



Assessment of Groundwater Hardness in Khorramabad Plain Using Hybrid Models Based on Metaheuristic Algorithms

Hamidreza Babaali¹ | Ebrahim Nohani² | Reza Dehghani³

1. Associate Professor, Department of Civil Engineering, Islamic Azad University, Khorramabad branch, Khorramabad, Iran.
2. Assistant Professor, Department of Civil Engineering, Materials and Energy Research Center, Dezful Branch, Islamic Azad University, Dezful, Iran.
3. PhD in Water Sciences and Engineering, Department of Soil Conservation and Watershed Management, Lorestan Province Agriculture and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization, Khorramabad, Iran.

✉Corresponding Author: A.saberinasr@scu.ac.ir

Received:
15 November 2024

Accepted:
01 December 2024

Published:
20 December 2024

Keywords:

*Groundwater,
Khorramabad,
Support Vector Regression,
Metaheuristic.*

Extended abstract

Introduction

Over the past century, water scarcity has become a significant global issue due to climate change, population growth, urbanization, and agriculture. In response to this problem, groundwater resources have been used extensively for various purposes, including agriculture, industry, and drinking. However, the increasing global demand for water has led to the overexploitation of groundwater and a decline in quality. Groundwater pollution has adversely affected the accessibility and suitability of groundwater and is detrimental to human health. Furthermore, cleaning up polluted groundwater is costly and time-consuming due to the complex nature of groundwater systems and the invisible threat of groundwater contamination. Therefore, assessing and monitoring groundwater quality is crucial, considering the potential risk of groundwater contamination and its effects on human usability. In recent years, models based on artificial intelligence approaches have been employed due to the non-linear and complex nature of geohydrological issues. Khorramabad is one of the important regions of Lorestan province, where the drinking water of the city is supplied from groundwater resources.

Cite this article: Babaali, H., Nohani, E. & Dehghani, R. (2024). Assessment of groundwater hardness in Khorramabad plain using hybrid models based on metaheuristic algorithms, *Journal of Aquifer and Qanat Title*, 5 (1), 125-138. DOI: <http://doi.org/10.22077/jaaq.2025.8579.1083>



Copyright: © 2024 by the authors. Licensee Journal of Aquifer and Qanat. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

In recent years, the quality of drinking water in this region has faced problems. The quality of groundwater in this area has decreased annually from the past to the present, posing a serious threat to the health of living organisms. Therefore, it is essential to analyze and investigate the quality of groundwater in this region using a hybrid model of support vector regression with metaheuristic algorithms to estimate the hardness of groundwater.

Methodology

To model the hardness of groundwater in the Khorramabad plain, a support vector regression (SVR) model was used in conjunction with wavelet, grey wolf, and firefly algorithms. In the SVR model, activation functions known as kernels were also utilized. These kernels included radial basis, polynomial, and linear functions, which were examined in this research. For this purpose, the values of the qualitative parameters of the Nasirvand piezometric well were normalized and then fed into the SVR model. In recent years, because the parameter values of the kernel functions in the SVR model are chosen randomly, optimization algorithms have been used to increase the model's accuracy and reduce errors. In this study, wavelet, grey wolf, and firefly algorithms were also used to optimize the tuning parameters to improve the model's performance. Therefore, in this research, after entering the input parameter data into the model and optimizing the tuning parameters, a hybrid model structure is formed, leading to the computational response of the model. Since the stopping criterion in training artificial intelligence models is the error rate, the model stops at the lowest error rate, and the output is generated.

Results and Discussion

The results showed that hybrid models in the combined scenario, which included all input parameters, had less error compared to other scenarios. Therefore, increasing the number of effective parameters in hybrid models based on support vector regression leads to an increase in the model's performance. Also, all models show better accuracy with the radial basis kernel function. The results of the studied models, according to the evaluation criteria, showed that the support vector regression-wavelet model with the highest correlation coefficient of 0.917, the lowest root mean square error (ppm) of 0.190, the lowest mean absolute error (ppm) of 0.115, and the highest Nash-Sutcliffe coefficient of 0.920, showed better performance in the validation stage.

Conclusions

The results of the study, based on the evaluation of scenarios consisting of input parameters, showed that in all the models examined, increasing the number of effective parameters in different modeling methods leads to better performance in estimating the hardness of groundwater. Furthermore, the results from the evaluation criteria indicated that the support vector regression-wavelet model has high accuracy and negligible error. Additionally, according to the examined graphs, the support vector regression-wavelet model estimated the groundwater hardness values close to their actual amounts.

Overall, the results of this study indicate that the use of artificial intelligence models based on the support vector regression approach can be beneficial for estimating the quality of groundwater over a 20-year statistical period for other regions of the country and is a step towards making appropriate management decisions. It is also suggested that to improve the quality of results, precise statistics and long-term datasets should be used, and to evaluate the model, the results should be compared with other regions.



ارزیابی سختی آب زیرزمینی دشت خرم آباد با استفاده از مدل‌های هیبریدی مبتنی بر الگوریتم‌های فراابتکاری (مطالعه موردی: لندفیل همدان)

حمیدرضا باباعلی^۱ | ابراهیم نوحانی^۲ | رضا دهقانی^۳ ✉

۱. دانشیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد، خرم‌آباد، ایران
۲. استادیار گروه عمران، مرکز تحقیقات مواد و انرژی، واحد دزفول، دانشگاه آزاد اسلامی، دزفول، ایران.
۳. دکترای علوم و مهندسی آب، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران.

