

Assessment of Surface Water Quality and Water Quality Index (WQI) Modeling Using SVR, SVR-GWO and SVR-PSO (Case Study: Khorramabad, Biranshahr and Alashtar Watersheds, Lorestan Province)

Alireza Sepahvand¹ *, Negar Arjmand² , Nasrin Beiranvand³ 

Received: 08-11-2025, Revised: 08-02-2026, Accepted: 13-04-2026, Published: 17-04-2026

<https://doi.org/10.22034/19.71.6>

Extended Abstract

Introduction

Water quality assessment and prediction play crucial roles in ensuring the sustainability and safety of freshwater resources. That with the rapid urbanization, industrialization and agricultural activities, large amount of river pollution from point or non-point sources have posed increasingly challenges over the world. The ongoing deterioration of water quality has put safe water supplies at risk, causing water pollution incidents and damaging aquatic ecosystems, especially in coastal cities with more prosperous economic development and intensive anthropogenic activities. Throughout human history, access to clean water has been a fundamental necessity. The water supply is essential to human well-being and is seen as a basic prerequisite for human activity and economical utility. Rivers, considered to be the most productive ecosystems and is essential for eliminating and neutralizing different types of contaminants. Thus, it is most frequently mentioned as the surface water sources that are exploited because of its accessibility and quantity, which have accelerated human development and population increase close to water channels. One of the key indicators used to assess water quality is the Water Quality Index (WQI). Various models and methods exist for calculating and estimating this index, with artificial intelligence emerging as a modern and effective approach in recent years. This study aims to model the WQI in the Kashkan watershed using three models: SVR, SVR-GWO, and SVR-PSO.

Materials and Methods

To compare the result of the proposed models' performance, the Cham Anjir, Kaka Reza and Sarab Syed Ali hydrometry stations in Khorramabad, Biranshahr and Alashtar sub-watersheds (a part of Kashkan watershed) in western of Iran, is used as a case study area. The geographic coordinates of the Cham Anjir, Bahram Jo, Kaka Reza and Sarab Syed Ali are 48° 15' 34" E 33° 26' 55" N, 48° 17' 45" E 33° 34' 8" N, 48° 13' 51" E 33° 43' 39" N and 48° 12' 14" E 33° 44' 55" N, respectively. The studied area has a semiarid climate with a mean annual rainfall Less than 500 mm. The studied area has a maximum elevation of 3578 m in Alashtar watershed and the minimum elevation of 1158 m in Khorramabad watershed. Water quality parameters were collected over a ten-year period (2014–2023) at hydrometric stations located at the outlet of sub-watersheds within the Kashkan basin. The input data for the modeling process included TDS, EC, pH, CO₃, HCO₃, Cl, SO₄, Ca, Mg, Na, and K, which were used to calculate the WQI. For model development, 70% of the data was used for training and the remaining 30%

1-Associate Professor, Department of Range and Watershed Management Engineering, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran. Sepahvand.a@lu.ac.ir. 09163679256.

2- Ph.D. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran.

3-Ph.D. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran.

for validation. The performance of the models was evaluated using error metrics such as MAE, RMSE, correlation coefficient (CC), and visual tools including Taylor and violin box plots.

Results and Discussion

The results shown that the SVR-GWO model outperformed the SVR and SVR-PSO models. In the training phase, it achieved MAE = 0.986, CC = 0.966, and RMSE = 0.792, while in the testing phase, the values were MAE = 0.936, CC = 0.871, and RMSE = 3.727, respectively. These findings indicate that SVR-GWO was the most accurate and reliable model for estimating the Water Quality Index (WQI). Moreover, Thus, the Taylor diagram also concluded that SVR-GWO model was the most reliable soft computing technique for the prediction of WQI. Thus, the violin cum box plot also supported the conclusion that SVR-GWO model had an edge on SVR and SVR-PSO in the prediction of WQI. Conversely, the basic SVR model showed comparatively weaker performance. In general, the SVR-GWO model, is the powerful model for the prediction of Water Quality Index (WQI). Therefore, according to the obtained results from this research, these optimal models can be used to costly and time-consuming tasks of the estimation of Water Quality Index (WQI) from river. Also, these models can be used to estimate the Water Quality Index (WQI) of nearby rivers by/without hydrometry station for the management of the quantity and quality of surface water. In such a case, soft computing techniques (SVR-GWO model) can be used to assess water quality.

Conclusion

The present study focused on the development of a SVR, SVR-GWO, and SVR-PSO models to estimate the water quality index(WQI). For this purpose, the quality parameters data of the Cham Anjir, Sarab Syed Ali and Kaka Reza stations in Khorramabad, Alashtar and Biranshahr sub-watersheds composed of Water Quality Index (WQI), were used. In general, the major conclusions of the study are as follows: among those models with the highest performance, the SVR-GWO has the highest performance in both testing and training phases. The SVR-GWO predicted data are closer to observational data compared with the other model's output data. Besides, the SVR-GWO is the nearest predicted model with observational data. The SVR model is one of the most extensively used data driven models in the natural literature, while the usages of other data-driven models are comparatively lesser. Also, the structure of the SVR-GWO is very simple and very less time consumable. Thus, the SVR-GWO model can be useful in the Water Quality Index (WQI) modeling not only for accuracy but also for its time-saving nature and simple structure compared with other models. Overall, the findings suggest that artificial intelligence techniques, due to their cost-effectiveness and speed, offer strong capabilities for assessing and predicting surface water quality. The WQI can also serve as a practical tool for the optimal management of surface and groundwater resources in watershed areas.

Keywords: Lorestan Province, Kashkan Watershed, Water Quality Index (WQI), Artificial Intelligence.

Article Type: Research Article

Conflicts of interest: The authors have no conflict of interest.

Data availability: Data will be provided for reasonable and formal request upon of corresponding author.

Authors' contribution: Alireza Sepahvand: Supervisor, Conceptualization, Supervision, Methodology, Final editing;

Negar Arjmand: Analysis, Investigation and modeling, Writing original draft;

Nasrin Beiranvand: Writing, Preparing data, Modelling, Resources, Software, Manuscript editing, Editing.

Citation: Sepahvand A, Arjmand N, Beiranvand N. Assessment of surface water quality and Water quality Index (WQI) modeling using SVR, SVR-GWO and SVR-PSO (Case study: Khorramabad, Biranshahr and Alashtar watersheds, Lorestan province). *jwmseir* 2025; 19(71): 87-105

Iran-Watershed Management Science & Engineering, Year 2025, Vol 19, No 71, 87-105

Publisher: Watershed Management Society of Iran

© Author(s)



بررسی کیفیت آب سطحی و مدل سازی شاخص کیفیت آب با استفاده از SVR-PSO و SVR-GWO (منطقه مورد مطالعه: حوزه آبخیز کشکان، لرستان)

علیرضا سپهوند^۱، نگار ارجمند^۲، نسرین بیرانوند^۳

تاریخ دریافت: ۱۴۰۴/۰۸/۱۷، تاریخ داوری: ۱۴۰۴/۱۱/۱۹، تاریخ پذیرش: ۱۴۰۵/۰۱/۲۴، تاریخ انتشار: ۱۴۰۵/۰۱/۳۱

<https://doi.org/10.22034/19.71.6>


چکیده

یکی از شاخص‌های مهم بررسی کیفیت آب، شاخص کیفیت آب (WQI) است. مدل‌ها و روش‌های مختلفی برای تعیین و تخمین این شاخص وجود دارد که هوش مصنوعی از روش‌های جدید و امروزی است که برای تعیین شاخص کیفیت آب مورد استفاده قرار می‌گیرد. هدف این تحقیق مدل سازی شاخص کیفیت آب بخشی از حوزه آبخیز کشکان با استفاده از مدل‌های SVR، SVR-GWO و SVR-PSO بوده است. در این تحقیق در محل ایستگاه‌های هیدرومتری (خروجی حوضه‌ها) خصوصیات کیفی آب در دوره ۱۰ ساله (۱۴۰۲-۱۳۹۳) اندازه‌گیری شد. داده‌های استفاده شده در این تحقیق برای مدل سازی کیفیت آب شامل TDS، EC، PH، CO₃، HCO₃، Cl، SO₄، Ca، Mg، Na و K بودند. در ادامه برای بخش مدل سازی، خصوصیات کیفی آب به‌عنوان داده‌های ورودی و شاخص WQI به‌عنوان داده خروجی به مدل معرفی شد که ۷۰ درصد کل داده‌ها برای مرحله آموزش و ۳۰ درصد باقی‌مانده برای صحت‌سنجی مدل استفاده شدند. برای ارزیابی مدل‌ها از معیارهای سنجش خطا شامل MAE، C.C، RMSE، نمودارهای تیلور و ویولین باکس استفاده شد. نتایج این تحقیق نشان داد که مدل SVR-GWO بر اساس میزان معیارهای ارزیابی خطا MAE و RMSE در مرحله آموزش به‌ترتیب برابر ۰/۹۸۶، ۰/۹۶۶ و ۰/۷۹۲ و در مرحله آزمایش به‌ترتیب برابر ۰/۹۳۶، ۰/۸۷۱ و ۳/۷۲۷ نسبت به نتایج مدل‌های SVR و SVR-PSO عملکرد بهتری داشته است و به‌عنوان مدل برتر برای تخمین میزان شاخص کیفیت آب (WQI) انتخاب شد. همچنین نتایج مربوط به نمودارهای تیلور و ویولین باکس نشان دادند که مدل SVR-GWO دارای بیشترین کارایی برای تعیین شاخص کیفیت آب (WQI) است. علاوه بر این مشخص شد که مدل SVR نسبت به سایر مدل‌ها دارای عملکرد ضعیف‌تری بود. به‌طور کلی با توجه به نتایج این تحقیق، می‌توان بیان نمود که روش‌های هوش مصنوعی با توجه به میزان هزینه و زمان کم، در ارزیابی و پیش‌بینی کیفیت آب سطحی از قدرت بالا و عملکرد خوبی برخوردارند. همچنین می‌توان از این شاخص برای مدیریت بهینه کیفیت آب‌های سطحی و زیرزمینی در حوزه‌های آبخیز استفاده نمود.

کلیدواژه‌ها: استان لرستان، حوزه آبخیز کشکان، شاخص کیفیت آب (WQI)، هوش مصنوعی.

نوع مقاله: پژوهشی

استناد: سپهوند علیرضا، ارجمند نگار، بیرانوند نسرین. بررسی کیفیت آب سطحی و مدل سازی شاخص کیفیت آب با استفاده از SVR-PSO، SVR-GWO و SVR (منطقه مورد مطالعه: حوزه آبخیز کشکان، لرستان). علوم و مهندسی آبخیزداری ایران. ۱۴۰۴؛ ۱۹(۷۱): ۸۷-۱۰۵
علوم و مهندسی آبخیزداری ایران، سال ۱۴۰۴، دوره ۱۹، شماره ۱۷، صفحه ۸۷-۱۰۵



© نویسندگان

ناشر: انجمن آبخیزداری ایران

۱- دانشیار، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، خرم‌آباد، ایران. (Sepahvand.a@lu.ac.ir). 09163679256.

۲- دانشجوی دکتری، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، لرستان، خرم‌آباد، ایران.

۳- دانشجوی دکتری، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، لرستان، خرم‌آباد، ایران.

