



The Impact of Climate Change Parameters on Groundwater Level Decline (Case Study: Kuhdasht-Lorestan)

Ebrahim Nohani¹, | Hamidreza Babaali² | Reza Dehghani³

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

✉Corresponding Author: Ebrahim.nohani@iau.ac.ir

Received:
28 January 2025

Accepted:
23 August 2025

Published:
22 September 2025

Keywords:

*Groundwater,
Prediction,
Artificial Neural Network,
General Circulation Model.*

Extended abstract

Introduction

The industrialization of societies in recent years has led to an increase in greenhouse gases. This increase has caused the Earth's temperature to rise, which in turn affects the conditions of other components of the climate system, leading to climate events that differ fundamentally from the natural trend of these events. This process is called climate change. According to the IPCC reports in 2007, the process of climate change and global warming significantly impacts various systems such as water resources, agriculture, drinking water, and industry. The continuous increase in greenhouse gas emissions will exacerbate these effects, leading to warmer temperatures, changes in precipitation patterns, melting of snow, and consequently, changes in the availability of drinking and agricultural water. Groundwater resources are connected to climate change through direct interaction with surface water resources like rivers and lakes, and indirect interaction through the recharge process. Climate change indirectly affects groundwater discharge and storage by altering recharge conditions resulting from rainfall and runoff.

Cite this article: Nohani, E., Babaali, H. & Dehghani, R. (2025). The Impact of Climate Change Parameters on Groundwater Level Decline (Case Study: Kuhdasht-Lorestan). *Journal of Aquifer and Qanat*, 6 (1), 87-106. DOI: <http://10.22077/jaaq.2025.9841.1119>



Copyright: © 2025 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/>).

Therefore, identifying and analyzing influential parameters, including climatic parameters, can greatly assist in predicting groundwater resources, thereby preventing serious hazards such as land subsidence and drought. On the other hand, given the complex and non-linear relationship between climatic parameters and groundwater resources, the use of artificial intelligence models, including novel hybrid models, is a suitable solution for these problems. Therefore, this research aims to analyze and predict climatic parameters using general atmospheric circulation models for the coming years and to predict the groundwater level of the kuhdasht plain using a hybrid model of wavelet-artificial neural network and a hybrid model of artificial neural network with a novel optimization algorithm such as the chicken swarm optimization, based on climatic parameters, groundwater level, and aquifer withdrawal.

Materials and Methods

In this research, to simulate and predict the groundwater level of the Kuhdasht plain, climatic parameters affecting groundwater levels will first be investigated based on general atmospheric circulation models. Then, the artificial neural network model approach will be used to predict the groundwater level, assuming that the amount of extraction from the groundwater resources of the Kuhdasht plain remains consistent with the past statistical period. Given that the ANN model has errors according to recent research, to reduce the model's error, the strategy of optimizing the tuning parameters using metaheuristic algorithms will be employed. In recent years, numerous studies have been conducted on the hybrid ANN model with metaheuristic algorithms; however, in this research, to address the challenges of this model and present a new algorithm to facilitate the simulation process, novel algorithms that have not yet been investigated in hydrological or hydrogeological processes will also be used. For this purpose, the novel chicken swarm optimization algorithms will be used to estimate the changes in groundwater level. Additionally, the performance of new metaheuristic algorithms will be compared with the hybrid wavelet artificial neural network model (WANN) for simulating groundwater levels. After obtaining and integrating the necessary statistics and information from the Regional Water Company and the Meteorological Organization of Lorestan Province, the normalization process will be carried out. Following data normalization, the artificial intelligence model will be used to simulate the groundwater level for the current period (2002-2022). For using the artificial intelligence model, 70% of the data will be selected for training (2002-2018) and the remaining 30% for validation (2018-2022). Then, by selecting the artificial intelligence model, the 20-year estimation or prediction of climatic parameters using general atmospheric circulation models will be undertaken. Finally, considering the estimation of climatic parameters such as temperature and precipitation for the next 20 years and the selected artificial intelligence model, the groundwater level will be predicted for the future period (2022-2042) and compared with the current groundwater level status (2022). Overall, suitable solutions will be presented to prevent excessive decline in groundwater levels.