✉ نویسنده مسئول: R.kh72777@gmail.com

چکیده

در این پژوهش از مدل هیبریدی رگرسیون بردار پشتیبان با الگوریتم‌های بهینه‌سازی مویک، کرم شب تاب و گرگ خاکستری به منظور برآورد میزان سختی آب زیرزمینی چاه ناصرون واقع در دشت خرم‌آباد استان لرستان استفاده شد. جهت مدل‌سازی از داده‌های کیفی چاه موجود شامل پارامتر هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (So_4)، منیزیم (mg)، کلسیم (ca) و سختی آب (TH) همگی بر حسب ppm در مقیاس زمانی ماهانه در طی سال آبی (۱۴۰۲-۱۳۸۲) به عنوان ورودی و میزان سختی آب زیرزمینی به عنوان خروجی مدل انتخاب گردید. به منظور ارزیابی عملکرد مدل‌ها از معیارهای ارزیابی ضریب هم‌بستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش ساتکلیف استفاده شد. همچنین جهت تحلیل نتایج مدل‌ها از نمودار سری زمانی و باکس پلات و تیلور استفاده شد. نتایج نشان داد سناریوهای ترکیبی در مدل‌های مورد بررسی باعث بهبود عملکرد مدل می‌شود. مقایسه نتایج نشان داد مدل رگرسیون بردار پشتیبان - مویک عملکرد بهتری نسبت به مدل رگرسیون بردار پشتیبان - گرگ خاکستری در مدل‌سازی دارد، به گونه‌ای که مدل رگرسیون بردار پشتیبان - مویک با ضریب هم‌بستگی ۰/۹۱۷، کمترین ریشه میانگین مربعات (ppm) ۱۹۰ / ۰، کمترین میانگین قدر مطلق خطا (ppm) ۰/۱۱۵ و بیشترین ضریب نش ساتکلیف ۰/۹۲۰ در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد استفاده از مدل‌های هوشمند مبتنی بر رویکرد رگرسیون بردار پشتیبان می‌تواند رویکردی مؤثر در مدیریت کیفی آب‌های زیرزمینی باشد.

تاریخ دریافت: ۱۴۰۳/۰۸/۲۵

تاریخ پذیرش: ۱۴۰۳/۰۹/۱۱

تاریخ انتشار: ۱۴۰۳/۰۹/۳۰

کلیدواژه‌ها:

آب زیرزمینی،

خرم‌آباد،

رگرسیون بردار پشتیبان،

فراابتکاری.

مقدمه

در طول قرن گذشته، کمبود آب به دلیل تغییرات آب و هوایی، رشد جمعیت، شهرنشینی و کشاورزی به یک مسئله مهم در سطح جهانی تبدیل شده است (Raj and Singh, 2021). در پاسخ به این مشکل، از منابع آب زیرزمینی به طور متناوب برای مصارف مختلف از جمله کشاورزی، صنعت و شرب استفاده می‌شود (Dwivedi and Pathak, 2007). با این حال، افزایش تقاضای جهانی برای آب منجر به بهره برداری بیش از حد از آب‌های زیرزمینی و کاهش کیفیت آن شده است. تخریب کیفیت آب‌های زیرزمینی به شدت تحت تأثیر عوامل طبیعی (نفوذ آب دریا و واکنش‌های شست و شوی آب-سنگ) و عوامل انسانی (معدن کاری، آلودگی صنعتی، استفاده بیش از حد از کودها و آفت‌کش‌ها و فاضلاب خانگی) است که بر ویژگی‌های فیزیکی و شیمیایی آب‌های زیرزمینی تأثیر می‌گذارد (Gupta et al., 2020). آلودگی آب‌های زیرزمینی تأثیرات نامطلوبی بر دسترسی و مناسب بودن آب‌های زیرزمینی داشته و برای سلامت انسان مضر است. علاوه بر این، به دلیل سیستم‌های پیچیده آب‌های زیرزمینی و تهدید نامرئی آلودگی‌های آب زیرزمینی، پاک‌سازی آب‌های زیرزمینی آلوده پرهزینه و زمان‌بر است. بنابراین، ارزیابی و پایش کیفیت آب زیرزمینی با توجه به خطر بالقوه آلودگی آب زیرزمینی و اثرات آن بر قابلیت مصرف انسانی، بسیار ضروری است. در سال‌های اخیر به دلیل ماهیت غیر خطی و پیچیده مسائل ژئوهیدرولوژی از مدل‌های مبتنی بر رویکرد هوش مصنوعی استفاده نمودند. این مدل‌ها از طبیعت موجودات زنده الهام گرفته و قادرند مسائل با پیچیدگی و گستردگی فراوان را حل نمایند. این مدل‌ها در زمینه پایش بینی پارامترهای کیفی آب زیرزمینی مورد توجه محققین قرار گرفته است که می‌توان به موارد زیر اشاره نمود

در پژوهشی ارزیابی مدل‌های هیبریدی رگرسیون بردار پشتیبان-رقابت استعماری و رگرسیون بردار پشتیبان-گرگ خاکستری به منظور پایش بینی کیفیت آب زیرزمینی دشت سلماس واقع در کشور ایران بررسی نمودند نتایج نشان داد مدل رگرسیون بردار پشتیبان-گرگ خاکستری از عملکرد بهتری برخوردار است (Emami et al., 2021). در پژوهشی جهت پایش بینی کیفیت آب زیرزمینی دشت

خارطوم سودان از مدل‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی استفاده کردند در این پژوهش از ۱۱ پارامتر فیزیکی و شیمیایی جمع آوری شده از ۲۰ چاه آب زیرزمینی pH، EC، TDS، TH، Cl⁻، SO₄²⁻، NO₃⁻، Ca⁺²، Mg⁺²، Na⁺ و HCO₃⁻ بهره گرفتند نتایج نشان داد مدل رگرسیون بردار پشتیبان از خطای کمتری نسبت به مدل شبکه عصبی مصنوعی برخوردار است (Mohammed et al., 2023). جهت پایش بینی کیفیت آب زیرزمینی دشت حمیر پر هیمالچال واقع در هند از مدل‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی استفاده کردند نتایج نشان داد مدل رگرسیون بردار پشتیبان از دقت بیشتری نسبت به مدل عصبی مصنوعی برخوردار است (Chandel et al., 2024). در پژوهشی جهت پایش بینی کیفیت آب زیرزمینی دشت مراغه واقع در کشور ایران از مدل‌های شبکه‌های عصبی پایش‌خور، رگرسیون بردار پشتیبانی و سیستم استنتاج فازی عصبی تطبیقی استفاده نمودند نتایج نشان داد مدل رگرسیون بردار پشتیبان از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است (Nourani et al., 2024).