آب یکی از اساسی‌ترین منابع طبیعی برای زندگی انسان است که در موارد مختلف مورد استفاده قرار می‌گیرد و در توسعه اجتماعی و اقتصادی بشر نقش کلیدی دارد. با وجود اینکه ۷۱ درصد از سطح زمین را آب پوشانده است، تنها حدود ۲/۵ درصد از آن آب شیرین است؛ بنابراین، مدیریت مناسب منابع آب امری حیاتی برای داشتن یک جامعه توسعه یافته است [۲۰]. امروزه به دلیل افزایش جمعیت، قطع درختان، احداث سدهای مخزنی، شهرسازی و... که از عوامل نابودی چرخه آب در سطح جهان هستند، سبب شده که آب به‌عنوان یک عامل حیاتی و به‌وجودآورنده بحران تلقی شود. با توجه به قرار گرفتن ایران در نواحی خشک و نیمه‌خشک مقدار بارندگی و حجم آب‌های موجود کافی نیست. میانگین حجم نزولات جوی نسبت به خشکی‌های کره زمین به ازای هر کیلومتر مربع ۸۳۰ هزار مترمکعب است، در حالی که این مقدار نسبت به خشکی‌های ایران ۲۵۰ هزار مترمکعب است [۵]. در سال‌های اخیر تخلیه فاضلاب‌های شهری، صنعتی، شیرابه‌ها و زباله‌ها به محیط‌زیست باعث آلودگی و کاهش کیفیت منابع آب شده است [۱]. در محیط‌های آبی، اندازه‌گیری میزان اکسیژنی که در دسترس همه حیوانات موجود در آب است، اهمیت دارد. مقدار پایین اکسیژن محلول در آب یکی از عوامل مهم در تعیین کیفیت آب است. یکی از منابع طبیعی که در اثر فعالیت‌های بشر حجم وسیعی از آلودگی‌های شیمیایی و بیولوژیکی به آن دارد می‌شود، رودخانه‌ها هستند [۳۵]. بوم‌سازگان‌های رودخانه‌ای به شدت به کیفیت آب وابسته هستند. پارامترهای فیزیکی و شیمیایی آب نقش مهمی در پایداری و عملکرد آن دارند [۸۷، ۳۷]. کیفیت آب‌های سطحی در سراسر جهان به‌طور قابل توجهی کاهش یافته است، که علت اصلی آن افزایش ورود آلاینده‌های فیزیکی، شیمیایی و زیستی به سامانه‌های آبی است [۱۶، ۸]. این آلودگی‌ها باعث به هم خوردن تعادل بوم‌سازگان‌ها، تهدید تنوع زیستی و به خطر افتادن پایداری منابع آبی مورد نیاز برای انسان و محیط زیست می‌شود [۲، ۸]. ارزیابی کیفیت آب برای بوم‌سازگان‌های رودخانه‌ای و دریاچه‌ای، به دلیل تغییرات شدید اقلیمی و اثرات محیطی اهمیت بالایی دارد [۳۴، ۳۷]. بررسی کیفیت آب یکی از حوزه‌های پژوهشی مهم محیط زیستی در قرن بیست و یکم است. اهمیت این موضوع در نتیجه استفاده گسترده از آب در صنعت، کشاورزی، ساخت‌وساز و مصارف خانگی دوچندان می‌شود، زیرا تمامی این فعالیت‌ها مستلزم حد معینی از کیفیت آب هستند [۶۸، ۵۱]. کیفیت آب، عاملی کلیدی برای کاربردهای گوناگون از جمله تأمین تأمین آب، آبیاری، فعالیت‌های تفریحی و مصارف صنعتی است. تناسب آب برای هر یک از این مصارف به نوع و غلظت آلاینده‌ها بستگی دارد، که معمولاً از طریق پارامترهای استاندارد اندازه‌گیری در قالب شاخص‌های کیفیت آب (WQI) تعیین می‌شود [۸، ۲۲، ۲۵، ۴۱]. WQI با ارائه یک مقدار واحد و قابل فهم، فرآیند تصمیم‌گیری و

ارتباط در زمینه مدیریت منابع آب را تسهیل می‌کند [۸، ۱۵]. نخستین بار هورتون^۲ در سال ۱۹۶۵ مفهوم استفاده از WQI را برای ارزیابی کیفیت آب با در نظر گرفتن چندین متغیر و تبدیل آن‌ها به یک مقدار نهایی مطرح کرد [۴۵، ۶۲]. مقدار نهایی WQI نشان‌دهنده کیفیت و قابلیت استفاده آب است و به همین دلیل ابزاری ارزشمند برای ارزیابی منابع آبی محسوب می‌شود [۱۴، ۶۲]. مدل‌ها و روش‌های مختلفی برای تعیین و تخمین این شاخص وجود دارد که هوش مصنوعی از روش‌های جدید و امروزی است که برای تعیین شاخص کیفیت آب مورد استفاده قرار می‌گیرد. هوش مصنوعی مجموعه‌ای از سیستم‌های کامپیوتری است که می‌تواند بسیاری از کارها مانند استدلال کردن، تصمیم‌گیری، حل مسئله و... را انجام دهد. با افزایش جمعیت، نیمی از مناطق جهان با مسئله مربوط به تأمین آب مواجه هستند که هوش مصنوعی می‌تواند برای مقابله با این کمبود نقش مهمی در جلوگیری از هدر رفتن آب ایفا کند. هوش مصنوعی می‌تواند در شهرهایی که جمعیت زیادی دارند و با کمبود آب مواجه هستند، به حل این مشکلات کمک کند. یکی از اصلی‌ترین چالش‌های مربوط به آب، به کیفیت آن مربوط می‌شود که می‌توان به کمک هوش مصنوعی به آنالیز کیفیت آب و در نتیجه بررسی میزان آلاینده‌ها پرداخت. مدل‌های کیفیت آب با شبیه‌سازی ساده و دقیق می‌توانند به عنوان یک ابزار قدرتمند در فرایند تعیین کیفیت آب استفاده شوند [۸۸]. در سال‌های اخیر، یادگیری ماشین^۳ (ML) کارایی و عملکرد بالایی در مدیریت منابع آب نسبت به مدل‌های سنتی از خود نشان داده‌اند؛ زیرا این فناوری توانایی پردازش داده‌های مختلف را به‌طور همزمان دارد و به زمان و هزینه‌ی کمتر نیاز دارد. مدل‌های یادگیری ماشین در حوزه مدیریت منابع آب به‌منظور بهبود ارزیابی، پیش‌بینی و استفاده پایدار از منابع آب به‌کار گرفته می‌شود. این مدل‌ها با استفاده از داده‌های سری زمانی هیدرولوژیکی آموزش می‌بینند تا فرآیند پیش‌بینی انجام شود. در سال‌های اخیر، مدل‌های مبتنی بر هوش مصنوعی به مدل‌های فیزیکی یا مفهومی ترجیح داده می‌شوند؛ زیرا می‌توانند روابط غیرخطی بین ورودی و خروجی را مشخص کنند و پیش‌بینی‌های قابل اعتمادی ارائه دهند [۶۷، ۲۰]. در زمینه مدل‌سازی شاخص کیفیت آب تحقیقات زیادی در ایران و سایر نقاط جهان انجام شده است. در این میان، Islam و همکاران [۳۷] تغییرات مکانی در ویژگی‌های مختلف کیفیت آب شامل دما، شوری، قلیائیت، سختی و عوامل دیگر را بررسی کردند. این تحقیق شاخص کیفیت آب را بررسی کرده و خطرات اکولوژیکی بالقوه را ارزیابی کرده است. برای تعیین وضعیت کیفیت آب، از مدل WQI استفاده شده و تحلیل همبستگی پیرسون دوطرفه و تحلیل مؤلفه‌های اصلی چندمتغیره برای بررسی ارتباط میان تراکم پلانکتون (PD) و WQI به‌کار رفته است. تحلیل چندمتغیره نشان داد که بین BOD.PD و DO همبستگی قوی وجود دارد. Bouchared و همکاران [۸]

2- Horton

3- Machine Learning

1- Water Quality Index

روش تحقیق

در این تحقیق در محل ایستگاه‌های هیدرومتری نمونه برداری آب در یک دوره ۱۰ ساله (۱۳۹۳-۱۴۰۲) از جریان اصلی و در عمق حدود پنج سانتی متری از سطح به کف انجام شد. برخی از داده‌های استفاده شده برای مدل‌سازی در این تحقیق حاصل نمونه‌برداری میدانی و تعیین کیفیت آب منطقه (۱۳۹۳-۱۳۹۵) و باقیمانده داده‌ها از شرکت آب منطقه‌ای استان لرستان در مقیاس ماهانه تهیه شدند. بعد از نمونه‌برداری، خصوصیات کیفی آب در آزمایشگاه تعیین شد. برای این منظور، ظروف نمونه‌برداری از جنس پلاستیک به حجم یک لیتر تهیه شد که قبل از نمونه‌برداری بایستی با یک پاک‌کننده به‌خوبی شسته شوند. در ادامه نمونه‌های گرفته شده جهت بررسی به آزمایشگاه منتقل می‌شدند و خصوصیات شیمیایی TDS، EC، pH، CO₃، HCO₃، Cl، SO₄، Ca، Mg، Na و K تعیین شدند. لازم به ذکر است که در ابتدا داده‌ها جهت استفاده در فرآیند مدل‌سازی بر اساس رابطه ۱ نرمال‌سازی شدند [۵۲، ۵۳].

$$X_{new} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

که در آن: X_{new} مقدار داده نرمال شده در محدوده صفر تا یک، X مقدار داده مشاهده‌ای، X_{min} کم‌ترین مقدار داده مشاهده‌ای و X_{max} بیش‌ترین مقدار داده مشاهده‌ای است.

مجموعه داده‌های استفاده شده برای مدل‌سازی

ابتدا آزمون خود همبستگی (MCT^*) برای تعیین همبستگی درونی بین متغیرها از طریق دو فاکتور معیار تورم واریانس (VIF^t) و تلورانس (TOL^o) انجام شد.

داده‌های استفاده شده در این تحقیق برای مدل‌سازی کیفیت آب در مجموع شامل ۱۲۴ داده برای هر پارامتر بوده است که داده‌های ورودی مدل شامل TDS ، EC ، PH ، HCO_3^- ، CL^- ، SO_4^{2-} ، CA^{2+} ، Mg^{2+} ، Na^+ و K^+ و همچنین خروجی مدل شاخص کیفیت آب (WQI) بوده است. از کل داده‌های استفاده شده برای مدل‌سازی شاخص کیفیت آب، ۷۰ درصد برای مرحله آموزش (تعداد ۸۶ داده برای هر پارامتر) و ۳۰ درصد باقیمانده برای مرحله آزمایش مدل (تعداد ۳۸ داده برای هر پارامتر) استفاده شده است. برای مدل‌سازی و تخمین شاخص کیفیت آب از مدل‌های SVM، SVM-GWO و SVM-PSO در محیط پایتون استفاده شده است.

شاخص کیفیت آب (WQI)

شاخص کیفیت آب برای درجه‌بندی کیفی آب رودخانه به کار می‌رود، و می‌تواند برای مقایسه کیفیت منابع آبی در یک ناحیه یا در سراسر جهان مورد استفاده قرار گیرد. این شاخص از مقدار پارامترهای عمومی آب شامل اکسیژن محلول، سختی، اسیدیته،

پارامترهای کیفیت آب شامل SiO_4 ، DIN ، NO_3 ، NO_2 ، NH_4 ، PO_4 ، TDS ، Ec ، Na ، $NaCl$ ، CL ، SO_4 ایستگاه نمونه‌برداری، اندازه‌گیری کردند. نتایج نشان داد که اغلب ایستگاه‌ها در طبقه‌بندی WQI در سطح خوب قرار دارند به استثنای چند ایستگاه که در طبقه ضعیف و نامناسب قرار دارند. Gholizadeh و همکاران [۲۸] به ارزیابی کیفیت آب برپایه شاخص‌های کیفی آب‌های سطحی پرداختند. در این تحقیق پنج ایستگاه نمونه‌برداری براساس معیارهای استاندارد انتخاب شده است و ۱۲ پارامتر کیفی شامل اکسیژن محلول، درجه حرارت، فسفات آلی، نیترات و غیره به مدت یک‌سال با استفاده از روش استاندارد اندازه‌گیری شده است. نتایج شاخص‌های کیفیت آب بیانگر تأثیرات بسیار زیاد خروجی فاضلاب‌های شهری و زباله‌های انسانی در حریم رودخانه است. Effendi و همکاران [۱۹] به تعیین وضعیت کیفیت آب براساس شاخص‌های آلودگی و کیفیت آب پرداختند. در این تحقیق از شاخص آلودگی PI^۱ و شاخص کیفیت آب NSF-WQI^۲ استفاده شده است. نتایج شاخص آلودگی و شاخص کیفیت نشان‌دهنده کیفیت خوب در منطقه بوده است. Sepahvand و همکاران [۶۶] به بررسی شاخص کیفیت آب با استفاده از هوش مصنوعی پرداختند. در این تحقیق از مدل‌های RF، RepTree، M5P و Bagging استفاده شده است و نتایج با استفاده از برخی معیارهای ارزیابی بررسی شده است. نتایج تحقیق نشان داده است مدل BM5P نسبت به سایر مدل‌های به‌کار گرفته شده از عملکرد بالاتری برخوردار بوده است. لذا در این تحقیق به بررسی کیفیت آب سطحی و مدل‌سازی شاخص کیفیت آب با استفاده از SVR، SVR-GWO و SVR-PSO پرداخته شده است. از دلایل انتخاب این الگوریتم‌ها برای مدل‌سازی، اجرای سریع و همچنین عدم اجرا در گذشته در منطقه مورد مطالعه برای مدل‌سازی شاخص کیفیت آب بوده است.