Results and Discussion

The results obtained from evaluating the data generated using the LARS-WG model and the observed data from two piezometric wells, Baghzal and Bogelan, during the base period show that the coefficient of determination in all models studied was calculated to be greater than 0.96. The Mean Absolute Error (MAE) for simulating precipitation, minimum temperature, and maximum temperature was obtained as 0.25, 0.03, and 0.04, respectively, indicating that the error in precipitation simulation is greater than for other parameters. The RMSE and NRMSE indices were also significantly higher for precipitation simulation compared to other parameters (5.18 and 12.36, respectively), showing a greater error. Therefore, the ability of the LARS-WG model in simulating meteorological parameters is confirmed, but nonetheless, the model shows less accuracy in simulating precipitation. Furthermore, the results from model evaluation showed that the Artificial Neural Network-Wavelet model performs better than the

Artificial Neural Network-Chicken Swarm model. Specifically, for the Baghzal piezometric well, it has values of $R=0.970$, $RMSE=0.231$ m, $MAE=0.121$ m, and $NS=0.980$. For the Bogelan piezometric well, it has values of $R=0.982$, $RMSE=0.124$ m, $MAE=0.068$ m, and $NS=0.990$.

Conclusion

The evaluation of the LARS-WG model using data from the base period (2002-2022) indicated that the CIMP6 general atmospheric circulation model has a favorable performance in predicting meteorological parameters, with negligible differences observed across the examined scenarios. The simulated temperature in all considered climate models (SSp126, SSP245, and SSP585) for the future period (2022-2042) shows an increase compared to the base period across all months, while the average precipitation did not exhibit a clear trend. The results from the performance of the hybrid WANN and CSO-ANN models, based on the statistical period of 2002-2002, demonstrated that the models under consideration, when structured to include all input parameters, exhibit better performance due to increased memory capacity. The WANN model shows greater accuracy and less error compared to other models studied. The results from predicting groundwater levels in the coming years indicate a downward trend in all examined piezometric wells, with this decline being approximately -3 to -4.5 meters, assuming constant abstraction from the aquifers.



تأثیر پارامترهای تغییر اقلیم بر افت سطح آب زیرزمینی (مطالعه موردی: کوهدشت - لرستان)

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

۱. استادیار، گروه مهندسی عمران، مرکز تحقیقات مواد و انرژی، واحد دزفول، دانشگاه آزاد اسلامی، دزفول، ایران.
۲. دانشیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد، خرم‌آباد، ایران.
۳. دانش‌آموخته دکتری 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: Ebrahim.nohani@iau.ac.ir

چکیده

در سال‌های اخیر، گرم‌شدن هوا، نوسانات اقلیمی و فشار برداشت از منابع آب، سبب افت سطح آب‌های زیرزمینی شده است؛ بنابراین برای جلوگیری از تشدید روند فوق و مدیریت بهینه بهره‌برداری از منابع آب زیرزمینی دشت‌ها، شبیه‌سازی و پیش‌بینی تراز آب‌های زیرزمینی امری ضروری و اجتناب‌ناپذیر است. به‌منظور پیش‌بینی تغییرات سطح آب زیرزمینی آبخوان کوهدشت ابتدا از مدل گردش عمومی جو CIMP6 تحت سناریو مختلف، پارامترهای هواشناسی پیش‌بینی و تحلیل گردید. سپس با استفاده از پارامترهای دما، بارش و مقدار برداشت از آبخوان طی دوره آماری ۲۰۰۲-۲۰۲۲ عملکرد مدل‌های هیبریدی شبکه عصبی مصنوعی- موجک (WANN) و شبکه عصبی مصنوعی - ازدحام مرغ CSO-ANN در برآورد سطح آب زیرزمینی موردبررسی قرار گرفت. در گام بعد با بهره‌گیری از مدل منتخب هیبریدی تغییرات سطح آب زیرزمینی منطقه برای دوره آماری ۲۰۲۲-۲۰۴۲ پیش‌بینی شد. نتایج حاصل از مدل گردش عمومی جو نشان داد با افزایش دما میزان بارش کاهش می‌یابد و دمای شبیه‌سازی شده در کلیه مدل‌های اقلیمی (SSP585 و SSP245 و SSP126) مورد بررسی در دوره آتی (۲۰۲۲-۲۰۴۲) نسبت به دوره پایه در تمام ماه‌ها افزایش داشته در حالی‌که میانگین بارش روند مشخصی از خود نشان نداده است. همچنین نتایج حاصل از مدل‌سازی نشان داد مدل شبکه عصبی مصنوعی-موجک عملکرد بهتری نسبت به سایر مدل‌ها در برآورد سطح آب زیرزمینی دشت کوهدشت دارد همچنین نتایج مطابق مدل منتخب نشان داد این دشت طی سال‌های ۲۰۲۲-۲۰۴۲ میزان ۴/۵-۳ متر افت سطح آب زیرزمینی دارد.