در مجموع با توجه به پژوهش‌های انجام‌شده، مدل هوش مصنوعی رگرسیون بردار پشتیبان به عنوان ابزاری کارآمد در برآورد کیفیت آب‌های زیرزمینی و مسائل ژئوهیدرولوژی می‌باشد. امروزه به منظور افزایش کارایی و بهبود عملکرد مدل رگرسیون بردار پشتیبان، از ترکیب این مدل با الگوریتم‌های فراابتکاری به عنوان یک راهکاری مناسب جهت پایش بینی میزان سختی آب زیرزمینی استفاده می‌شود. در این پژوهش نیز از مدل‌های هیبریدی رگرسیون بردار پشتیبان-کرم شب تاب و رگرسیون بردار پشتیبان-گرگ خاکستری جهت تخمین میزان سختی آب زیرزمینی دشت خرم‌آباد واقع در استان لرستان استفاده شد. شهرستان خرم‌آباد یکی از مناطق مهم استان لرستان می‌باشد به گونه‌ای که آب شرب این شهرستان از منابع آب زیرزمینی تأمین می‌شود و در سال‌های اخیر کیفیت آب شرب این منطقه با مشکل مواجه شده است به گونه‌ای که در از گذشته تاکنون کیفیت آب زیرزمینی این منطقه سالانه کاهش یافته و این سبب مخاطره جدی برای سلامت موجودات زنده می‌شود. بنابراین تحلیل و بررسی کیفیت آب زیرزمینی این منطقه با شرایط سرمایه گذاری


می‌باشد. همچنین متوسط بارش سالانه محدوده مطالعاتی خرم‌آباد ۵۰۹ میلی‌متر و متوسط دمای آن ۱۷/۲ درجه سانتی‌گراد است. سفره آبدار اصلی دشت خرم‌آباد را رسوبات آبرفتی تشکیل می‌دهد که این دشت دارای یک حلقه چاه پیژومتر با آمار همگن بوده و فاقد آمار و اطلاعات مفقود است که در شکل ۱ قابل‌مشاهده است. همچنین جهت مدل‌سازی از پارامترهای هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (So_4)، منیزیم (mg) و کلسیم (ca) و به‌عنوان ورودی و سختی آب (TH) به‌صورت ماهانه که در شرکت آب منطقه‌ای لرستان طی بازه زمانی ۱۳۸۲-۱۴۰۲ در دسترس بود، استفاده گردید. که ۸۰٪ داده‌ها برای مدل‌سازی و ساخت مدل (دوره آموزش) و ۲۰ درصد آن برای صحت‌سنجی و یا ارزیابی مدل (دوره تست) می‌باشد. جدول (۱) موقعیت جغرافیایی چاه‌های پیژومتر موردبررسی نشان داده شد. بدین‌منظور برای مدل‌سازی پارامترهای هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (So_4)، منیزیم (mg) و کلسیم (ca) و به‌عنوان ورودی و سختی آب (TH) به‌عنوان پارامتر خروجی مدل انتخاب شد.

اقتصادی، تولید محصولات آبی، گردشگری و موقعیت ویژه جغرافیایی برنامه‌ریزی آمایش استان لرستان و حتی کشور را تحت تأثیر قرار می‌دهد، امری لازم و ضروری است. از طرف دیگر اگرچه استفاده از مدل رگرسیون بردار پشتیبان به‌طور گسترده برای پیش‌بینی کیفیت آب زیرزمینی این منطقه استفاده شده است. تاکنون پژوهشی در زمینه استفاده و مقایسه الگوریتم‌های فراابتکاری گرگ خاکستری و کرم شب‌تاب در این منطقه انجام نشده است. بنابراین در این پژوهش از الگوریتم‌های بهینه‌سازی با هدف ترکیب با مدل رگرسیون بردار پشتیبان برای برآورد میزان سختی آب زیرزمینی شهرستان خرم‌آباد استفاده شد.

مواد و روش‌ها

منطقه مورد مطالعه

دشت خرم‌آباد در مرکز استان لرستان واقع در کشور ایران بین عرض‌های جغرافیایی ۳۳ درجه و ۱۳ دقیقه تا ۳۳ درجه و ۳۵ دقیقه شمالی و طول‌های جغرافیایی ۴۷ درجه و ۵۲ دقیقه تا ۴۸ درجه و ۴۶ دقیقه شرقی قرار گرفته است. حداکثر ارتفاع منطقه ۱۹۰۳ متر و حداقل آن ۹۲۹ متر و مساحت این محدوده مطالعاتی ۲۵۱۷ کیلومترمربع



شکل ۱- منطقه مورد مطالعه

Figure 1- Study area

جدول ۱ - موقعیت جغرافیایی ایستگاه‌های مورد مطالعه

Table 1 - Geographical location of the studied stations

شماره	چاه پیزومتر	طول جغرافیایی	عرض جغرافیایی	ارتفاع (m)
۱	ناصروند	۴۸° ۲۳' ۴۱"	۳۳° ۲۳' ۵۳"	۱۲۳۴

مدل رگرسیون بردار پشتیبان به صورت زیر می باشد (Vapnik, 1998).

$$f(x) = W^T \cdot \phi(x) + b \quad (1)$$

$$y = f(x) + \text{noise} \quad (2)$$

رگرسیون بردار پشتیبان همانند مدل‌های هوش مصنوعی دارای توابع محرکی بوده که کرنل نام دارند این کرنل‌ها شامل کرنل چندجمله‌ای^۱ و کرنل توابع پایه شعاعی^۲ (RBF) و کرنل خطی می‌باشند و مطابق روابط زیر برآورد می‌شوند (Vapnik and Chervonenkis, 1991; Basak et al., 2007). در این پژوهش نیز از این سه تابع کرنل استفاده شد. همچنین مدل رگرسیون بردار پشتیبان در نرم‌افزار متلب کدنویسی شد.