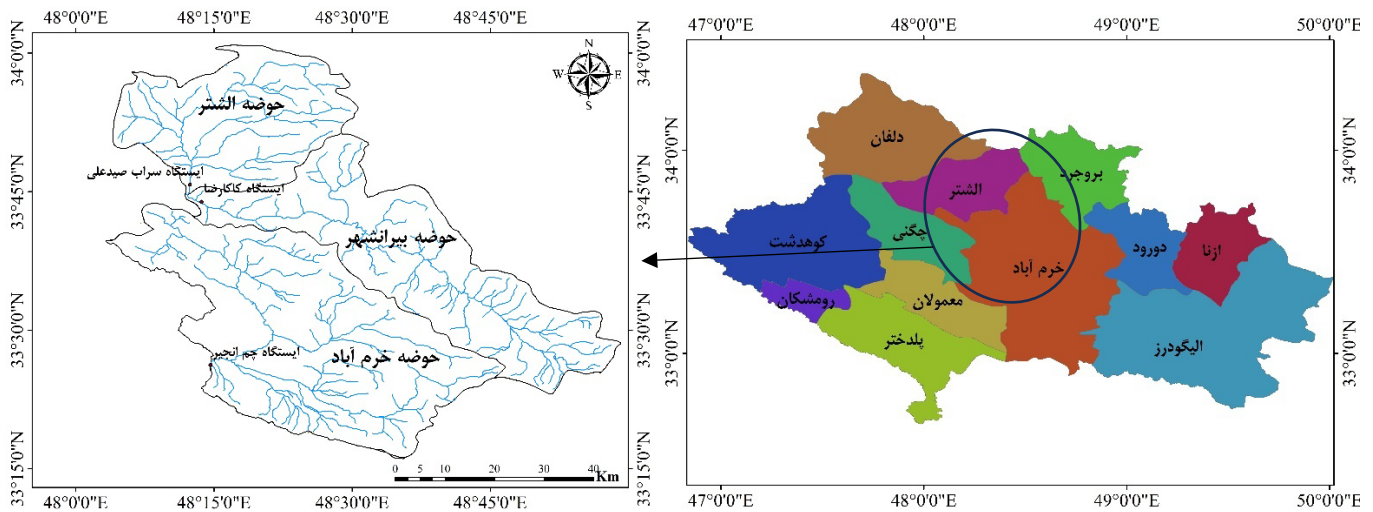
مواد و روش‌ها

منطقه مورد مطالعه

حوزه‌های آبخیز خرم‌آباد، الشتر و بیرانشهر از نظر ژئومورفولوژیکی در بخش مرکزی سلسله جبال زاگرس در استان لرستان قرار دارند که خود بخشی از حوزه آبخیز کشکان هستند. این حوضه‌ها در مجموع با مساحت ۳۵۷۶ کیلومتر مربع بین طول‌های جغرافیایی ۳۴°۰۱′۰۷″ تا ۳۳°۱۶′۰۵″ و عرض‌های ۴۸°۵۹′۰۷″ شرقی و ۴۸°۰۴′ شمالی قرار دارند (شکل ۱). بلندترین نقطه در بخش شمالی با ارتفاع ۳۵۷۸ متر و پست‌ترین نقطه در بخش غربی، یعنی خروجی حوزه آبخیز با ارتفاع ۱۱۵۸ متر از سطح دریا قرار دارد. میانگین بارندگی سالانه منطقه بین ۴۰۰ تا ۵۰۰ میلی‌متر بوده و دارای اقلیم نیمه‌خشک و سرد است [۶۶]. از نظر سنگ‌شناسی، منطقه مورد مطالعه عمدتاً توسط سازندهای کارستی پوشیده شده است.

- 1- Pollution Index
- 2- National Sanitation Foundation Water Quality Index

- 3- Multi-collinearity test
- 4- Variance Inflation Factor
- 5-TOLerance



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه بر روی نقشه استان لرستان
 Fig 1. Geographical location of the study area on the map of Lorestan Province

این پارامترها WQI به صورت زیر محاسبه می شود:

۱- ابتدا وزن (Z_i) هر پارامتر مشخص می شود.

۲- وزن نسبی پارامترها با استفاده از رابطه ۲ مشخص می شود:

$$Z_i = \frac{z_i}{\sum_{i=1}^n z_i} \quad (2)$$

که در آن Z_i وزن هر پارامتر، Z_i وزن نسبی و n تعداد پارامترها است [۷۳، ۸۳، ۸۴].

۳- مقیاس نرخ کیفیت آب برای هر پارامتر از طریق رابطه ۳ محاسبه می شود:

$$s_i = \left(\frac{con_i}{std_i} \right) * 100 \quad (3)$$

که در این رابطه s_i مقیاس نرخ کیفیت آب، con_i غلظت هر پارامتر در نمونه های آب برحسب میلی گرم در لیتر و std_i استاندارد هر پارامتر طبق WHO است [۷۳].

۴- محاسبه زیر شاخص کیفیت آب (SIL) برای هر پارامتر با استفاده از رابطه ۴:

$$SIL_i = Z_i \times s_i \quad (4)$$

۵- در نهایت محاسبه شاخص کیفیت آب با استفاده از رابطه ۵:

$$WQI = \sum SIL_i \quad (5)$$

مدل سازی شاخص کیفیت آب (WQI)

مدل های مبتنی بر یادگیری به لحاظ به کارگیری الگوریتم های تخمین و توزیع، طبیعت داده محور و تکرار بالای فرآیند مدل سازی، توانایی بالایی در شناسایی رفتار وقوع پدیده مورد نظر داشته و در پژوهش های علمی زیادی برتری خود را نسبت به دیگر مدل های آماری دو متغیره و چند متغیره اثبات نموده اند [۷۳].

دما، نیترات و برخی یون های اصلی بدست می آید [۴۹]. دسترسی به آب های سطحی و زیرزمینی و کیفیت آن با توجه به عواملی مانند: افزایش جمعیت، توسعه کشاورزی، صنعتی شدن و شهرنشینی در جهان رو به کاهش است [۸۰]. عوامل طبیعی مانند تبخیر، زمین شناسی منطقه و عوامل انسانی در کنترل ترکیبات شیمیایی، فیزیکی و بیولوژیکی آب های سطحی نقش دارند [۵۵]. بنابراین تعیین وضعیت کیفی منابع آب برای ایجاد راهکارهای مناسب به منظور جلوگیری از کاهش کیفیت و بهبود آن دارای اهمیت است. شاخص های کیفی، روش هایی اند که مقادیر ویژگی های کیفی آب را به یک عدد تبدیل می کنند تا برای مدیریت و تحلیل کیفیت آب و همچنین پیش تغییرات کیفی آب در طول زمان و مکان مورد استفاده قرار بگیرند [۴۴]. شاخص کیفیت آب در سال ۱۹۷۰ برای کنترل تغییرات کیفیت آب توسعه یافت، و می تواند سلامت منابع آبخیز را در نقاط مختلف نشان دهد. مقایسه کیفیت آب در بخش های مختلف یک کشور و ایجاد استانداردهای کیفی منابع آب از طریق محاسبه چند آزمایش بدست می آید که نشان دهنده سطح کیفیت منابع آب است. پارامترهای مورد نیاز برای تعیین شاخص کیفیت آب شامل: اکسیژن آب، نیترات، ph ، تغییرات دما، کدورت و WQI هستند. برای تعیین یک رده بندی در مقیاس اعداد کمتر از ۵۰ تا بیشتر از ۳۰۰ در نظر گرفته می شود که مقادیر بالا نشان دهنده کیفیت پایین تر و مقادیر کمتر نشان دهنده کیفیت بالاتر آب است [۹، ۵۰].

مراحل محاسبه شاخص کیفیت آب

سه نوع داده بیولوژیکی، فیزیکی و شیمیایی برای تجزیه و تحلیل کیفیت آب مورد استفاده قرار می گیرد که با استفاده از آن ها WQI محاسبه می شود [۱۷]. این پارامترها شامل TDS ، EC ، PH ، HCO_3^- ، Na^+ ، Mg^{2+} ، Ca^{2+} ، SO_4^{2-} ، Cl^- و K^+ هستند که با استفاده از

الگوریتم SVR به عنوان یک روش یادگیری نظارت شده معرفی شد [۸۱]. و از همان اصول SVM برای طبقه‌بندی استفاده می‌کند، با چند تفاوت جزئی [۸۲]. SVR می‌تواند برای حل مسائل خطی و غیرخطی زمانی که نقاط داده و ویژگی‌های آن‌ها محدود است استفاده شود. و بر اساس به حداقل رساندن ریسک ساختاری، مسائل غیرخطی را با ابعاد بالا و نمونه‌های کمی حل می‌کند، و در مقایسه با روش‌های دیگر، همگرایی سریع را نشان می‌دهد [۷۴]. این الگوریتم داده‌های آموزشی را از طریق تبدیل غیرخطی به فضای با ابعاد بالا به نام فضای ویژگی‌ها نگاشت می‌کند. تعیین دقیق تابع جریمه و خطای مجاز، نوع تابع هسته و مقدار بهینه برای پارامتر تابع هسته در الگوریتم SVR برای دستیابی به حداکثر دقت مدل ضروری است [۳۶].

الگوریتم GWO

گرگ‌های خاکستری ترجیح زیادی برای زندگی در دسته‌های پنج تا ۱۲ نفره دارند [۲۴]. هر گرگ دارای مسئولیت‌های خاصی است که توسط رهبر دسته مشخص شده است. بر این اساس، آن‌ها به چهار رتبه: α ، β ، δ و ω تقسیم می‌شوند. الگوریتم GWO بر اساس این ساختار سلسله مراتبی است [۵۴]. پس از ایجاد یک راه حل تصادفی (جمعیت)، مناسب‌ترین راه‌حل‌ها α ، β و δ تعیین می‌شوند [۵۸]. و راه‌حل‌های باقی مانده بر اساس معادلات ۶ تا ۸ تعیین می‌شوند [۵۴].

$$\vec{x}(t+1) = \frac{\vec{x}_1 + \vec{x}_2 + \vec{x}_3}{3} \quad (6)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \times (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \times (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \times (\vec{D}_\delta), \vec{A} = 2 \times \vec{\alpha} \times \vec{r}_1 - \vec{\alpha} \quad (7)$$

$$\vec{D}_\alpha = |\vec{C}_1 \times \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \times \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \times \vec{X}_\delta - \vec{X}|, \vec{C} = 2 \times \vec{r}_2 \quad (8)$$

جایی که X و T به ترتیب موقعیت گرگ و تعداد تکرارها را نشان می‌دهد. \vec{C} و \vec{A} بردارهای ضریب و اجزای $\vec{\alpha}$ هستند که به صورت خطی بین ۰ و دو در هر تکرار کاهش می‌یابد [۲۳، ۷۹]. \vec{r}_1 و \vec{r}_2 بردارهای تصادفی تولید شده برای محدوده (۰-۱) [۳۰]. فرآیند شکار زمانی تکمیل می‌شود که \vec{A} هنگامی که یک حمله رخ می‌دهد، مقادیر بین -۱ و ۱ را می‌گیرد [۲۱، ۲۷، ۳۸، ۴۸، ۵۴، ۶۱، ۸۵، ۸۶].

الگوریتم PSO

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) از رفتارهای اجتماعی حیوانات در جستجوی غذا الهام گرفته است [۴۳، ۷۱]. مانند پرندگان دسته جمعی و پرورش ماهی. PSO با جمعیتی از ذرات شروع می‌شود که هر کدام یک راه‌حل منتخب را نشان می‌دهد، که در منطقه جستجو با موقعیت‌ها و سرعت‌های تصادفی پراکنده می‌شوند. بهترین موقعیتی که هر ذره در فرآیند جستجو اشغال می‌کند $pbest$ نام دارد. و مکان آن در حافظه ذره ذخیره می‌شود. بهترین موقعیت (کمترین خطا) به دست آمده توسط همه ذرات حفظ شده و $Gbest$ تعیین می‌شود. همه ذرات با توجه به موقعیت میانگین وزنی موقعیت فردی و موقعیت بهینه تاریخی گروه به سمت بهترین موقعیت خود حرکت می‌کنند تا زمانی که در یک نقطه واحد همگرا شوند [۲۶، ۴۶]. در روش PSO با فضای جستجوی D بعدی، برای هر ذره دو بردار در نظر گرفته می‌شود که نشان‌دهنده i^{th} موقعیت ذرات و سرعت ذره است. $\vec{X}_i = \{X_{i1}, X_{i2}, X_{i3}, \dots, X_{iD}\}$

این دو بردار در هر تکرار با استفاده از رابطه‌های ۹ و ۱۰ محاسبه می‌شوند [۴۶، ۳۲].

$$\vec{V}_i(t+1) = W\vec{V}_i(t) + C_1r_1 \times (\vec{X}_{pbesti} - \vec{X}_i(t)) + C_2r_2 \times (\vec{X}_{Gbest} - \vec{X}_i(t)) \quad (9)$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (10)$$