تاریخ دریافت: ۱۴۰۴/۰۵/۰۷

تاریخ پذیرش: ۱۴۰۴/۰۶/۰۲

تاریخ انتشار: ۱۴۰۴/۰۶/۳۱

کلیدواژه‌ها:

آب زیرزمینی،

پیش‌بینی،

شبکه عصبی مصنوعی،

گردش عمومی جو.

مقدمه

صنعتی شدن جوامع در سال‌های اخیر سبب افزایش گازهای گلخانه‌ای شده است. این افزایش باعث گرم شدن کره زمین شده و به نوبه خود بر وضعیت اجزای دیگر سیستم اقلیم تأثیر دارد که موجب وقوع رخدادهایی در اقلیم شده؛ به گونه‌ای که تفاوت اساسی با روند طبیعی این رخدادها دارد، این فرایند تغییر اقلیم نام دارد (Li et al., 2015). مطابق با گزارش‌ها IPCC در سال ۲۰۰۷، فرایند تغییر اقلیم و گرمایش جهانی تأثیر به سزایی بر سیستم‌های مختلف مانند منابع آب، کشاورزی، شرب و صنعت دارد؛ به گونه‌ای که افزایش پیوسته انتشار گازهای گلخانه‌ای این اثرات را تشدید خواهد کرد و سبب گرم‌تر شدن هوا، تغییر در الگوی بارش، ذوب برف و در نتیجه تغییر در دسترسی به آب شرب و کشاورزی می‌شود (Endo et al., 2012). منابع آب زیرزمینی از طریق تعامل مستقیم با منابع آب سطحی مثل رودخانه‌ها و دریاچه‌ها و تعامل غیرمستقیم از طریق روند تغذیه، با پدیده تغییر اقلیم در ارتباط است (Abbasian et al., 2019 ; Roeckner et al., 2003). تغییر اقلیم با تغییر در شرایط تغذیه ناشی از بارندگی و رواناب به صورت غیرمستقیم بر تخلیه و ذخیره آب زیرزمینی اثر می‌گذارد؛ بنابراین شناسایی و تحلیل پارامترهای مؤثر از جمله پارامترهای اقلیمی می‌تواند کمک به سزایی به پیش‌بینی منابع آب زیرزمینی کند که بتوان از ایجاد مخاطره‌های جدی همچون فرونشست و خشک‌سالی جلوگیری کرد (Affandi and Watanabe., 2007). از سوی دیگر با توجه به اینکه ارتباط بین پارامترهای اقلیمی و منابع آب زیرزمینی به صورت پیچیده و غیرخطی است، استفاده از مدل‌های هوش مصنوعی از جمله مدل‌های هیبریدی نوین راهکار مناسبی برای حل این مشکلات است. در سال‌های اخیر استفاده از مدل‌های هیبریدی هوش مصنوعی از جمله شبکه عصبی مصنوعی با الگوریتم‌های فرا کاوشی در پژوهش‌هایی مورد بررسی قرار گرفته است که چندین مورد بررسی می‌شود.

در پژوهشی نخعی و صابری نصر (Nakhaei and Saberi, 2012a) جهت پیش‌بینی سطح آب زیرزمینی دشت قروه از مدل عددی و شبکه عصبی موجک استفاده کردند. نتایج مطالعه آنها نشان داد مدل شبکه عصبی