$$k(x_i, x_j) = (t + x_i \cdot x_j)^d \quad (3)$$

$$IK(x_i, x_j) = \exp\left[-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right] \quad (4)$$

$$k(x_i, x_j) = x_i \cdot x_j \quad (5)$$

سناریوی گرگ خاکستری

گرگ خاکستری GWO یک الگوریتم شبیه‌سازی بوده که از رفتار اجتماعی گرگ‌های خاکستری و فرآیند سلسله‌مراتبی بهره گرفته است (Ostu, 1979). این الگوریتم بر مبنای جمعیت بوده و به سادگی به مسائل با ابعاد قابل‌گسترش قابل‌تعمیم است. در این الگوریتم شکارچیان رأس، گرگ‌های خاکستری هستند که در بالای هرم قرار می‌گیرند. این گرگ‌ها در یک دسته قرار دارند، که هر گروه ۵-۱۲ عضو به طور متوسط دارد. گرگ‌های واقع در رأس هرم دارای وظایف خاصی بوده و

در این پژوهش داده‌های مورد استفاده به صورت سری زمانی ماهانه از شرکت آب منطقه‌ای لرستان اخذ شد. سپس طول دوره آماری که همگن بوده و فاقد داده گمشده می‌باشد، انتخاب شد. همچنین در این پژوهش از پارامترهایی که مقادیر آنها ثابت و در دسترس بود استفاده شد. به منظور یکپارچه سازی داده‌های مورد استفاده فرآیند نرمال‌سازی بر روی داده‌ها صورت گرفت و سپس وارد مدل‌های هوشمند مبتنی بر رویکرد ماشین بردار پشتیبان شدند. امروزه به دلیل افزایش دقت و کارایی مدل‌های هوشمند از فرآیند بهینه نمودن پارامترهای تنظیم مدل‌های هوش مصنوعی استفاده می‌نمایند که به صورت اختصار مدل و الگوریتم‌های مورد بررسی در زیر به اختصار تشریح می‌گردد. در این پژوهش نیز از الگوریتم‌های موجک، گرگ خاکستری و کرم شب تاب جهت بهینه نمودن پارامترهای تنظیم توابع فعال‌سازی (کرنل) مدل رگرسیون بردار پشتیبان استفاده شد. جهت فرآیند مدل‌سازی ۸۰ درصد داده‌ها از سال ۱۳۸۲ تا ۱۳۹۸ برای آموزش و ۲۰ درصد باقی مانده از سال ۱۳۹۹ تا ۱۴۰۲ برای آزمون یا صحت سنجی به صورت تصادفی انتخاب شدند. سپس، بعد از ساخت مدل داده‌های ورودی وارد مدل شده و منجر به پاسخ خروجی می‌گردد. در نهایت پاسخ خروجی طبق شاخص‌های ارزیابی و نمودارهای کیفی مورد بررسی و تجزیه و تحلیل قرار گرفت.

رگرسیون بردار پشتیبان


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

1. Polynomial

2. Radial Basis Functions (RBF)


آلفا (α)، بتا (β)، دلتا (δ) و امگا (ω) برای شبیه‌سازی سلسله‌مراتب رهبری استفاده شده است. (α آلفا: مناسب‌ترین جواب، β بتا: مناسب‌ترین جواب با فاکتور گرفتن از α ، دلتا: مناسب‌ترین جواب با فاکتور گرفتن از α و β ، امگا: مابقی راه‌حل‌های کاندید شده).

سلسله‌مراتب تسلط اجتماعی دقیقی دارند. در هر گله گرگ‌ها ۴ درجه جهت شکار کردن وجود دارد. در این سناریو بهینه‌سازی، از رفتار گرگ‌های خاکستری و سلسله‌مراتب رهبری و روش شکار آن‌ها سناریو برداری می‌شود. در این سناریو از چهار نوع گرگ خاکستری شامل



شکل ۲- سناریو سلسله‌مراتبی گرگ‌ها (Khan et al., 2018)

Figure 2 - Wolves Hierarchy Scenario (Khan et al., 2018)



شکل ۳. نمودار جریان‌ی سناریو گرگ خاکستری (Chawla et al., 2019)

Figure 3. Flowchart of the Gray Wolf Scenario (Chawla et al., 2019)

تبدیل موجک

شب تاب جهت حل مسائل استفاده می‌شود (Yang, 2008). در الگوریتم کرم شب‌تاب هر راه‌حل مسئله به‌صورت یک کرم شب‌تاب در نظر گرفته می‌شود و کرم‌های شب‌تاب برحسب شایستگی می‌توانند از خود نور تولید و سایر کرم‌های شب‌تاب را به سمت خود جذب نمایند. این الگوریتم، یک الگوریتم بهینه‌سازی جمعیت محور و تصادفی می‌باشد که اولین بار توسط یانگ به جامعه علمی معرفی شد (Yan et al., 2012). این الگوریتم بر مبنای رفتار کرم‌های شب‌تاب در جذب جفت عمل می‌کند. سه فرضیه اساسی این الگوریتم به‌صورت زیر است.

الف) برای کرم‌های شب‌تاب جنسیت خاصی در نظر گرفته نمی‌شود

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

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

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

$$\beta(r) = \beta_0 e^{-r/r_{ij}^2} \quad (6)$$

در این رابطه β ، میزان جذابیت کرم درخشان‌تر در $r=0$ است (فاصله کرم شب‌تاب کم‌نور نسبت به کرم شب‌تاب پر نور تر است). موقعیت کرم i ام پس از حرکت به سمت کرم j ام که درخشان‌تر است از رابطه زیر محاسبه می‌گردد:

$$X_{id}(t+1) = X_{id}(t) + \beta_0 e^{-r/r_{ij}^2} (X_{jd}(t) - X_{id}(t)) + \alpha \left(rand - \frac{1}{2} \right) \quad (7)$$

$$r_{ij} = \|X_i - X_j\| \quad (8)$$

Rand عدد تصادفی بین ۰ و ۱ است و α بین ۰ و ۱ است و پارامتر تصادفی سازی نامیده می‌شود.