جایی که $\vec{V}_i(t+1)$ و $\vec{X}_i(t+1)$ هستند سرعت ذره و موقعیت آن به ترتیب در تکرار $t+1$. وزن اینرسی را نشان می‌دهد و مقدار بهینه آن نشان‌دهنده تعادل بین اکتشاف جهانی و بهره‌برداری محلی است [۷۵]. اگر مقدار w به درستی انتخاب شده باشد، تعداد تکرارهای مورد نیاز برای یافتن راه‌حل بهینه کاهش می‌یابد. با این حال، در مورد $w > 1$ ، فضای جستجو گسترده‌تر می‌شود و الگوریتم به دلیل افزایش سرعت ذرات ناپایدار می‌شود. C_1 و C_2 ثابت‌های مثبتی هستند که معمولاً در محدوده [۲، ۲/۰۵] قرار دارند [۳]. ثابت C_1 و ضریب یادگیری C_2 را تعیین کرد. C_1 یک پارامتر شناختی مربوط به تجربیات یک ذره فردی است، در حالی که C_2 یک پارامتر اجتماعی است که تجربیات همه ذرات را منعکس می‌کند. انتخاب مقادیر مناسب برای این پارامترها همگرایی را تسهیل می‌کند و در عین حال از همگرایی اولیه در بهینه‌های محلی جلوگیری می‌کند و تأثیر قابل توجهی بر نحوه حرکت یک ذره در طول هر تکرار دارد [۷۰]. انتخاب یک مقدار بزرگتر برای پارامتر شناختی C_1 نسبت به پارامتر اجتماعی C_2 ممکن است بهینه باشد [۷]. علاوه بر این، شرط $C_1 + C_2 \geq 4$ باید رعایت شود [۶، ۱۲، ۴۷]. P_{besti} به بهترین مقامی که تا به حال رسیده است و G_{best} نشان‌دهنده مناسب‌ترین موقعیت

1- Support Vector Regression

2- GWO algorithm

3- Particle Swarm Optimization algorithm

کل ازدحام در t تکرار T_1 و T_2 بردارهای تصادفی بین ۰ و ۱ هستند که برای تنوع بخشیدن به جمعیت استفاده می‌شوند [۱۱، ۱۳، ۶۳]. طبق توضیحات ارائه شده سرعت ذرات متحرک در هر مرحله از سه قسمت تشکیل شده است. بخش اول سرعت جاری ذرات است. دوم مؤلفه شناختی است که نشان‌دهنده رفتار ذرات فردی است. بخش سوم همکاری بین ذرات (مؤلفه اجتماعی) را نشان می‌دهد [۱۸]. بدون بخش دوم و سوم، الگوریتم منجر به جستجوی جهانی کور خواهد شد. بدون بخش اول، الگوریتم فقط نزدیک بهترین ذره جستجو می‌کند و به بقیه فضای جستجو نمی‌رسد. برای دستیابی به تعادل بین جستجوی جهانی و محلی، هر سه بخش الگوریتم باید به‌کار گرفته شوند. این الگوریتم زمانی متوقف می‌شود که تعداد مشخصی از تکرارها سپری شود یا زمانی که هیچ بهبود قابل توجهی در تابع تناسب رخ ندهد. از آنجایی که رویکرد PSO شامل عملیات کمتری نسبت به سایر الگوریتم‌های فراابتکاری است، پیاده‌سازی آن در مقایسه با روش‌های دیگر مانند الگوریتم ژنتیک، ساده‌تر، با محاسبات کمتر و نرخ همگرایی بالاتر است [۴، ۱۸].

معیارهای سنجش خطای مدل‌سازی

برای بررسی دقت نتایج حاصل از مدل‌سازی پارامترها از معیارهای متفاوتی می‌توان استفاده کرد. در این تحقیق برای تعیین مدل بهینه از معیارهای سنجش خطای ریشه میانگین مربعات خطا ($RMSE^1$)، ناش-سایتکلیف، و ضریب همبستگی (CC^2) استفاده شد. براساس معیارهای استفاده شده مدلی که دارای ضریب همبستگی بالاتر و ریشه میانگین مربعات خطا و میانگین خطای مطلق کمتری باشد از دقت بالاتری برخوردار است. (رابطه‌های ۱۱ تا ۱۳).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (H - F)^2} \quad (11)$$

$$E_{NS} = 1 - \frac{\sum_{i=1}^n (Q_i^{sim} - Q_i^{obs})^2}{\sum_{i=1}^n (Q_i^{obs} - Q_i^{obsav})^2} \quad (12)$$

$$CC = \frac{n \sum HF - (\sum H)(\sum F)}{\sqrt{(n \sum H^2) - (\sum H)^2} \sqrt{(n \sum F^2) - (\sum F)^2}} \quad (13)$$

در روابط فوق، F مقدار برآورد شده، H مقدار مشاهده شده، \bar{H} میانگین مقادیر مشاهده شده و n تعداد داده‌ها هستند. علاوه بر معیارهای سنجش خطا، از نمودارهای تیلور و ویولین باکس برای مقایسه نتایج مدل‌ها استفاده شد که این نمودارها در نرم‌افزار Origin SR1 2024 استفاده شد.

نمودار تیلور

نمودار تیلور در سال ۲۰۰۱ توسط Taylor توسعه یافت که

1- Root Mean Squar Error

2- Correlation Coefficient

یکی از پرکاربردترین و مدرن‌ترین روش‌ها است [۷۷]. این نمودار مجموعه‌ای از الگوها را از نظر همبستگی، ریشه میانگین مربعات خطا و تغییرات استاندارد بررسی می‌کند. نمودارهای تیلور نمودارهای ریاضی هستند و به صورت گرافیکی نشان می‌دهند کدام یک از چندین مدل تقریبی یک سیستم پدیده واقعی‌تری است، همچنین ارزیابی مقایسه‌ای مدل‌های مختلف را بر اساس ضریب همبستگی پیرسون، خطای ریشه میانگین مربعات ($RMSE$) و انحراف معیار استاندارد تسهیل می‌نماید.

نمودار ویولن باکس^۳

نمودار ویولن باکس ترکیبی از نمودار ویولن و جعبه است، در واقع یک نمایش گرافیکی منحصر به فرد است که علاوه بر این که مزایای هر دو طرح را دارد، به طور یکپارچه طرح ویولن و جعبه را با هم ادغام می‌کند. نمودار جعبه مانند ویولن دارای چند لایه است و میانگین داده‌ها را به صورت عمودی روی نمودارهای ویولن و جعبه نشان می‌دهد [۳۱، ۷۳].

نتایج

جدول ۱ خصوصیات پارامترهای کیفیت آب ایستگاه‌های چمانجیر، کاکارضا و سراب صیدعلی را نشان می‌دهد که مطابق نتایج بیشترین و کمترین مقدار TDS در ایستگاه سراب صید علی به ترتیب با مقادیر ۱۹/۷۸ و ۴/۶۸ میلی‌گرم بر لیتر مشخص شد. بیشترین مقدار EC به ترتیب با میزان ۴/۰۷ و ۴/۰۵ میکروزیمنس بر سانتی‌متر در ایستگاه‌های چمانجیر و سراب صیدعلی و کمترین آن با میزان یک میکروزیمنس بر سانتی‌متر در ایستگاه چمانجیر مشاهده شد. همچنین بیشترین مقدار شاخص WQI در ایستگاه چمانجیر با ۲۴/۶۵ و کمترین آن در ایستگاه سراب صید علی با میزان ۲۳/۶۵ مشاهده شد.

نتایج آزمون خود همبستگی برای تعیین همبستگی درونی بین متغیرها نشان داد که مقدار TOL و VIF به ترتیب بین ۰/۰۵۴-۰/۰۲۱ و ۱/۱۳-۳/۱۶۷ متغیر بود. جدول ۲ خصوصیات آماری داده‌های ورودی و خروجی در بخش آموزش و آزمایش فرآیند مدل‌سازی را نشان می‌دهد. مطابق نتایج جدول ۲ مشخص شد که بیشترین میزان شاخص کیفیت آب در بخش آموزش و آزمایش به ترتیب برابر ۵۱/۱۵ و ۶۴/۲۴ برآورد شده و کمترین مقدار شاخص کیفیت آب به ترتیب برابر ۲۳/۶۵ و ۲۵/۲۲ بوده است. جدول ۳ میزان وزن و وزن نسبی پارامترهای ورودی و خروجی مدل و جدول ۴ بیان‌کننده اطلاعات کیفی شاخص کیفیت آب می‌دهد.

3- Violinbox diagram

جدول ۱- ویژگی‌های پارامترهای کیفیت آب ایستگاه‌های مورد مطالعه

Table 1. Characteristics of water quality parameters of the studied stations

سرآب صید علی SaraSeydAli		کاکارضا KakaReza			چم انجیر ChamAnjir			استاندارد Standard	پارامتر Parameter				
انحراف Sd معیار	میانگین Mean	کمترین Min	بیشترین Max	انحراف Sd معیار	میانگین Mean	کمترین Min	بیشترین Max	انحراف Sd معیار	میانگین Mean	کمترین Min	بیشترین Max		
2.41	9.38	4.68	19.78	1.33	8.58	5.31	15.12	2.38	3.50	7.71	18.06	500	TDS (mg/l)
0.50	1.95	1	4.05	0.27	1.78	1.14	3.10	0.49	2.82	1.60	4.070	500	EC (μS/cm)
0.61	11.34	9.51	12.29	0.48	1.54	10.14	12.33	0.73	11.13	9.58	12.54	6.5-8.5	PH
0.56	1.80	0.57	2.80	0.46	1.69	0.57	2.40	0.66	2.40	0.57	3.77	500	HCO3- (mg/l)
0.51	1.06	0.17	3.54	0.61	0.96	0.30	4.60	0.86	2.56	0.88	5.84	250	CL-(mg/l)
2.03	1.67	0.12	7.92	1.58	1.53	0.21	7.20	2.52	2.11	0	10.56	250	SO42-(mg/l)
0.45	1.62	0.75	2.81	0.34	1.59	0.81	2.37	0.58	2.01	0.62	3.44	75	Ca2+(mg/l)
2.57	5.67	1.13	15.19	1.98	4.90	0.75	9.49	3.19	8.30	3.41	21.65	50	Mg2+(mg/l)
0.24	0.26	0.02	1.58	0.17	0.20	0.02	1.43	0.42	0.70	0.10	2.01	200	Na+(mg/l)
0.05	0.03	0	0.36	0.02	0.01	0	0.12	0.09	0.07	0.008	0.46	10	K+(mg/l)
7.04	34.98	23.65	57.18	4.60	32.97	25.41	49.56	7.37	45.72	32.99	64.24	-	WQI

جدول ۲- خصوصیات آماری داده‌های آموزش و آزمایش ایستگاه‌های مورد مطالعه

Table 2. Statistical characteristics of the training and testing data of the studied stations

آزمایش		آموزش			پارامتر Parameter			
انحراف معیار Sd	میانگین Mean	بیشترین Max	کمترین Min	انحراف معیار Sd		میانگین Mean	بیشترین Max	کمترین Min
53.60	269.24	484	170	96.898	334.95	573	150	TDS (mg/l)
82.12	420.17	745	275	155.502	525.29	977	241	EC (μS/cm)
0.30	7.90	8.39	5.07	0.527	7.64	8.53	6.47	PH
12.28	100.68	128.14	73.22	29.397	121.32	201.37	56.44	HCO3- (mg/l)
15.03	17.38	92.17	7.80	21.361	31.04	116.99	3.55	CL-(mg/l)
11.80	19.01	55.71	7.20	18.150	18.88	83.57	0	SO42-(mg/l)
10.75	55.52	74.15	26.05	16.434	61.38	110.22	24.05	Ca2+(mg/l)
6.16	13.95	26.74	2.43	10.412	20.65	69.28	3.65	Mg2+(mg/l)
8.03	6.02	45.98	0.69	11.098	10.45	64.37	0.69	Na+(mg/l)
0.83	0.97	3.91	0	4.795	3.48	44.18	0	K+(mg/l)
10.99	38.07	64.24	25.22	6.658	35.56	51.15	23.65	WQI

جدول ۳- جزئیات وزن و وزن نسبی پارامترها

Table 3. Details of the weight and relative weight of the parameters

WHO Standard	وزن نسبی (Wi)	وزن (z _i)	پارامتر
WHO Standard	Relative Weight (Wi)	Weight (z _i)	Parameter
500	0.15	5	TDS
500	0.62	2	EC
6.5-8.5	0.12	4	PH
500	0.93	3	HCO ₃ ⁻
250	0.12	4	CL ⁻
250	12	4	SO ₄ ²⁻
75	0.93	3	Ca ²⁺
50	0.93	3	Mg ²⁺
200	0.62	2	Na ⁺
10	0.62	2	K ⁺
-	1	32	مجموع Total

جدول ۴- توصیف کیفی شاخص WQI

Table 4. Qualitative classification of the Water Quality

شاخص WQI Index (WQI)	کیفیت آب WaterQuality
50>	خیلی خوب Excellent
50-100>	خوب Good
100-200>	بد Poor
200-300>	خیلی بد Very Poor
300<	نامناسب Unsuitable for Use

نسبت به نتایج مدل‌های SVR، SVR_PSO عملکرد بهتری داشته است و به‌عنوان مدل برتر برای تخمین میزان شاخص کیفیت آب انتخاب شد. همچنین مدل SVR نسبت به سایر مدل‌ها عملکرد ضعیف‌تری داشته که نتایج این مدل در بخش آموزش با توجه به معیارهای ارزیابی کارایی به ترتیب برابر ۰/۹۱۵، ۰/۷۸۲ و ۲/۰۰۸ بوده و در مرحله آزمایش به همین ترتیب برابر ۰/۷۵۱، ۰/۵۶۹، ۶/۸۲۳ برآورد شده است.