مصنوعی - موجک از عملکرد بهتری نسبت به مدل‌های عددی برخوردار است. در پژوهشی دیگر افضل و همکاران (Afzaal et al., 2020) جهت بررسی سطح آب زیرزمینی جزیره پرنس در کانادا از مدل‌های هوش مصنوعی استفاده کردند. در این پژوهش از مدل‌های یادگیری عمیق، شبکه‌های عصبی مصنوعی (یک پرسپترون چندلایه)، حافظه کوتاه مدت و شبکه عصبی کانولوشنال استفاده کردند. متغیرهایی از جمله سطح آبراهه، جریان آبراهه، بارش، رطوبت نسبی، میانگین دما، تبخیر و تعرق، درجه حرارت روز، دمای نقطه شبنم و تبخیر و تعرق برای دوره ۲۰۱۷-۲۰۱۱ به عنوان متغیرهای ورودی استفاده شد. یافته‌های آنها نشان داد شبکه عصبی مصنوعی نسبت به سایر مدل‌های مورد بررسی از دقت بهتری برخوردار است. در پژوهشی میرزانی و همکاران (Mirzania et al., 2023) به منظور ارزیابی سطح آب‌های زیرزمینی دشت شبستر از مدل شبکه عصبی مصنوعی- الگوریتم هاک هریس^۱ استفاده کردند. در این پژوهش از داده‌های سطح آب زیرزمینی به صورت ماهانه طی سال‌های ۲۰۰۱ تا ۲۰۱۹ به صورت ۷ سناریو ترکیبی بهره گرفتند. نتایج پژوهش مذکور نشان داد مدل در سناریو متشکل از کلیه داده‌های ورودی عملکرد بهتری از خود نشان داده است. همچنین مدل شبکه عصبی مصنوعی - الگوریتم هاک هریس از دقت مطلوبی برخوردار است. علاوه بر این، در پژوهشی دیگر بوبکران و همکاران (Bubakran et al., 2023) از مدل‌های شبکه‌های عصبی بازگشتی، شبکه‌های عصبی پیش‌خور و همچنین ماشین‌های بردار پشتیبان جهت پیش‌بینی سطح آب زیرزمینی آبخوان زیوه در استان آذربایجان غربی استفاده کردند. در این پژوهش از پارامترهای بارش، دما و سطح آب هفت چاه پی‌زومتر با مقیاس زمانی ماهانه طی سال‌های ۲۰۰۵ تا ۲۰۱۸ بهره گرفتند. نتایج نشان داد مدل منفرد شبکه عصبی مصنوعی نسبت به سایر مدل‌های مورد بررسی از دقت بیشتر و خطای کمتری برخوردار است. در پژوهشی میربلوکی و همکاران (Mirboluki et al., 2024) به منظور پیش‌بینی سطح آب زیرزمینی دشت مشهد از مدل‌های هیبریدی شبکه عصبی مصنوعی استفاده کردند. در این پژوهش از

^۱ Harris Hawks Optimizer

الگوریتم ترکیبی از بهینه‌سازی پیوسته و گسسته است و این امر سبب می‌گردد در به دام افتادن در نقاط بهینه محلی جلوگیری نماید (Yang et al., 2023).

این پژوهش به‌صورت خاص بر مدل‌سازی سطح آب زیرزمینی چاه‌های پی‌زومتر شهرستان کوه‌دشت واقع در استان لرستان تمرکز دارد. با توجه به اهمیت آبخوان دشت کوه‌دشت در تأمین آب بخش‌های مختلف کشاورزی، شرب و صنعت، ارائه روش‌های مناسب پیش‌بینی و برآورد تغییرات سطح آب زیرزمینی بسیار ضروری است. دشت کوه‌دشت یکی از قطب‌های مهم کشاورزی استان لرستان است، اما برداشت‌های بی‌رویه و حفر چاه‌های غیرمجاز سبب افت شدید منابع آب زیرزمینی در سال‌های اخیر شده‌اند، تا جایی که این دشت به‌عنوان تنها دشت ممنوعه استان لرستان شناخته می‌شود؛ بنابراین، پیش‌بینی تغییرات سطح آب زیرزمینی و اقدامات مدیریتی به‌منظور بهبود وضعیت کنونی بیش‌ازپیش حیاتی است. نوآوری اصلی این تحقیق، استفاده هم‌زمان از دو مدل هیبریدی W-ANN و-CSO برای اولین بار در منطقه کوه‌دشت است که علاوه بر افزایش دقت پیش‌بینی‌ها، امکان شناسایی روابط پیچیده بین پارامترهای اقلیمی و سطح آب زیرزمینی را فراهم می‌سازد. هدف نهایی این پژوهش، تحلیل و پیش‌بینی پارامترهای اقلیمی با استفاده از مدل‌های گردش عمومی جو و پیش‌بینی سطح آب زیرزمینی دشت کوه‌دشت با بهره‌گیری از مدل‌های تلفیقی موجک - شبکه عصبی مصنوعی و شبکه عصبی مصنوعی - ازدحام مرغ بر اساس داده‌های اقلیمی، سطح آب زیرزمینی و برداشت از آبخوان است.