معیار ارزیابی

در این پژوهش جهت ارزیابی مدل‌های مورد بررسی به‌منظور تخمین کیفیت آب زیرزمینی دشت خرم‌آباد از شاخص‌های ارزیابی زیر استفاده شد.

تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه‌ی زمان کوتاه ارائه‌شده است و هدف از ارائه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه‌ی زمان کوتاه، سیگنال موردنظر به پنجره‌هایی تقسیم‌شده و تبدیل موجک بر روی هرکدام از این پنجره‌ها به‌صورت جداگانه انجام می‌گیرد (Wang et al., 2000). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به‌عبارت‌دیگر، در تبدیل موجک به‌جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان - مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط‌شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض‌شده و کلیات سیگنال قابل بررسی می‌باشد. یک موجک به‌معنای موج کوچک، بخشی یا پنجره‌ای از سیگنال اصلی است که انرژی آن در زمان متمرکز شده است. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد. بنابراین موجک‌ها نمونه‌های انتقال‌یافته^۲ و مقیاس‌شده‌ی^۳ سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند (Nourani et al., 2018). بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نا مانا و گذرا^۴ را به‌صورت موضعی مورد تجزیه و تحلیل قرارداد (shin et al., 2005).

الگوریتم کرم شب‌تاب

الگوریتم کرم شب‌تاب از جمله الگوریتم‌های بهینه‌سازی می‌باشد که از رفتار موجودات زنده الهام گرفته شده است. این الگوریتم از جمله الگوریتم‌های فراابتکاری بوده که در حل مسائل پیچیده بسیار کارایی دارد. این الگوریتم از رویکرد گروهی الهام گرفته به‌صورتی که از حالت نورافشانی کرم‌های

2 Translation

3Dilation

4 Transient

آب زیر زمینی از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر به‌عنوان متغیر هدف انتخاب شد. در جدول ۱ ویژگی‌های آماری پارامتر استفاده‌شده، ارائه شده است. لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت تست، به‌صورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (Nagy et al., 2002; Kisi et al., 2006). یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. در مدل‌های هوشمند انتخاب ورودی‌های اولیه مناسب و تأثیرگذار در پدیده به‌منظور آموزش ماهیت سازوکار حاکم بر پدیده باعث بهبود عملکرد خواهد شد بنابراین در سناریو سازی میزان میزان سختی آب زیر زمینی نیز سعی گردید تا مؤثرترین داده‌های مشاهداتی به‌عنوان داده‌های آموزشی انتخاب شود (Dehghani et al., 2020). بدین‌منظور ترکیب‌های مختلفی از پارامتر ورودی به‌منظور دستیابی به مدل بهینه جهت تخمین میزان سختی آب زیر زمینی استفاده شد که در جدول ۲ آمده است.

به‌منظور مدل‌سازی میزان سختی آب زیر زمینی دشت خرم‌آباد از مدل رگرسیون بردار پشتیبان با الگوریتم‌های موجک، گرگ خاکستری و کرم شب تاب استفاده شد. همچنین در مدل رگرسیون بردار پشتیبان از توابع محرکی که کرنل نام دارند، استفاده شد این توابع شامل توابع پایه شعاعی، چندضلعی و خطی می‌باشد که در این پژوهش مورد بررسی قرار گرفت. بدین‌منظور مقادیر پارامترهای کیفی چاه پیژومتری ناصروند نرمال‌سازی شده سپس وارد مدل رگرسیون بردار پشتیبان می‌شود لازم به ذکر است فرآیند نرمال‌سازی مطابق رابطه (۱۳) صورت گرفت (Zhu et al., 2007). در سال‌های اخیر به‌دلیل آنکه در مدل رگرسیون بردار پشتیبان مقادیر پارامترهای تنظیم توابع کرنل به‌صورت تصادفی انتخاب می‌گردند از الگوریتم‌های بهینه‌سازی جهت افزایش دقت و کاهش خطای مدل استفاده شده است (Dehghani and Torabi, 2021). در این پژوهش نیز جهت افزایش عملکرد مدل از الگوریتم‌های موجک، گرگ خاکستری و کرم شب تاب جهت بهینه نمودن مقادیر پارامترهای تنظیم استفاده شد. بنابراین در این پژوهش بعد از ورود اطلاعات پارامترهای ورودی به مدل و بهینه نمودن پارامترهای تنظیم ساختار مدل هیبریدی شکل گرفته و

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad 1 \leq R \leq 1 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (10)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad (11)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad \infty \leq NS \leq 1 \quad (12)$$

در روابط بالا، R ضریب هم‌بستگی، $RMSE$ ریشه میانگین مربعات خطا برحسب NS معیار نش سانتکلیف، y_i و x_i به‌ترتیب مقادیر مشاهداتی و محاسباتی سختی آب زیرزمینی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به‌ترتیب میانگین مقادیر مشاهداتی و محاسباتی سختی آب زیرزمینی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت مقایسه و تحلیل بیشتر استفاده می‌گردد.