شکل ۲ نمودار پراکنش داده‌های مشاهداتی و پیش‌بینی مدل‌های SVR، SVR_PSO و SVR_GWO در مرحله آموزش و آزمایش مدل‌سازی را نشان می‌دهد.

جدول ۵- عملکرد مدل‌های مورد استفاده

Table 5. Performance of the applied models

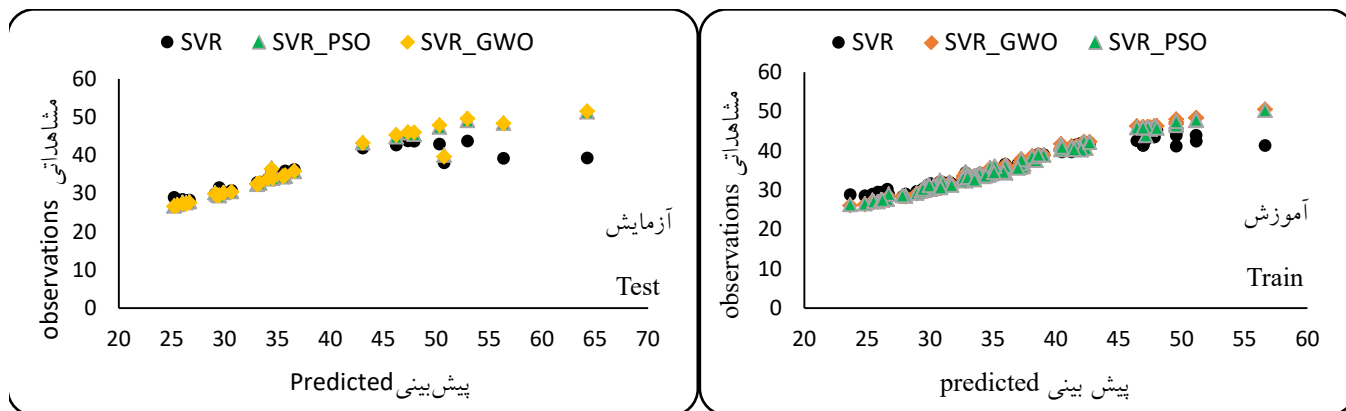
مدل‌ها Models	SVR	SVR_PSO	SVR_GWO
آموزش Train			
CC	0.915	0.983	0.986
NSE	0.782	0.956	0.966
RMSE	2.008	0.896	0.792
آزمایش Test			
CC	0.751	0.942	0.936
NSE	0.569	0.867	0.871
RMSE	6.823	3.780	3.727

شکل ۳ نمودار داده‌های مشاهداتی و داده‌های پیش‌بینی شده مدل در مرحله آموزش نشان می‌دهد که مطابق نتایج این نمودار تقریباً تطابق خوبی بین داده‌های مشاهداتی و داده‌های پیش‌بینی وجود دارد. همچنین شکل ۴ نمودار داده‌های مشاهداتی و تخمینی را در مرحله آزمایش نشان می‌دهد.

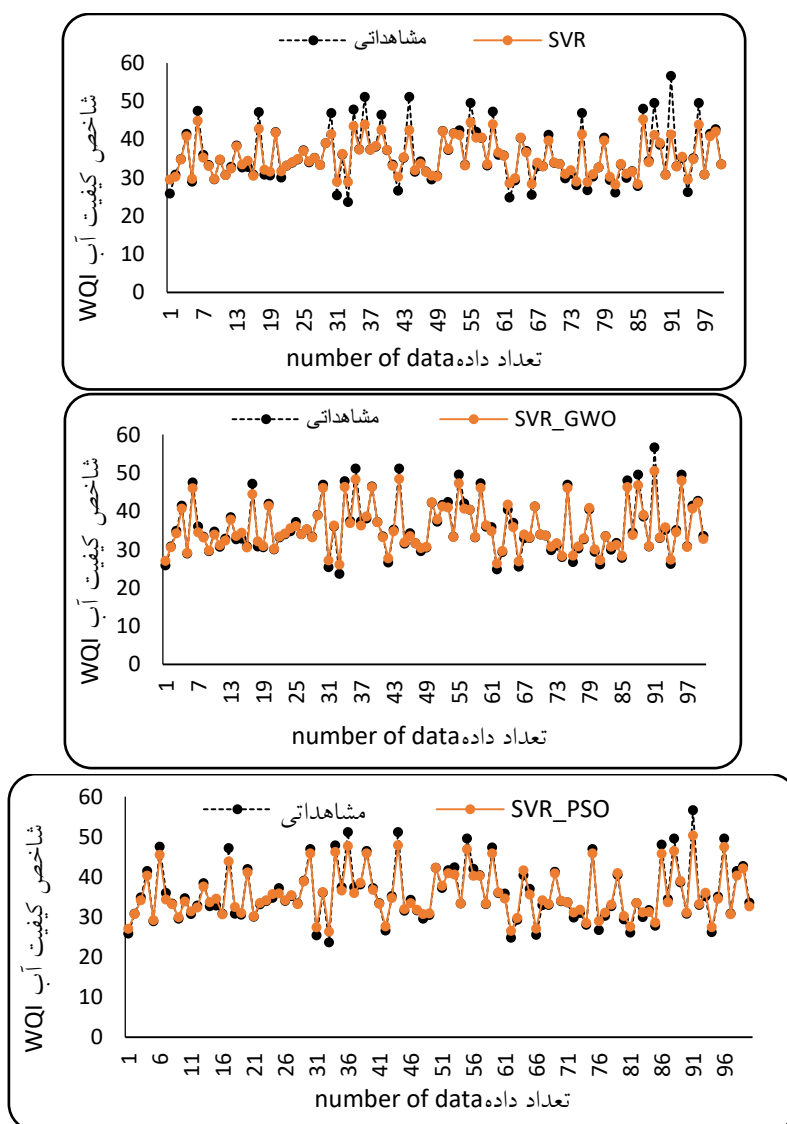
شکل‌های ۵ و ۶ نمودار تیلور را بر اساس نتایج داده‌های تخمینی مدل‌ها برای شاخص کیفیت آب (WQI) در مرحله آموزش (شکل ۵) و مرحله آزمایش (شکل ۶) نشان می‌دهد. مطابق نتایج شکل‌های ۵ و ۶ در بخش آموزش همه مدل‌ها در تخمین میزان WQI به خوبی عمل کرده‌اند، اما در بخش آزمایش مدل SVR-GWO در تخمین میزان WQI بر اساس داده‌های مشاهداتی دقیق‌تر از سایر مدل‌های به کار برده شده عمل کرده است. بنابراین طبق نتایج نمودار تیلور نیز می‌توان به این نتیجه رسید که SVR-GWO مدلی با دقت بیشتر برای تعیین میزان شاخص کیفیت آب (WQI) است.

شکل ۷ نمودار ویولن را برای ارزیابی مدل‌های استفاده شده در بررسی و پیش‌بینی شاخص کیفیت آب WQI در بخش آموزش و آزمایش داده‌ها نشان می‌دهد. مطابق نتایج شکل ۷ در بخش آموزش

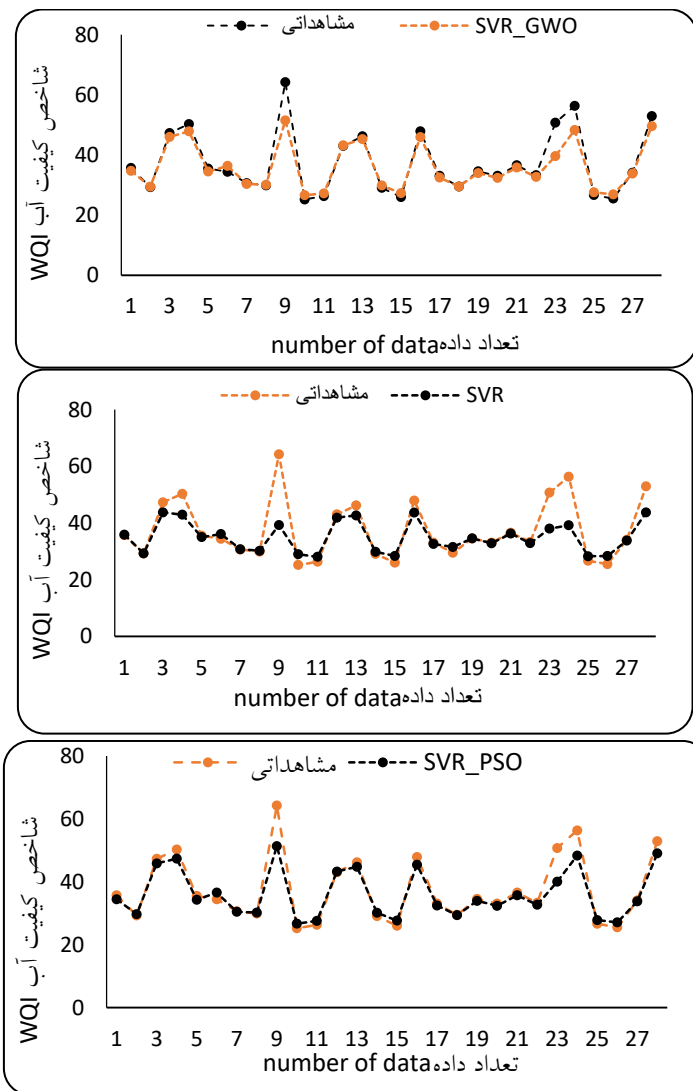
جدول ۵ نتایج حاصل از مدل‌سازی داده‌ها با استفاده از مدل‌های یادگیری ماشین SVR، SVR_PSO و SVR_GW استفاده شده در تحقیق را نشان می‌دهد. مطابق نتایج این جدول مشخص شد کدام یک از مدل‌های به کار گرفته شده در مقایسه با سایر مدل‌ها از عملکرد بهتری برخوردار بوده است. مطابق نتایج جدول ۵ مشخص شد که مدل SVR_GWO بر اساس میزان معیارهای ارزیابی خطای MAE، CC و RMSE در مرحله آموزش به ترتیب برابر ۰/۹۱۵، ۰/۷۸۲ و ۲/۰۰۸ و در مرحله آزمایش به ترتیب برابر ۰/۷۵۱، ۰/۵۶۹ و ۶/۸۲۳




شکل ۲- نمودار پراکنش داده‌های مشاهداتی و پیش‌بینی مدل‌ها در مرحله آموزش و آزمایش
 Fig 2. Scatter plot of observed data and model predictions during training and testing phases



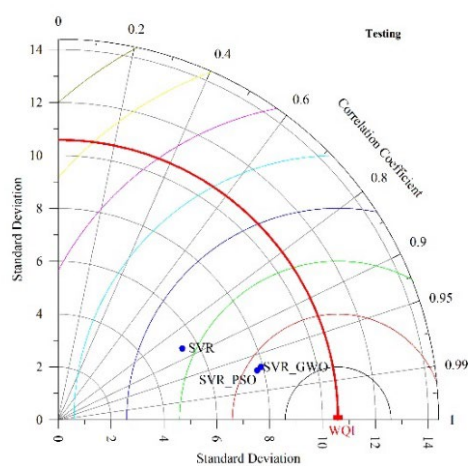
شکل ۳- نمودار داده‌های مشاهداتی و پیش‌بینی مدل‌های در مرحله آموزش
 Fig 3. Plot of observed data and model predictions during the training phase




شکل ۴- نمودار داده‌های مشاهداتی و پیش‌بینی مدل‌های در مرحله آزمایش
 Fig 4. Plot of observed data and model predictions during the testing phase



شکل ۶- نمودار تیلور در بخش آزمایش
 Fig 6. Taylor diagram for the testing



شکل ۵- نمودار تیلور در بخش آموزش
 Fig5. Taylor diagram for the training phase



شکل ۷- نمودار ویولین باکس نتایج مدل‌ها در بخش آموزش (الف) و بخش آزمایش (ب)
Fig 7. Violin-box plot of model results in the training phase (a) and testing phase (b)