مواد و روش

معرفی منطقه مورد مطالعه

دشت کوه‌دشت یکی از اصلی‌ترین آبخوان‌ها در استان لرستان است که در قسمت غربی استان و در ناحیه جغرافیایی ۲۶' ۳۳° تا ۳۶' ۳۳° شمالی و ۱۶' ۴۷° تا ۲۷' ۴۷° شرقی واقع شده است. این دشت دارای مساحتی معادل ۲۴۸ کیلومتر مربع بوده و یکی از نواحی مطالعه در حوضه آبخیز رودخانه کارون می‌باشد. اقلیم این منطقه نسبتاً گرم است و میانگین بارش سالانه ۴۵۰


داده‌های ۸۶ حلقه چاه پی‌زومتر دشت مشهد بهره گرفتند. همچنین جهت مدل‌سازی از روش یادگیری عمیق جدید، حافظه کوتاه‌مدت بلندمدت (LSTM)، با بهینه‌سازی گرگ خاکستری استفاده کردند. نتایج نشان داد مدل ترکیبی حافظه کوتاه‌مدت بلندمدت-گرگ خاکستری نسبت به مدل هیبریدی شبکه عصبی مصنوعی -گرگ خاکستری از دقت بیشتری برخوردار است. در پژوهشی فنگ و همکاران (Feng et al., 2024) جهت تخمین سطح آب زیرزمینی شهرستان ایزه واقع در کشور ایران از الگوریتم‌های مختلف یادگیری ماشین سنتی و عمیق، از جمله شبکه عصبی کانولوشن، شبکه عصبی تکراری، ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی و شبکه متخاصم مولد استفاده کردند. از پارامترهای نرخ برداشت آب زیرزمینی، میزان بارندگی و دبی رودخانه به‌عنوان ورودی برای فرآیند مدل‌سازی بهره گرفتند که نتایج نشان داد شبکه عصبی کانولوشن به‌عنوان ابزاری مفید در تخمین سطح آب زیرزمینی می‌باشد.

درمجموع با توجه به پژوهش‌های انجام‌شده کارایی مدل‌های هوش مصنوعی مورد تأیید قرار گرفته است به‌گونه‌ای که این مدل‌ها نسبت به مدل‌های آماری و فیزیکی از خطای کمتری برخوردار هستند (Dehghani et al., 2020). همچنین در سال‌های اخیر به‌دلیل افزایش دقت این مدل‌ها از فرایند بهینه نمودن پارامترهای تنظیم استفاده نمودند که سبب افزایش دقت و کاهش خطای مدل شده است (Rajaei et al., 2022). امروزه به‌منظور افزایش دقت، کاهش خطا و کارایی مدل شبکه عصبی مصنوعی، از ترکیب این مدل با الگوریتم‌های فرا ابتکاری بهینه‌ساز به‌عنوان یک راهکاری مناسب جهت پیش‌بینی سطح آب زیرزمینی استفاده‌شده است که نتایج مطلوبی ارائه داده است (Jalalkamali and JalalKamali., 2018).

در این پژوهش، به‌منظور دستیابی به دقت بالاتر و کاهش عدم قطعیت‌های مدل‌سازی، از دو رویکرد نوآورانه استفاده شده است: اولاً ترکیب مدل موجک - شبکه عصبی مصنوعی (W-ANN) برای بهبود پردازش سیگنال‌های غیرخطی و ناپایدار داده‌های سطح آب زیرزمینی، و ثانیاً ادغام شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی جدید ازدحام مرغ (CSO-ANN) به‌منظور تنظیم خودکار پارامترهای وزن‌ها و بایاس مدل شبکه عصبی است که این

به طور کلی ارتفاع متوسط برای کل ناحیه مورد مطالعه ۱۳۶۰ متر بالاتر از سطح دریا می باشد. موقعیت منطقه مورد مطالعه در شکل ۱ نشان داده شده است. در جدول ۱ موقعیت چاه های پیزومتری مورد بررسی نشان داده شده است.