نتایج و بحث

در این پژوهش به‌منظور مدل‌سازی میزان سختی آب زیر زمینی دشت خرم‌آباد واقع در استان لرستان از مدل رگرسیون بردار پشتیبان با الگوریتم‌های موجک، کرم شب تاب و گرگ خاکستری استفاده شد هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (SO_4)، منیزیم (mg) و کلسیم (ca) و به‌عنوان ورودی و سختی آب (TH) به‌عنوان پارامتر خروجی مدل در دوره زمانی ماهانه، سال ۱۴۰۲-۱۳۸۲ برای چاه پیژومتری ناصروند دشت خرم‌آباد به کار برده شد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آن‌ها در طبیعت کاری دشوار با عدم قطعیت بالا است. میزان سختی آب زیر زمینی از پارامترهای مهم هیدرولوژیکی از جمله کیفیت آب است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر میزان سختی آب زیر زمینی با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکرشده مورد استفاده قرار گرفت که در مقایسه با روش‌های تقریبی به‌مراتب عملکرد بهتری را ارائه می‌نماید. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای ژئوهیدرولوژی و ارائه مدل جهت پیش‌بینی در آینده است و از آنجایی که میزان میزان سختی

پشتیبان-موجک در تخمین کلیه مقادیر نسبت به داده‌های مشاهداتی عملکرد بهتری از خود نشان داده است در صورتیکه مدل رگرسیون بردار پشتیبان-گرگ خاکستری ضعیف عمل نموده است و مدل رگرسیون بردار پشتیبان-کرم شب تاب نیز از دقت مطلوبی برخوردار است و در رتبه دوم می‌باشد.

بنابراین مدل رگرسیون بردار پشتیبان-موجک نسبت به سایر مدل‌های مورد بررسی از عملکرد بهتری برخوردار است که این نتایج با پژوهش‌های فوق مطابقت دارد (Zeidalinejad and Dehghani, 2023; Babaali and Dehghani, 2023). در تحلیل این نتایج می‌توان بیان داشت برتری این مدل ناشی از تبدیل موجک می‌باشد که سیگنال‌های دریافتی را به دو دسته بالاگذر و پایین گذر تقسیم نموده و در دسته بالاگذر قدرت تفکیک افزایش یافته که سبب می‌گردد مقادیر بیشینه سیگنال با دقت مطلوبی تجزیه و تحلیل گردد.

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

به‌طور کلی پیشنهاد می‌شود از مدل هیبریدی رگرسیون بردار پشتیبان-موجک و کرم شب تاب به‌عنوان مدلی با خطای ناچیز برای حل مسائل غیرخطی با ابعاد بزرگ با سرعت مناسب در همگرایی به سمت یک جواب بهینه استفاده شود. همچنین می‌توان به‌عنوان راهکاری نوین در پیش بینی کیفیت آب‌های زیرزمینی منظور اتخاذ تصمیمات مدیریتی مناسب برای بهبود منابع آبی، آماده سازی زمین و سرمایه‌گذاری اقتصادی، تولید محصولات آبرزی دانست.

منجر به پاسخ محاسباتی مدل می‌گردد از آنجایی که معیار توقف در آموزش مدل‌های هوش مصنوعی میزان خطا می‌باشد بنابراین مدل در کمترین میزان خطا متوقف و خروجی حاصل می‌گردد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (13)$$

همان‌طور که در جدول ۳ مشخص است مدل‌های هیبریدی در سناریو شماره ۵ که شامل کلیه پارامترهای ورودی به مدل می‌باشد از خطای کمتری نسبت به سایر سناریوها برخوردار است بنابراین افزایش تعداد پارامترهای مؤثر در مدل‌های هیبریدی مبتنی بر رگرسیون بردار پشتیبان منجر به افزایش عملکرد مدل می‌شود. همچنین کلیه مدل‌ها در تابع کرنل پایه شعاعی از دقت بهتری برخوردار هستند. نتایج مدل‌های مورد بررسی در سناریو شماره ۵ در جدول ۴ نشان داده شده است همان‌طور که در جدول مشخص است مدل رگرسیون بردار پشتیبان-موجک با بیشترین ضریب هم‌بستگی ۰/۹۱۷، کمترین ریشه میانگین مربعات (ppm) ۰/۱۹۰، کمترین میانگین قدر مطلق خطا (ppm) ۰/۱۱۵ و بیشترین ضریب نش ساتکلیف ۰/۹۲۰ در مرحله صحت سنجی عملکرد بهتری از خود نشان داده است.

در شکل ۴ نمودار سری زمانی مقادیر مشاهداتی و محاسباتی نشان داده شده است همان‌طور که مشاهده می‌گردد مدل رگرسیون بردار پشتیبان-موجک نسبت به مدل‌های هیبریدی رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-کرم شب تاب در تخمین اکثر نقاط از جمله مینیم، ماکزیمم و میانی دقت قابل قبولی از خود نشان داده است همچنین مدل رگرسیون بردار پشتیبان-کرم شب تاب نیز از عملکرد مناسبی در تخمین اکثر نقاط برخوردار است اما مدل رگرسیون بردار پشتیبان-گرگ خاکستری در تخمین مقادیر میانی عملکرد نسبتاً مطلوبی داشته است و در تخمین مقادیر مینیم و ماکزیمم ضعیف عمل نموده است.

در شکل ۵ نمودار میزان خطای مدل‌های مورد بررسی نشان داده شد همان‌طور که مشاهده می‌گردد مدل رگرسیون بردار

جدول ۱- مشخصات آماری پارامترهای کیفی مورد بررسی

Table 1 - Statistical characteristics of the qualitative parameters under study

مرحله	پارامتر	واحد	میانگین	حداقل	حداکثر
Phase	Parameters	Unit	Mean	Minimum	Maximum

17.500	3.200	6.791	ppm	HCO ₃	آموزش
22	0.400	3.024	ppm	Cl	
10	0.300	2.360	ppm	So ₄	
6.900	1.200	3.250	ppm	Mg	
9.300	1.600	4.640	ppm	Ca	
805	160	395.560	ppm	Th	صحت سنجی
10.500	3	6.650	ppm	HCO ₃	
24.700	0.400	3.040	ppm	Cl	
5.900	0.400	2.220	ppm	So ₄	
9.300	1.800	3.660	ppm	Mg	
9.200	1.200	5.150	ppm	Ca	
925	240	434.460	ppm	Th	