صیدعلی به ترتیب برابر است با $۲/۸۲۰۰$ ، $۱/۷۸۶$ و $۱/۹۵۱$ PH. یک عامل بسیار مهم در تعیین خصوصیات فیزیکوشیمیایی آب است، دلیل این امر اثرگذاری بر شکل شیمیایی آلاینده‌ها، اثرات محیط زیستی، تبخیر و... است. بیشترین مقدار PH در ایستگاه چمنانجیر با $۱۲/۵۴۴$ و کمترین مقدار آن در ایستگاه سراب صید علی با $۹/۵۱۴$ مشخص شد که نشان‌دهنده شرایط بازی در هر دو ایستگاه است. کیفیت آب بسته به نوع و مقدار نمک‌های حل شده در آن، بسیار متغیر است. میزان TDS تا ۲۰۰۰ میلی‌گرم بر لیتر معمولاً به ماهیان آب شیرین و دیگر موجودات آبی آسیبی نمی‌زند. با توجه به تغییرات TDS بیش‌ترین و کم‌ترین مقدار TDS در ایستگاه سراب صیدعلی به ترتیب با $۱۹/۷۸۱$ و $۴/۶۷۷$ مشخص شد. کلری یکی از مهم‌ترین عناصر برای گندزدایی و تصفیه آب است که از رشد میکروب‌ها جلوگیری می‌کند. علی‌رغم مزایای متعدد، این عنصر خطرات زیادی برای بدن دارد. به همین دلیل بر اساس استاندارد ۱۰۵۳ سازمان استاندارد مقدار کلر آب باید بین ۲۰۰ میلی‌گرم بر لیتر باشد که با توجه به نتایج بدست آمده بیش‌ترین میزان کلر در ایستگاه چمنانجیر با $۵/۸۴۹$ و کم‌ترین میزان آن در ایستگاه سراب صیدعلی با $۰/۱۷۷$ مشخص شد. همچنین بیش‌ترین و کم‌ترین مقدار سایر پارامترها در سه ایستگاه مورد مطالعه از جمله (K^+ , Na^+ , Mg^{2+} , Ca^{2+} , SO_4^{2-} , HCO_3^-) نسبت به استاندارد WHO پرداخته شد. با توجه به نتایج بدست آمده مشخص شد که بیش‌ترین و کم‌ترین شاخص کیفیت آب (WQI) در ایستگاه‌های چمنانجیر و سراب صید علی بوده است. بر اساس این نتایج کیفیت آب ایستگاه‌های کاکارضا و سراب صیدعلی در محدوده خوب و قابل استفاده بوده اما کیفیت آب رودخانه خرم‌آباد در محدوده ایستگاه هیدرومتری چمنانجیر در محدوده خوب بوده است که دلیل کیفیت پایین‌تر رودخانه خرم‌آباد نسبت به رودخانه کاکارضا و سراب صیدعلی، ورود فاضلاب‌های شهری به این رودخانه هست. با اینکه آب این رودخانه برای مصارف کشاورزی استفاده می‌شود اما بهتر

این نمودار در مراحل آموزش و آزمایش مقادیر پیش‌بینی مدل-SVR با GWO با مقادیر واقعی همخوانی بیشتری دارد. بنابراین با توجه به نتایج این نمودار عملکرد خوب مدل SVR-GWO در تخمین WQI تأیید می‌شود.

بحث و نتیجه‌گیری

شناخت کیفیت آب سطحی عامل بسیار مهمی در تعیین مناسب بودن آن برای کاربردهای مختلف اعم از شهری، کشاورزی و صنعتی و... است. منابع مهم آب سطحی با توجه به رشد جمعیت، توسعه کاربری، صنعت و کشاورزی و تقاضا برای تأمین آب از نظر کمی و کیفی در معرض خطر هستند. بنابراین، توجه به تغییرپذیری مکان آلاینده‌های مختلف و طیف گسترده شاخص‌های مختلف از اهمیت بالایی برخوردار است. در این تحقیق به مدل‌سازی شاخص کیفیت آب حوضه کشکان با استفاده از مدل‌های SVR، SVR-GWO و SVR-PSO و همچنین مهم‌ترین پارامترهای فیزیکوشیمیایی آن اعم از: (TDS , EC , PH , HCO_3^- , CL^- , SO_4^{2-} , Ca^{2+} , Mg^{2+} , Na^+ , K^+) و WQI) پرداخته شده است. در بخش بررسی خصوصیات کیفی آب ایستگاه‌های چمنانجیر، کاکارضا و سراب صیدعلی مشخص شد که به‌ترتیب بیش‌ترین و کم‌ترین مقدار EC در ایستگاه‌های چمنانجیر و سراب صیدعلی است که دلیل بالا بودن EC در ایستگاه‌های چمنانجیر و سراب صیدعلی تغییرپذیری متغیر در اثر فرآیندهای مختلفی مانند فرآیندهای طبیعی و انسانی است که دلیل این امر بیشتر بودن جامدات محلول در آب است. علاوه بر این هرچه میزان نمک‌های محلول در آب بیشتر باشد میزان بیشتری EC وجود خواهد داشت. موثرترین راه برای تعیین کیفیت آب اندازه‌گیری EC است، با اندازه‌گیری این پارامتر می‌توان به مقدار تقریبی نمک‌های موجود در آب پی برد. پارامتر EC به میزان جامدات محلول در آب وابسته است. با توجه به نتایج بدست آمده، مقدار میانگین EC در ایستگاه‌های چمنانجیر، کاکارضا و سراب

است که فقط در مواقع ضروری از آن برای کشاورزی استفاده شود و منابع آبی دیگر برای مصارف کشاورزی جایگزین شود. استفاده از مدل‌های یادگیری در سال‌های اخیر برای تخمین پارامترهای کیفیت آب افزایش یافته است [۸۸]. در این تحقیق به تخمین شاخص کیفیت آب (WQI) با استفاده از مدل‌های SVR-GWO و SVR-PSO، MAE، CC و RMSE و همچنین نمودارهای تیلور و ویولین باکس استفاده شد. نتایج نشان داد که مدل SVR_GWO بر اساس معیارهای ارزیابی خطای MAE، CC و RMSE در مرحله آموزش به ترتیب برابر ۰/۹۸۶، ۰/۹۶۶ و ۰/۷۹۲ و در مرحله آزمایش به ترتیب برابر ۰/۹۳۶ و ۰/۸۷ و ۳/۷۳ نسبت به نتایج مدل‌های SVR_PSO، SVR عمکرد بهتری داشته است و به عنوان بهترین مدل برای تخمین میزان شاخص کیفیت آب (WQI) انتخاب شد. همچنین مدل SVR نسبت به سایر مدل‌ها عملکرد ضعیف‌تری داشته که نتایج این مدل در بخش آموزش با توجه به معیارهای ارزیابی به ترتیب برابر ۰/۹۱۵، ۰/۷۸ و ۲/۰۱ بوده و در مرحله آزمایش به همین ترتیب برابر ۰/۷۵، ۰/۵۷ و ۶/۸۲ برآورد شده است. همچنین براساس نتایج به دست آمده از نمودارهای تیلور و ویولن باکس، عملکرد مثبت مدل‌های SVR، SVR-PSO و SVR-GWO استفاده شده در تحقیق به منظور مدل‌سازی شاخص کیفیت آب (WQI) و همچنین برتری مدل SVR-GWO نسبت به سایر مدل‌ها تأیید شده است. نتایج تحقیق نشان‌دهنده دقت بالای الگوریتم‌های یادگیری در ارزیابی و پیش‌بینی شاخص کیفیت آب با استفاده از پارامترهای کیفی استفاده شده در منطقه مورد مطالعه است. مطابق نتایج تحقیق Musaab و همکاران [۵۷] در بررسی کیفیت آب زیرزمینی با استفاده از شبکه عصبی به این نتیجه رسیدند که استفاده از مدل، ابزار مناسبی برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی در حجم بالا بدون نیاز به اندازه‌گیری و کارهای آزمایشگاهی است. در تحقیق انجام شده نیز نتایج نشان‌دهنده کارایی بالای مدل‌ها در ارزیابی کیفیت آب بوده است. مطابق نتایج تحقیق Panahi و همکاران [۶۰] مدل SVR-GWO دارای بهترین عملکرد در پیش‌بینی وقوع زمین لغزش بود که با نتایج این تحقیق همخوانی دارد. همچنین در تحقیق دیگری که توسط Panahi و همکاران [۵۹] انجام گرفت، مشخص شد که مدل SVR-GOA بهترین عملکرد را داشته و به دنبال آن مدل‌های SVR-PSO و SVR به عنوان بهترین مدل‌های تخمین عوامل موثر حساسیت به سیل شناسایی شدند که با نتایج تحقیق حاضر همخوانی ندارد. Gupta و همکاران [۲۹] از الگوریتم‌های یادگیری ماشین برای ارزیابی WQI در هند استفاده کردند. نتایج نشان‌دهنده قدرت بالای این الگوریتم‌ها در ارزیابی کیفیت آب زیرزمینی بوده است. Singh و همکاران [۷۳] به بررسی کیفیت آب با استفاده از ترش‌های هوش مصنوعی پرداختند. کارایی مدل‌های استفاده شده با استفاده از معیارهای ارزیابی MAE، NSE، RMSE، MAPE و CC بررسی شد که نتایج نشان‌دهنده عملکرد خوب این الگوریتم‌ها در ارزیابی کیفیت آب بوده است. Mokhtar و همکاران [۵۶] از سه مدل

هوش مصنوعی و چهار مدل رگرسیون چندگانه برای پیش‌بینی شش معیار کیفیت آب آبیاری استفاده کردند. نتایج نشان داد این مدل‌ها توانایی تصمیم‌گیری سریع در مورد کیفیت آب آبیاری را دارا بودند. همچنین Masaab و همکاران [۵۷] به مدل‌سازی شاخص کیفیت آب با استفاده از مدل‌های هوش مصنوعی پرداختند. پارامترهای کیفی این تحقیق Na ، Mg^{2+} ، Ca^{2+} ، No_3 ، So_4^{2-} ، Cl ، TH ، TDS ، EC ، PH^+ و Nco_3 بوده است. نتایج عملکرد بالای مدل‌های هوش مصنوعی را در مدل‌سازی GWQI نشان داد که این نتایج با نتایج تحقیق انجام شده همخوانی دارند. نتایج مشابه را می‌توان در مطالعات Saleem و همکاران [۶۴]، Kawo و همکاران [۴۲] و Jalili و همکاران [۴۰] مشاهده کرد که با نتایج این تحقیق همخوانی دارد.

Shams و همکاران [۶۹] به پیش‌بینی شاخص کیفیت آب با استفاده از مدل‌های یادگیری ماشین پرداختند. آن‌ها در این تحقیق از مدل‌های 'KNN'، 'DT'، 'SVR' و 'MLP' برای تخمین شاخص کیفیت آب استفاده کردند. نتایج تحقیق آن‌ها نشان داد که مدل MLP دارای توانایی بالایی برای تخمین WQI بود که با نتایج این تحقیق همخوانی نداشت اما نتایج تحقیق آن‌ها، در اینکه مدل‌های هوش مصنوعی و الگوریتم‌های یادگیری قدرت بالایی در تخمین و پیش‌بینی شاخص کیفیت آب (WQI) دارند با نتایج این تحقیق همخوانی داشت. Ehteram و همکاران [۲۰] به پیش‌بینی شاخص کیفیت آب (WQI) با استفاده از مدل‌های یادگیری عمیق پرداختند. آن‌ها در این تحقیق از مدل‌های CNN، Clockwork RNN و M5 Tree برای پیش‌بینی WQI استفاده کردند. نتایج این تحقیق نشان داد که مدل‌های هوش مصنوعی توانایی بالایی در تخمین و پیش‌بینی شاخص کیفیت آب دارند که با نتایج تحقیق حاضر همخوانی دارد. Singh و همکاران [۷۲] به پیش‌بینی شاخص کیفیت آب (WQI) با استفاده از الگوریتم‌های یادگیری پرداختند. آن‌ها در تحقیق خود بیان داشتند که مدل‌های هوش مصنوعی دارای توانایی بالای برای تخمین WQI برای مدیریت بهتر کیفیت آب هستند که با نتایج این تحقیق همخوانی دارد. به طور کلی با توجه به نتایج این تحقیق و همچنین تحقیقات گذشته، می‌توان بیان نمود که روش‌های هوش مصنوعی با توجه به میزان هزینه و زمان کم، در ارزیابی و پیش‌بینی کیفیت آب سطحی از قدرت بالا و عملکرد خوبی برخوردارند. بنابراین می‌توان این مدل‌ها را برای تخمین میزان شاخص کیفیت آب (WQI) در پارامترهای کیفی متفاوت و در بازه‌های زمانی مختلفی برای مدیریت بهینه کیفیت آب‌های سطحی و زیرزمینی در حوزه‌های آبخیز به کار برد. در مجموع با توجه به نتایج بدست آمده از این تحقیق می‌توان بیان نمود که شاخص کیفیت آب (WQI) مانند سایر شاخص‌ها در بررسی کیفیت آب دارای عملکرد خوبی هستند.

- 1- K-Nearest Neighbor
- 2- Decision Tree
- 3- Multi-Layer Perceptron

نویسندگان بر خود لازم می‌دانند از مشاوره‌های جناب آقای دکتر مهدی پناهی در بحث مدل‌سازی کمال تشکر و قدردانی را دارند.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش وجود ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

علیرضا سپه‌وند: راهنمایی، مفهوم‌سازی، روش کار، ویرایش و بازبینی مقاله، کنترل نتایج؛ نگار ارجمند: انجام تحلیل‌های نرم‌افزاری و مدل‌سازی، نگارش مقاله، نسرین بیرانوند: مرتب کردن داده‌ها، مدل‌سازی، ویرایش مقاله.