میلی متر است. سطح آب های زیرزمینی در این دشت از نوع آزاد بوده و شکل بیضی دارد و در رسوبات آبرفتی در قسمت شمالی ناحیه مورد مطالعه قرار دارد. وسعت این آبخوان معادل ۱۸۲/۱ کیلومتر مربع است و ارتفاع متوسط دشت ها و کوه ها به ترتیب ۱۲۶۱ و ۱۳۹۶ متر است که



شکل ۱. منطقه مورد مطالعه

Fig 1. Study area

جدول ۱-موقعیت چاه های پیزومتری مورد بررسی

Table 1-Location of the piezometric wells studied.

شماره	نام پیزومتر	طول جغرافیایی	عرض جغرافیایی	ارتفاع
Number	Pizometer	Longitude	Latitude	Elevation
1	باغزال	47°38' 57"	33°33' 15"	1226
2	بوگلان	47°39' 52"	33°28' 38"	1188

۲-۲. مدل گردش عمومی جو

مدل‌های گردش عمومی GCM قادر هستند تا تغییرات پارامترهای اقلیمی را در سناریوهای مختلف مدل گردش عمومی شبیه‌سازی نماید. این مدل بر پایه قوانین فیزیک بنا شده و از روابط ریاضی برای پیش‌بینی متغیرهای اقلیمی در هر یک از سلول‌های شبکه بهره می‌گیرند. مدل‌های GCM به سه دسته مدل‌های گردش عمومی جو (AGCM)، گردش عمومی اقیانوسی (OGCM) و گردش عمومی جوی - اقیانوسی (AOGCM) تقسیم می‌شوند. در حال حاضر معتبرترین ابزار برای مطالعات تغییرات اقلیمی مدل (AOGCM) است که مهم‌ترین ورودی این مدل‌ها، میزان انتشار گازهای گلخانه‌ای که در قالب سناریو انتشار برای دوره‌های آتی ارائه شده است (Irwin et al., 2012).

مدل‌های اقلیمی عملکرد متفاوتی در پیش‌بینی متغیرهای هواشناسی در نقاط مختلف دارند. از این رو می‌بایست قبل از استفاده از خروجی این مدل‌ها، توانایی آنها مورد ارزیابی قرار داده شود. در همین راستا، در مطالعه حاضر برای انتخاب مدل‌های مناسب برای منطقه مورد مطالعه، ابتدا نتایج حاصل از پیش‌بینی بارش و دما توسط مدل‌های اقلیمی (مربوط به نزدیک‌ترین سلول محاسباتی به حوزه آبخیز کوه‌دشت) در دوره پایه (۲۰۲۲-۲۰۲۰) از سازمان هواشناسی استان لرستان اخذ شد. در این پژوهش برای ارزیابی عملکرد مدل‌های اقلیمی از شاخص‌های ریشه دوم میانگین مربعات خطا (RMSE)، ریشه دوم میانگین مربعات خطای نرمال شده (NRMSE)، ضریب تبیین (r) و میانگین خطای مطلق (MAE) استفاده شد که روابط آنها در زیر آمده است.

$$RMSE = \left[\frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \right]^{1/2} \quad (1)$$

$$NRMSE = \left[\frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \right]^{1/2} \times \frac{100}{\bar{O}} \quad (2)$$

$$R^2 = \frac{\sum_{i=1}^n (S_i - \bar{O})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |S_i - O_i|}{n} \quad (4)$$

جدیدترین سناریوهای ارائه شده برای بررسی پارامترهای اقلیمی، سناریوهای گزارش ششم (AR6) است. در این سناریوها چگونگی مدل گردش عمومی در دوره‌های آتی بر اساس ترکیب سناریوهای انتشار (RCPs) و سناریوهای اقتصادی - اجتماعی (SSPs) بررسی می‌شود. درواقع بر اساس این گزارش، سناریوهای آینده علاوه بر توصیف اقلیم‌های متفاوت، باید جنبه‌های پیشرفت اقتصادی و اجتماعی را نیز شامل شوند. در سناریوهای SSPs بر شبیه‌سازی چگونگی تغییر شرایط اقتصادی - اجتماعی مانند رشد جمعیت، رشد اقتصادی، آموزش، شهرنشینی، توسعه و تکنولوژی تأکید شده است (Jahangir et al., 2022).