جدول ۲- ترکیبات ورودی مدل‌های مورد بررسی

Table 2 - Input combinations of the models under study

شماره Number	ورودی Input	خروجی Output
1	HCO ₃ (t)	TH (t)
2	HCO ₃ (t), Cl (t)	TH (t)
3	HCO ₃ (t), Cl (t), SO ₄ (t)	TH (t)
4	HCO ₃ (t), Cl (t), SO ₄ (t), Ca (t)	TH (t)
5	HCO ₃ (t), Cl (t), SO ₄ (t), Ca (t), Mg (t)	TH (t)

جدول ۳- میزان خطای مدل‌های مورد بررسی تحت سناریوهای مختلف

Table 3 - Error rate of the models under study under different scenarios


مدل Model	سناریو Senario	آموزش Training RMSE (ppm)	صحت سنجی Testing RMSE (ppm)
GWO-SVR	1	0.278	0.248
	2	0.256	0.234
	3	0.245	0.220
	4	0.238	0.210
	5	0.231	0.205
FA-SVR	1	0.258	0.236
	2	0.247	0.221
	3	0.238	0.212
	4	0.231	0.205
	5	0.225	0.198
WSVR	1	0.261	0.244
	2	0.248	0.228
	3	0.242	0.221
	4	0.236	0.210
	5	0.231	0.205

جدول ۴- نتایج مدل‌های مورد بررسی

Table 4 - Results of the models studied


مدل Model	کرنل Kernel	آموزش Training	صحت سنجی Testing
--------------	----------------	-------------------	---------------------

NS	MAE (ppm)	RMSE (ppm)	R	NS	MAE (ppm)	RMSE (ppm)	R		
0.905	0.131	0.205	0.900	0.895	0.146	0.231	0.890	RBF	GWO-SVR
0.895	0.144	0.217	0.890	0.885	0.154	0.240	0.880	Poly	
0.890	0.155	0.224	0.885	0.880	0.162	0.248	0.870	Line	
0.910	0.122	0.198	0.910	0.905	0.139	0.225	0.901	RBF	FA-SVR
0.905	0.129	0.208	0.900	0.900	0.148	0.238	0.895	Poly	
0.900	0.148	0.216	0.897	0.895	0.155	0.242	0.880	Line	
0.920	0.115	0.190	0.917	0.915	0.132	0.220	0.910	RBF	WSVR
0.910	0.123	0.202	0.905	0.908	0.141	0.227	0.900	Poly	
0.905	0.142	0.224	0.895	0.900	0.148	0.236	0.890	Line	



شکل ۴- نمودار سری زمانی مدل‌های مورد بررسی

Figure 4- Time series diagram of the models under study



شکل ۵- نمودار میزان خطای مدل‌های مورد بررسی
Figure 5 - Error rate diagram of the models under study

به عملکرد بهتر در تخمین میزان سختی آب زیر زمینی می‌شود. علاوه بر این، نتایج حاصل از معیارهای ارزیابی نشان داد مدل رگرسیون بردار پشتیبان-موجک از دقت بالا و خطای ناچیزی برخوردار است. همچنین مطابق نمودارهای مورد بررسی مدل رگرسیون بردار پشتیبان-موجک مقادیر میزان سختی آب زیر زمینی را نزدیک به مقدار واقعی‌شان برآورد نموده است. در مجموع، نتایج این تحقیق نشان می‌دهد که استفاده از مدل‌های هوش مصنوعی مبتنی بر رویکرد مدل رگرسیون بردار پشتیبان می‌تواند در زمینه تخمین کیفیت آب‌های زیرزمینی طی ۲۰ سال آماری برای سایر مناطق کشور و گامی در جهت اتخاذ تصمیمات مدیریتی مناسب مورد استفاده قرار گیرد. همچنین پیشنهاد می‌گردد جهت بهبود کیفیت نتایج از آمار و اطلاعات دقیق و دارای دوره زمانی طولانی مدت استفاده شود و نیز جهت ارزیابی مدل نتایج با سایر مناطق مقایسه شود.

منابع

- Chandel, N., Gupta, S., Ravi, A. (2024). Ground Water Quality Analysis using Machine Learning Techniques: a Critical Appraisal. *Journal of Mining and Environment (JME)*, 15(2), 419-426. <https://doi.org/10.22044/jme.2023.13452.2484>
- Chawla, V.K., Chanda, A.K., Angra, S. (2019). The scheduling of automatic guided vehicles for the workload balancing and travel time minimization in the flexible manufacturing system by the nature-

نتیجه‌گیری

تخمین میزان سختی آب زیر زمینی توسط مدل‌های ترکیبی مبتنی بر رگرسیون بردار پشتیبان به‌عنوان ابزاری کارآمد در طراحی سیستم‌های ژئوهیدرولوژی می‌باشد. در پژوهش حاضر مطالعه موردی جهت ارزیابی عملکرد مدل فراابتکاری هیبریدی رگرسیون بردار پشتیبان به‌منظور برآورد میزان سختی آب زیر زمینی دشت خرم‌آباد واقع در استان لرستان صورت گرفت. بدین‌منظور از الگوریتم‌های الهام گرفته از طبیعت شامل موجک، کرم شب تاب و گرگ خاکستری که با مدل رگرسیون بردار پشتیبان ترکیب شده، استفاده گردید. همچنین جهت مدل‌سازی از پارامترهای هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (So_4)، منیزیم (mg) و کلسیم (ca) و به‌عنوان ورودی و سختی آب (TH) به‌عنوان خروجی مدل استفاده شد. به‌منظور ساخت مدل هیبریدی بهینه رگرسیون بردار پشتیبان ۸۰ درصد داده جهت آموزش و ۲۰ درصد باقی مانده جهت آزمون بررسی و انتخاب شدند. جهت ارزیابی مدل‌های مورد بررسی از شاخص‌های آماری ضریب هم‌بستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش ساتکلیف استفاده شد همچنین جهت تحلیل نتایج از نمودارهای سری زمانی استفاده گردید. نتایج تحقیق طبق ارزیابی سناریوهایی متشکل از پارامترهای ورودی نشان داد که در کلیه مدل‌های مورد بررسی افزایش تعداد پارامترهای مؤثر در مدل‌های مختلف مدل سازی منجر