منابع مورد استفاده

1. Abbasnia, A. Yousefi, N. Mahvi, A.H. Nabizadeh, R. Radfard, M. Yousefi, M. and Alimohammadi, M. 2019. Evaluation of groundwater quality using water quality index and its suitability for assessing water for drinking and irrigation purposes: Case study of Sistan and Baluchistan province (Iran). *Human and Ecological Risk Assessment: An International Journal*. 25(4): 988-1005. doi: 10.1080/10807039.2018.1458596.
2. Aljanabi, Z.Z. Jawad, A.I. Obaidy, A.H.M. and Hassan, F.M. 2021. A brief review of water quality indices and their applications. *IOP Conference Series Earth Environmental Science*. 779(1): 012088. https://doi.org/10.1088/1755-1315/779/1/012088.
3. Al-Musaylh, M.S. Deo, R.C. Li, Y. and Adamowski, J.F. 2018. Two-phase particle swarm optimized-support vector regression hybrid model integrated with improved empirical mode decomposition with adaptive noise for multiple-horizon electricity demand forecasting. *Applied Energy* 217, 422–439. https://doi.org/10.1016/j.apenergy.2018.02.140.
4. Angeline, P.J. 1998. Evolutionary optimization versus particle swarm optimization: Philosophy and performance differences. *International Conference on Evolutionary Programming*, 601–610. https://doi.org/10.1007/BFb0040811.
5. AslHashemi, A. and Taghipour, H. 2010. Water Quality Index. *Journal of Environmental Chemistry Applications*. 1(4): 1–7. (in Persian). https://sid.ir/paper/236291/fa.

6. Barrera, J. Alvarez-Bajo, O. Flores, J.J. and Coello Coello, C.A. 2016. Limiting the velocity in the particle swarm optimization algorithm. *Computacion Sistemas*. 20(4): 635–645. Doi: 10.13053/CyS-20-4-2505

7. Beielstein, T. Parsopoulos, K.E. and Vrahatis, M.N. 2002. Tuning PSO parameters through sensitivity analysis. *Universitätsbibliothek, Dortmund*. Doi: :10.13140/2.1.1466.2080

8. Bouchareb, N. Chouaib, R.A. Meriem, L. Abdelaziz, B. Salah, K. Sara, B. and Mohamed, C. 2025. Monitoring water quality in Beni Haroun Dam Northeastern Algeria: Application of Water Quality Index (WQI), Pollution Index (PI), and statistical analyses. *Desalination and Water Treatment*. 323-101267. https://doi.org/10.1016/j.dwt.2025.101267.

9. Brown, M. McClelland, N.I. Deininger, R.A. and O'Connor, M.F. 1972. A water quality index crashing the psychological barrier, *Indicators of Environmental Quality*. 173-182. https://doi.org/10.22098/mmws.2022.11069.1097.

10. Cabello, V. Willaarts, B. Aguilar, M. and Del Moral, L. 2015. River basins as socioecological systems: linking levels of societal and ecosystem water metabolism in a semiarid watershed. *Ecology and Society*. 20(3): 1-20. https://doi.org/10.5751/ES-07778-200320.

11. Campana, E.F. Diez, M. Fasano, G. and Peri, D. 2013. Initial particles position for PSO, in bound constrained optimization. *Lecture Notes in Computer Science*. 112–119. https://doi.org/10.2139/SSRN.2324450.

12. Carlisle, A. and Dozier, G. 2001. An off-the-shelf PSO, *Conference: Proceedings of the Workshop on Particle Swarm Optimization*, Indianapolis.

13. Cura, T. 2009. Particle swarm optimization approach to portfolio optimization. *Nonlinear Analysis: Real World Applications*. 10(4): 2396–2406. https://doi.org/10.1016/j.nonrwa.2008.04.023.

14. De La Mora-Orozco, C. Flores-Lopez, H. RubioArias, H. Chavez-Duran, A. and Ochoa-Rivero, J. 2017. Developing a water quality index (WQI) for an irrigation dam. *International journal of environmental research and public health*. 14(5): 439. https://doi.org/10.3390/ijerph14050439.

15. Dippong, T. Hoaghia, M.A. and Senila, M. 2022. Appraisal of heavy metal pollution in alluvial aquifers: study case on the protected area of roni?oara forest, Romania (Article) *Ecol Indic*. 143: 109347. https://doi.org/10.1016/j.ecolind.2022.109347.

16. Dippong, T. Mihali, C. Marian, M. Roca, O.M., and Resz, M.A. 2024. Heavy metal contamination assessment and potential

org/10.1007/978-3-642-38703-6_9.

27. Gao, Z.M. and Zhao, J. 2019. An improved grey wolf optimization algorithm with variable weights. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2019/2981282>.

28. Gholizadeh, M. and Heydari, O. 2020. Evaluation of Gorganrood River water quality based on surface water quality indices in Gonbad Kavous urban area. *Journal of Health and Environment*. 13(1): 4–33. (in Persian). <http://ijhe.tums.ac.ir/article-1-6340-fa.html>.

29. Gupta, A.N. Kumar, D. and Singh, A. 2021. Evaluation of Water Quality Based on a Machine Learning Algorithm and Water Quality Index for Mid Gangetic Region (South Bihar plain), India. *J. Geol. Soc.* 97(9): 1063–1072. <https://doi.org/10.1007/s12594-021-1821-0>.

30. Gupta, S. and Deep, K. 2019. A novel random walk grey wolf optimizer. *Swarm Evol. Comput.* 44, 101–112. <https://doi.org/10.1016/j.swevo.2018.01.001>.

31. Hameed, M.M. Masood, A. Srivastava, A. Rahman, N.A. Razali, S.F.M. and Elbeltagi, A. 2024. Investigating a hybrid extreme learning machine coupled with Dingo Optimization Algorithm for modeling liquefaction triggering in sand-silt mixtures. *Scientific Reports* 14. 10799. <https://doi.org/10.1038/s41598-024-61059-6>.

32. Hasanipناه, M. Shahnazar, A. Amnieh, H.B. and Armaghani, D.J. 2017. Prediction of air overpressure caused by mine blasting using a new hybrid PSO–SVR model. *Eng. Comput.* 33(1): 23–31. <https://doi.org/10.1007/s00366-016-0453-2>.

33. Hazbavi, Z. Parchami, N. Alaei, N. and Babaei, L. 2020. Assessment and Analysis of the KoozehTopraghi Watershed Health Status, Ardabil Province, Iran. *Water and Soil Resources Conservation*. 9(3): 121-143. <https://sid.ir/paper/412661/en>.

34. He, W. and Guan, M. 2023. RETRACTED ARTICLE: Parameter estimation method of option pricing model based on convolutional neural network in high frequency financial trading. *Annals of Operations Research*. 326(11): 151–151. <https://doi.org/10.1007/s10479-022-04582-x>.

35. Hemond, H. and Fechner, E. 2014. *Chemical fate and transport in the environment*. Elsevier, Academic Press, 338P.

36. Hong, W.C. Dong, Y. Zhang, W.Y. Chen, L.Y. and Panigrahi, B. 2013. Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm. *Int. J. Electr. Power Energy Syst.* 44, 604–614. <https://doi.org/10.1016/j.ijepes.2012.08.010>.

37. Islam, S.K.S. Dhara, S.N. and Midya, S. 2025. Water quality assessment using WQI and zooplankton indicators in aquatic

human health risk of water quality of lakes situated in the protected area of tisa, Romania. *Heliyon*. 10(7): e28860. <https://doi.org/10.1016/j.heliyon.2024.e28860>.

17. Dogan, E. Sengorur, B. and Koklu, R. 2009. Modeling biological oxygen demand of the Melen River in Turkey using an artificial neural network technique. *Journal of Environmental Management*. 90 (2): 1229-1235. <https://doi.org/10.1016/j.jenvman.2008.06.004>.

18. Eberhart, R. and Kennedy, J. 1995. A new optimizer using particle swarm theory, MHS'95. In: *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. Ieee, pp. 39–43. doi: 10.1109/MHS.1995.494215.

19. Effendi, H. and Wardiatno, Y. 2015. Water quality status of Ciambulawung River, Banten Province, based on pollution index and NSF-WQI. *Procedia Environmental Sciences* 24, 228- 37. doi: <https://doi.org/10.1016/j.proenv.2015.03.030>.

20. Ehteram, M. Ahmed, A.N. Sherif. M. and El-Shafie, A. 2024. An advanced deep learning model for predicting water quality index, *Ecological Indicators*. 160: 111806. doi: 10.1016/j.ecolind.2024.111806

21. El-Fergany, A.A. and Hasanien, H.M. 2015. Single and multi-objective optimal power flow using grey wolf optimizer and differential evolution algorithms. *Electr. Power Compon. Syst.* 43 (13): 1548–1559. <https://doi.org/10.1080/15325008.2015.1041625>.

22. Elsayed, S. Ibrahim, H. Hussein, H. Elsherbiny, O. Elmetwalli, A.H. Moghanm, F.S. Ghoneim, A.M. Danish, S. Datta, R. and Gad, M. 2021. Assessment of water quality in lake qaroun using ground-based remote sensing data and artificial neural networks. *Water*. 13(21): 3094. <https://doi.org/10.3390/w13213094>.

23. Emary, E. Zawbaa, H.M. and Grosan, C. 2018. Experienced gray wolf optimization through reinforcement learning and neural networks. *IEEE Trans. Neural Netw. Learn. Syst.* 29 (3): 681–694. Doi: 10.1109/TNNLS.2016.2634548

24. Emary, E. Zawbaa, H.M. and Hassanien, A.E. 2016. Binary grey wolf optimization approaches for feature selection. *Neurocomputing* 172, 371–381. Doi: <https://doi.org/10.1016/j.neucom.2015.06.083>

25. Gad, M. Saleh, A.H. Hussein, H. Farouk, M. and Elsayed, S. 2022. Appraisal of surface water quality of Nile river using water quality indices, spectral signature and multivariate modeling. *Water*. 14(7): 1131. <https://doi.org/10.3390/w14071131>.

26. Gao, Y. Peng, L. Li, F. Liu, M. and Liu, W. 2013. Opposition-Based Learning Fully Informed Particle Swarm Optimizer without Velocity. *Int. Conf. Swarm Intell.* Springer. 79–86. https://doi.org/10.1007/978-3-642-38703-6_9.

org/10.1155/2016/8301962.

47. Lim, S.Y. Montakhab, M. and Nouri, H. 2009. A constriction factor-based particle swarm optimization for economic dispatch.

48. Liu, G. Chen, W. Chen, H. and Xie, J. 2019. A Quantum Particle Swarm Optimization Algorithm with Teamwork Evolutionary Strategy. *Mathematical Problems in Engineering*, 2019. 1-12. <https://doi.org/10.1155/2019/1805198>.

49. Lobato, T. Hauser-Davis, R. Oliveira, T. Silveira, A. Silva, H. and Tavares, M. 2015. Construction of a novel water quality index and quality indicator for reservoir water quality evaluation: A case study in the Amazon region. *Journal of Hydrology*. 522: 674-83. <https://doi.org/10.1016/j.jhydrol.2015.01.021>.

50. Lohani, B.N. and Todino, G. 1984. Water quality index for Chao Phraya river. *Journal of Environmental Engineering*. 110 (6): 1163-1176. Doi: 10.1061/(ASCE)0733-9372(1984)110:6(1163).

51. Marselina, M. Rahmi, N.A. and Nurhayati, S.A. 2025. The water quality of the Upper Citarum: Applying the overall index of pollution, Said-WQI, and pollution index methods. *Heliyon*. 11(2): e41690. <https://doi.org/10.1016/j.heliyon.2025.e41690>.

52. Melesse, A.M. Khosravi, K. Tiefenbacher, J.P. Heddum, S. Kim, S. Mosavi, A. and Pham, B.T. 2020. River Water Salinity Prediction Using Hybrid Machine Learning Models. *Water*, 12(10), 2951. <https://doi.org/10.3390/w12102951>.

53. Mirhashemi, SH. Panahi, M. and Zareei, L. 2020. Evaluation of M5P Algorithm for Estimation of Potential Evapotranspiration, Minimum and Maximum Temperature. *Journal of Meteorology and Atmospheric Sciences*. 2(4): 287-295.

54. Mirjalili, S. Mirjalili, S.M. and Lewis, A. 2014. Grey wolf optimizer. *Adv. Eng. Softw.* 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>.

55. Mishra, B.K. Regmi, R.K. Masago, Y. Fukushi, K. Kumar, P. and Saraswat, C. 2017. Assessment of Bagmati River pollution in Kathmandu Valley: scenario-based modeling and analysis for sustainable urban development. *Sustainability of Water Quality and Ecology*. 9: 67-77. <https://doi.org/10.1016/j.swaqe.2017.06.001>.