همچنین در این پژوهش اطلاعات مربوط به متغیرهای بارش، دمای بیشینه، دمای کمینه و تعداد ساعات آفتابی مربوط به ایستگاه هواشناسی کوه‌دشت در طی سال‌های ۲۰۲۲-۲۰۲۰ به مدل LARSWG ارائه خواهد شد و پس از اطمینان از توانایی مدل در شناخت ویژگی‌های آماری ایستگاه مذکور، از این مدل جهت ریزمقیاس نمایی خروجی مدل‌های اقلیمی تحت سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5 استفاده خواهد شد. از آنجایی که

مدل‌های گزارش ششم در نرم‌افزار LARS WG تعریف نشده هستند بنابراین، نیاز است تا خروجی هر کدام از مدل‌ها با تعریف سناریو ریزمقیاس شود. به همین منظور داده‌های بارش، دمای بیشینه و دمای کمینه مربوط به خروجی هر مدل برای دوره آتی تحت هر سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5 استخراج شود. سپس برای پارامتر بارش، نسبت میانگین بلندمدت ماهانه دوره آتی به دوره پایه و برای پارامترهای دمای بیشینه و دمای کمینه، اختلاف میانگین بلندمدت ماهانه دوره آتی و دوره پایه محاسبه شود. بنابراین، برای هر

موجود در لایه ورودی و خروجی با توجه به ماهیت مسئله موردبررسی مشخص می‌شود. به‌طوری‌که تعداد نورون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطای مدل مشخص می‌گردد. روند کار با تعداد نورون‌های کم آغاز و افزودن نورون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نورون‌های بیشتر تأثیری در بهبود خطا نداشته باشد. در این پژوهش از تابع نمونه‌ای از ساختار شبکه سه‌لایه‌ای متشکل از یک‌لایه ورودی، یک‌لایه مخفی، و یک‌لایه خروجی در شکل ۷ نشان‌داده شده است. لازم به ذکر است در شبکه عصبی مصنوعی به‌دلیل ماهیت توابع فعال‌سازی باید دامنه پارامترهای مورد استفاده در محدوده توابع محرک باشند؛ بنابراین از فرمول زیر جهت نرمال‌سازی استفاده شد:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

۲-۴. تبدیل موجک

تبدیل موجک به‌عنوان روشی جایگزین برای تبدیل فوریه زمان کوتاه^۲ ارائه شده است و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوریه زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریه زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هر کدام 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 منبسط شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال قابل بررسی است (Wang et al., 2000).

پارامتر در همراه ضربی به‌دست خواهد آمد که از آن برای ایجاد سناریو در نرم‌افزار LARSWG و ریزمقیاس نمایی خروجی مدل‌های گزارش ششم استفاده شد.


۲-۳. شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani et al., 2011). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک‌لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۱ انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا^۲ با سناریو شبکه پیش‌خور و تعداد سه‌لایه به‌طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al., 2011). از رایج‌ترین توابع فعال‌سازی استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هایپربولیک ذکر کرد (Hornik., 1998). در این پژوهش از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نورون‌های متفاوت استفاده شد. تابع تانژانت هایپربولیک متداول‌ترین شکل از توابع محرک است که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا به نام الگوریتم لونبرگ - مارکوارت به‌دلیل همگرایی سریع‌تر در آموزش شبکه، انجام گرفت. همچنین از ترکیبات مختلف توابع محرک در لایه مخفی استفاده شد. تعداد تکرارهای لازم فرایند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به‌کمک معیار میانگین مربعات خطا مورد ارزیابی قرار می‌گیرد. تعداد نورون‌های

^۱ Multi-Layer Perceptron

^۲ Back Propagation (BP)