- A.(2024).Spatiotemporal assessment of groundwater quality and quantity using geostatistical and ensemble artificial intelligence tools. *Journal of Environmental Management*.355(4),120-145.10.1016/j.jenvman.2024.120495 .
- Nourani, V., Tajbakhsh, A.D., Molajou, A. (2018). Data mining based on wavelet and decision tree for rainfall-runoff simulation. *Hydrol. Res*, 50, 75–84. <https://doi.org/10.2166/nh.2018.049>.
- Ostu, N. A. (1979). Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man and Cybernetics*,9 (1), 62-66.10.1109/TSMC.1979.4310076.
- Raj, C., & Singh, V. (2021). Spatial and temporal variation of fluvial islands and sandbars in River Ganga from Bhagalpur to Farakka during 1955– 2019. *Sustainable Water Resources Management*, 7(3), 22-38.<https://doi.org/10.1007/s40899-021-00522-y>.
- Shin, S., Kyung, D., Lee, S., Taik & Kim, J., and Hyun, J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(4), 127-135.<https://doi.org/10.1016/j.eswa.2004.08.009>.
- Vapnik, V., Chervonenkis, A.(1991). The necessary and sufficient conditions for consistency in the empirical risk minimization method. *Pattern Recognition and Image Analysis*,1(3), 283-305.10.12691/jgg-2-3-9.
- Vapnik, V.N. (1995).The nature of statistical learning theory. *Springer, New York*, 3(1), 250-320.<https://doi.org/10.1007/978-1-4757-3264-1>.
- Vapnik, V.N.(1998). Statistical learning theory. *Wiley, New York*, 4(1), 250-320. <https://doi.org/10.1007/978-1-4757-3264-1>.
- Wang, D., Safavi, A.A., and Romagnoli, J.A.(2000). Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*,46(4), 1607-1615. <https://doi.org/10.1002/aic.690460812>.
- Yan, X., Zhu, Y., Wu, J., Chen, H.(2012). An improved firefly algorithm with adaptive strategies. *Adv Sci Lett*, 16(1), 249–254.<https://doi.org/10.1016/j.eswa.2020.113340>.
- Yang, X.S.(2008). Firefly algorithm, nature-inspired meta-heuristic algorithms. *Wiley Online Libr*, 20, 79–90.https://doi.org/10.1007/978-3-642-29694-9_16.
- Zeidalinejad, N., Dehghani, R.(2023). Use of meta-heuristic approach in the estimation of aquifer's response to climate change under shared socioeconomic pathways. *Groundwater for Sustainable Development*, 20(4), 112-132.<https://doi.org/10.1016/j.gsd.2022.100882>.
- Zhu, Y. M., Lu, X. X., & Zhou, Y. (2007). Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84(1-2), 111-125.
- inspired algorithm. *Journal of Project Management*, 4(1):19-30.10.5267/j.jpm.2018.8.001
- Dehghani, R., Babaali, H.(2023). Evaluation of Statistical Models and Modern Hybrid Artificial Intelligence in Simulation of Runoff Precipitation Process. *Sustain. Water Resour. Manag*, 8, 154-172. <https://doi.org/10.1007/s40899-022-00743-9>.
- Dehghani, R., Torabi Poudeh, H., Younesi, H., Shahinejad, B.(2020). Daily Streamflow Prediction Using Support Vector Machine-Artificial Flora (SVM-AF) Hybrid Model. *Acta Geophysica*, 68(6), 51-66. <https://doi.org/10.1007/s11600-020-00472-7>
- Dehghani, R., Torabi, H.(2021). Dissolved oxygen concentration predictions for running waters using hybrid machine learning techniques. *Modeling Earth Systems and Environment*, 6(2), 64-78. <https://doi.org/10.1007/s40808-021-01253-x>.
- Dwivedi, S. L., & Pathak, V. (2007). A preliminary assessment of water quality index to Mandakini River, Chitrakoot. *Indian Journal of Environmental Protection*, 27(11), 103-122.10.4236/jwarp.2011.36050.
- Emami, S., Emami, H., Choopan, Y., Jahandideh, O.(2021). Modeling groundwater quality using three novel hybrid support vector regression models. *Advances in Environmental Technology* .2 (4),99-110.10.22104/aet.2021.4286.1212
- Gupta, S. K., Singh, P. K., Tyagi, J., Sharma, G., & Jethoo, A. S. (2020). Rainstorm-generated sediment yield model based on soil moisture proxies (SMP). *Hydrological Processes*, 34(16), 3448-3463. <https://doi.org/10.1002/hyp.13789>.
- Gupta, S. K., Tyagi, J., Sharma, G., Jethoo, A. S., & Singh, P. K. (2019). An event-based sediment yield and runoff modeling using soil moisture balance/budgeting (SMB) method. *Water Resources Management*, 33, 3721-3741.<https://doi.org/10.1007/s11269-019-02329-1>.
- Khan, M. F., Aadil, F., Maqsood, M., Khan, S., & Bukhari, B. H. (2018). An efficient optimization technique for node clustering in VANETs using gray wolf optimization. *KSII Transactions on Internet and Information Systems (TIIS)*, 12(9), 4228-4247.
- Kisi, O., Karahan, M., Sen, Z. (2006). River-suspended sediment modeling using the fuzzy logic approach. *Hydrol Process*, 20(2),4351-4362.10.1002/hyp.6166.
- Mohammed, M.A.A., Khleel, N.A.A., Szabó, N.P., Szűcs, P. (2023). Modeling of groundwater quality index by using artificial intelligence algorithms in northern Khartoum State, Sudan. *Model. Earth Syst. Environ*. 9, 2501–2516.<https://doi.org/10.1007/s40808-022-01638-6>.
- Nagy, H. M., Watanabe, K. A. N. D., & Hirano, M. (2002). Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulic Engineering*, 128(6), 588-595.
- Nourani, V., Ghaffari, A., Behfar, N., Foroumandi, E., Zeinali, A., Qing, C., Sankaran,