56. Mokhtar, A. Elbeltagi, A. Gyasi-Agyei, Y. Al-Ansari, N. and Abdel-Fattah, M.K. 2022. Prediction of irrigation water quality indices based on machine learning and regression models. *Apply Water Science*. 12(4): 1-11. <https://doi.org/10.1007/s13201-022-01590-x>.

57. Musaab, A.A.M. Nasraldeen, A.A.K. Norbert, P.S. and Peter, S. 2023. Modeling of groundwater quality index by using artificial intelligence algorithms in northern Khartoum State, Sudan. *Modeling Earth Systems and Environment*. 9: 2501–2516.

ecosystems: Insights from a correlation-based study. *Cleaner Water*. 4: 1-9. <https://doi.org/10.1016/j.clwat.2025.100103>.

38. Jaafari, A. Panahi, M. Pham, B.T. Shahabi, H. Bui, D.T. Rezaei, F. and Lee, S. 2019. Meta optimization of an adaptive neuro-fuzzy inference system with grey wolf optimizer and biogeography-based optimization algorithms for spatial prediction of landslide susceptibility. *Catena* 175, 430–44. <https://doi.org/10.1016/j.catena.2018.12.033>.

39. Jahandari, J. Hejazi, R. Jozi, S.A. and Moradi, A. 2022. Impacts of urban expansion on spatio temporal patterns of carbon storage ecosystem services in Bandar Abbas Watershed using InVEST software. *Water and Soil Management and Modeling*. 2(4): 91-106. <https://doi.org/10.22098/mmws.2022.11069.1097>.

40. Jalili, M. Hosseini, M.S. Ehrampoush, M.H. Sarlak, M. Abbasi, F. and Fallahzadeh, R.A. 2019. Use of water quality index and spatial analysis to assess groundwater quality for drinking purpose in Ardakan, Iran. *Journal of Environmental Health and Sustainable Development*. 4(3): 834-842. <https://dor.isc.ac/dor/20.1001.1.24766267.2019.4.3.6.8>.

41. Kanga, I.S. Seydou, N.A. Mustapha, N. Chikhaoui, M. Keith, S. Stephanie, L.T. and Nizar, S.N. 2019. A systematic review and Meta-Analysis of water quality indices. *J Agric Sci Technol B*. 9: 1-14. <https://doi.org/10.17265/2161-6264/2019.01.001>.

42. Kawo, N.S. and Karuppannan, S. 2018. Groundwater quality assessment using water quality index and GIS technique in Modjo River Basin, central Ethiopia. *Journal of African Earth Sciences*. 147(November 2018): 300-311. <https://doi.org/10.1016/j.jafrearsci.2018.06.034>.

43. Kennedy, J. and Eberhart, R. 1995. Particle swarm optimization. In: *Proceedings of ICNN'95-International Conference on Neural Networks*. IEEE, pp. 1942-1948. Doi: 10.1109/ICNN.1995.488968

44. krbajal-Hernández, J.J. Sánchez-Fernández, L.P. VillaVargas, L.A. Carrasco-Ochoa, J.A. and Martínez Trinidad, J.F. 2013. Water quality assessment in shrimp culture using an analytical hierarchical process. *Ecological indicators*. 29:148-58. <https://doi.org/10.1016/j.ecolind.2012.12.017>.

45. Kükrcer, S. and Mutlu, E. 2019. Assessment of surface water quality using water quality index and multivariate statistical analyses in Saraydüzü Dam Lake, Turkey. *Environ Monit Assess*. 15;191(2):71. <https://doi.org/10.1007/s10661-019-7197-6>.

46. Li, X. and Li, C. 2016. Improved CEEMDAN and PSO-SVR modeling for near-infrared noninvasive glucose detection. *Computational and mathematical methods in medicine*. <https://doi.org/10.1155/2016/8301962>.

Techniques (AIT) (Case study: Kashkan watershed, Lorestan province). *Journal of Range and Watershed Management*, 78(2), 207-223. (in Persian). 10.22059/jrwm.2025.385428.1789.

67. Shahra, E.Q. Wu, W. and Romano, M. 2019. Considerations on the deployment of heterogeneous IoT devices for smart water networks. In: 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing. Internet of People and Smart City Innovation, Leicester, UK, pp. 791-796. <https://doi.org/10.1109/SmartWorld-UIC-ATC-SCALCOM-IOP-SCI.2019.00167>.

68. Shakhari, S. and Banerjee, I. 2019. A multi-class classification system for continuous water quality monitoring. *Heliyon*. 2019 May 30;5(5):e01822. <https://doi.org/10.1016/j.heliyon.2019.e01822>.

69. Shams, M.Y. Elshewey, A.M. El-kenawy, S.M. Ibrahim, A.M. Talaat, F.M. and Tarek, Z. 2024. Water quality prediction using machine learning models based on grid search method. *Multimedia Tools and Applications*. 83(12): 35307-35334. <https://doi.org/10.1007/s11042-023-16737-4>.

70. Sheng, X. Xi, M. Sun, J. and Xu, W. 2015. Quantum-behaved particle swarm optimization with novel adaptive strategies. *J. Algorithms Comput. Technol.* 9(2): 143-161. Doi: <https://doi.org/10.1260/1748-3018.9.2.143>

71. Shi, Y. and Eberhart, R. 1998. A modified particle swarm optimizer. In: 1998 IEEE international conference on evolutionary computation proceedings. IEEE world congress on computational intelligence (Cat. No. 98TH8360). IEEE, pp. 69-73. Doi: 10.1109/ICEC.1998.699146

72. Singh, B. Sepahvand, A. Sihag, P. Singh, K. Prabha, Ch. Nag, A. Hassan, M. Vimal, S. and Kang, D. 2024. Development of soft computing-based models for forecasting water quality index of Lorestan Province, Iran, *Scientific Reports*, 14, Article number: 25980. <https://doi.org/10.1038/s41598-024-76894-w>

73. Singh, B. Sihag, P. Singh, V.P. Sepahvand, A. and Singh, K. 2021. Soft computing technique-based prediction of water quality index. *Water Supply*. 21(8): 4015-4029. <https://doi.org/10.2166/ws.2021.157>.

74. Su, H. Li, X. Yang, B. and Wen, Z. 2018. Wavelet support vector machine-based prediction model of dam deformation. *Mech. Syst. Signal Pr.* 110: 412-427. <https://doi.org/10.1016/j.ymsp.2018.03.022>.

75. Talbi, E.G. 2009. *Metaheuristics: from design to implementation*. John Wiley & Sons. 74. <https://doi.org/10.1007/s40808-022-01638-6>.

Doi:<https://doi.org/10.1007/s40808-022-01638-6>.

58. Niu, M. Wang, Y. Sun, S. and Li, Y. 2016. A novel hybrid decomposition-and-ensemble model based on CEEMD and GWO for short-term PM_{2.5} concentration forecasting. *Atmos. Environ.* 134: 168-180. <https://doi.org/10.1016/j.atmosenv.2016.03.056>.

59. Panahi, M. Dodangeh, E. Rezaie, F. Khosravi, K. Van Le, H. Lee, M. Lee, S. and Pham, B. 2021. Flood spatial prediction modeling using a hybrid of meta-optimization and support vector regression modeling. *CATENA*. 199: 105-114. <https://doi.org/10.1016/j.catena.2020.105114>.

60. Panahi, M. Gayen, A. Pourghasemi, H.R. Rezaie, F. and Lee, S. 2020. Spatial prediction of landslide susceptibility using hybrid support vector regression (SVR) and the adaptive neuro-fuzzy inference system (ANFIS) with various metaheuristic algorithms. *Science of the Total Environment*. 1(741): 139937. <https://doi.org/10.1016/j.scitotenv.2020.139937>.

61. Panahi, M. Sadhasivam, N. Pourghasemi, H.R. Rezaie, F. and Lee, S. 2020. Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). *J. Hydrol.* 588, 125033. <https://doi.org/10.1016/j.jhydrol.2020.125033>.

62. Ravi, N.K. Jha, P.K. Varma, K. Tripathi, P. Gautam, S.K. Ram, K. Kumar, M. and Tripathi, V. 2023. Application of water quality index (WQI) and statistical techniques to assess water quality for drinking, irrigation, and industrial purposes of the Ghaghara River, India. *Total Environment Research Themes*. 6-10049. <https://doi.org/10.1016/j.totert.2023.100049>.

63. Reche-Lopez, P. Ruiz-Reyes, N. Gal an, S.G. and Jurado, F. 2009. Comparison of metaheuristic techniques to determine optimal placement of biomass power plants. *Energy Convers. Manage.* 50(8): 2020-2028. <https://doi.org/10.1016/j.enconman.2009.04.008>.

64. Saleem, M. Hussain, A. Mahmood, G. 2016. Analysis of groundwater quality using water quality index: A case study of greater Noida (Region), Uttar Pradesh (UP), India. *Cogent Engineering*. 3(1), 1237927. <https://doi.org/10.1080/23311916.2016.1237927>.

65. Sayed, S. Abdoulhalik, A. Moutari, S. and Oyedele, L. 2024. Applications of machine learning to water resources management: A review of present status and future opportunities. *Journal of Cleaner Production*; 441(15): 140715. <https://doi.org/10.1016/j.jclepro.2024.140715>.

66. Sepahvand, A. Beiranvand, N. and Arjmand, N. 2025. Water quality Index (WQI) modeling using Artificial Intelligence

84. Wagh, V.M. Panaskar, D.B. Muley, A.A. and Mukate, S.V. 2017. Groundwater suitability evaluation by CCME WQI model for Kadava river basin, Nashik, Maharashtra, India. *Modeling Earth Systems and Environment*. 3 (2): 557–565. doi: <https://link.springer.com/article/10.1007/s40808-017-0316-x>.
85. Wang, J.S. and Li, S.X. 2019. An improved grey wolf optimizer based on differential evolution and elimination mechanism. *Sci. Rep.* 9 (1): 71-81. <https://doi.org/10.1038/s41598-019-43546-3>.
86. Xing, H. Zhou, X. Wang, X. Luo, S. Dai, P. Li, K. and Yang, H. 2019. An integer encoding grey wolf optimizer for virtual network function placement. *Appl. Soft Comput.* 76: 575–594. Doi: <https://doi.org/10.1016/j.asoc.2018.12.037>.
87. Yılmaz, E. Koç, C. 2016. Organic pollution of the Büyük Menderes River, Turkey and effects on aquaculture. *Environ Sci Pollut Res Int.* 23(12): 493-506. DOI: 10.1007/s11356-016-6397-7.
88. Zhang, R. Qian, X. Li, H. Yuan, X. and Ye, R. 2012. Selection of Optimal River Water Quality Improvement Programs Using QUAL2K: A Case Study of Taihu Lake Basin, China. *The Science of The Total Environment*. 1;431: 278-85. <https://doi.org/10.1016/j.scitotenv.2012.05.063>.
- org/10.1002/9780470496916.
76. Tania, M. Radu, M. Dan, V. Rodica, V. and Mihnea, M. 2013. Water quality assessment of the nadas river (romania) in terms of NSF water quality index. *Analele Universităţii Din Oradea, Fascicula Protecţia Mediului*, 21.
77. Taylor, K.E. 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research. Atmospheres.* 106 (D7): 7183–7192. <https://doi.org/10.1029/2000JD900719>.
78. Tsai, Y.W. Lin, J.Y. and Chen, Y.C. 2021. Establishment of the watershed health indicators and health check of reservoirs. *Ecological Indicator.* 127(5): 107779. <https://doi.org/10.1016/j.ecolind.2021.107779>.
79. Tu, Q. Chen, X. and Liu, X. 2019. Hierarchy strengthened grey wolf optimizer for numerical optimization and feature selection. *IEEE Access.* 7: 78012–78028. <https://doi.org/10.1109/ACCESS.2019.2921793>.
80. Tyagi, P.K. Shruti, S.V. and Ahuja, A. 2012. Synthesis of metal nanoparticles. A biological prospective for analysis. *International Journal of Pharmaceutical Innovations.* 2(4): 48-60.
81. Vapnik, V. 1995. *The Nature of Statistical Learning Theory*. Springer, New York. https://doi.org/10.1007/978-1-4757-3264-1_1.
82. Vapnik, V. Golowich, S.E. and Smola, A.J. 1997. Support vector method for function approximation, regression estimation and signal processing. *Adv. Neural Inform. Process Syst.* 9: 281–287.
83. Vasant, W. Dipak, P. Aniket, M. Ranjitsinh, P. Shrikant, M. Nitin, D. Manesh, A. and Abhay, V. 2016. GIS and statistical approach to assess the groundwater quality of Nanded Tehsil, (MS) India. In: *Proceedings of First International Conference on Information and Communication Technology for Intelligent Systems*: 1(50): 409–417. Doi: 10.1007/978-3-319-30933-0_41