrics and Intelligent Laboratory Systems*.2020; 200(4):186-197
- [29]. Xu C, Chen X, Zhang L. Predicting river dissolved oxygen time series based on stand-alone models and hybrid wavelet-based models. *Journal of Environmental Management*. 2021;295(4):166-178
- [30]. Nourani V, Alami MT, and Aminfar MH. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*.2009; 22(3): 466-472.
- [31]. Nourani V, Kisi Ö, Komasi M. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*.2011;402(3): 41-59.
- [32]. Tokar A, Johnson P. Rainfall-Runoff Modeling Using Artificial Neural Networks. *J Hydrol Eng*.1999; 4(2): 232-239
- [33]. Vapnik VN. *Statistical learning theory*. Wiley, New York.1998
- [34]. Wang D, Safavi AA, Romagnoli JA. Wavelet-based adaptive robust M-estimator for non-linear system identification, *AIChE Journal*. 2000; 46(4):1607-1615.
- [35]. Shin S, Kyung D, Lee S, Taik & Kim J, and Hyun J. An application of support vector machines in bankruptcy prediction model, *Expert Systems with Applications*. 2005;28(4):127-135.
- [36]. Ostu N. A Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man and Cybernetics*. 1979; 9 (1): 62-66.
- [37]. Amuda A, Brest J, Mezura-Montes E. 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*.2013: 1925-1931
- [38]. Nourani V, Kisi Ö, Komasi M. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*.2011; 402(3): 41-59.
- [39]. Nagy H, Watanabe K, Hirano M. Prediction of sediment load concentration in rivers using artificial neural network model, *Journal of Hydraulics Engineering*.2002; 128: 558-559.
- [40]. Kisi O, Karahan M, Sen Z. River suspended sediment modeling using fuzzy logic approach. *Hydrol Process*.2006; 20: 4351-4362.
- [41]. Zhu YM, Lu XX, Zhou Y. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment. *Geomorphology*.2007;84(1): 111-125.
- [42]. Khosravi K, Nohani E, Maroufinia E, and Pourghasemi HRA. GIS-based flood susceptibility assessment and its mapping in

- Iran: a comparison between frequency ratio and weights of evidence bivariate statistical models with multi-criteria method. *Natural Hazards*.2016; 83(2):1-41
- [43]. Dehghani R, Torabi H. Dissolved oxygen concentration predictions for running waters with using hybrid machine learning techniques. *Modeling Earth Systems and Environment*.2021;11(3):424-436
- [44]. Babaali HR, Dehghani R. Evaluation of the performance of the wavelet neural network model in estimating daily discharge. *Irrigation Science and Engineering*.2017; 6(4):22-35 [Persian]