^۳ Short-term Fourier Transform



شکل ۲. نمای کلی یک شبکه عصبی مصنوعی سه لایه

Fig 2. Overview of a three-layer artificial neural network

تغییر مقیاس موجک مادر هستند. واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به‌دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است. در این پژوهش از توابع مختلف موجک شامل هار، کلاه مکزیکی، مورلت استفاده شد. تابع موجک مورلت به‌دلیل آنکه مشتق دوم تابع گوسین می‌باشد از عملکرد بهتری برخوردار بود، انتخاب شد. تبدیل موجک مورلت با ارائه تحلیل زمان-فرکانس دقیق، قابلیت تنظیم فرکانس مرکزی، شکل مناسب برای تحلیل سیگنال‌های ارتعاشی، و امکان استخراج اطلاعات فاز، یک ابزار قدرتمند برای تحلیل سیگنال‌ها در حوزه‌های مختلف است که حتی می‌تواند نویز را از سیگنال حذف نماید. روش‌های حذف نویز مبتنی بر موجک معمولاً عملکرد بهتری نسبت به روش‌های سنتی دارند، زیرا می‌توانند نویز را بدون از دست دادن جزئیات مهم سیگنال حذف کنند.

۵-۲. الگوریتم ازدحام مرغ

بهینه‌سازی ازدحام مرغ (CSO¹)، یک الگوریتم الهام‌گرفته زیستی است که برای بهینه‌سازی تک‌هدفه مورد استفاده

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 و مقیاس شده سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانوا و گذرا را به‌صورت موضعی مورد تجزیه و تحلیل قرار داد (Shin et al, 2005). تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته تابع $f(t)$ به‌صورت روابط (۶) و (۷) تعریف می‌شود:

$$CWT_f^\psi(s, \tau) = \Psi_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t-\tau}{s} \right) dt = (f(t), \Psi_{s,\tau}(t)) \quad (6)$$

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right) \quad (7)$$

رابطه (۷) یک رابطه با دو متغیر s و τ است که s پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال هستند. علامت * نیز نشان دهنده مزدوج مختلط است. ψ تابع پنجره یا موجک مادر و $\frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right)$ موجک‌های حاصل از انتقال و

¹ chicken swarm algorithm

$$X_{i,j}^{t+1} = X_{i,j}^t \cdot (1 + \text{Randn}(0, \sigma^2)) \quad (8)$$

$$\sigma^2 =$$

$$\begin{cases} 1. & \text{if } f_i \leq f_k \\ \exp\left(\frac{f_k - f_i}{|f_i| + \varepsilon}\right) & \text{otherwise } k \in [1, \text{RN}], k \neq i. \end{cases} \quad (9)$$

در اینجا، $\text{Randn}(0, \sigma^2)$ یک عدد تصادفی است که از توزیع گاوسی با میانگین صفر و واریانس σ^2 پیروی می‌کند. ε یک ثابت بسیار کوچک است، k تعداد خروس دیگری است که به صورت تصادفی انتخاب می‌شود، و f_i و f_k به ترتیب مقادیر برازندگی خروس i ام و خروس k ام هستند. موقعیت بازگشتی یک مرغ به شرح زیر تعریف می‌شود:

$$\begin{aligned} X_{i,j}^{t+1} = & X_{i,j}^t + C1 \cdot \text{Rand} \cdot (X_{r1,j}^t - X_{i,j}^t) \\ & + C2 \cdot \text{Rand} \cdot (X_{r2,j}^t - X_{i,j}^t) \end{aligned} \quad (10)$$

$$C1 = \exp\left(\frac{f_k - f_i}{|f_i| + \varepsilon}\right) \quad (11)$$

$$C2 = \exp(f_{r2} - f_i) \quad (12)$$

در اینجا، $C1$ و $C2$ فاکتورهای یادگیری هستند، یک عدد تصادفی است که از توزیع یکنواخت در بازه $[0, 1]$ پیروی می‌کند. $r1$ شاخص خروسی است که همسر مرغ i ام است، $r2$ تعداد یک خروس یا یک مرغ است که به صورت تصادفی انتخاب می‌شود و $r1 \neq r2$. موقعیت بازگشتی یک جوجه به شرح زیر تعریف می‌شود:

$$X_{i,j}^{t+1} = X_{i,j}^t + FL \cdot (X_{m,j}^t - X_{i,j}^t) \quad (13)$$

m, j نشان دهنده مرغ مادر جوجه‌ها است و FL یک فاکتور تصادفی در بازه $[0, 2]$ است. در شکل ۳ فلوچارت الگوریتم نشان داده شده است.

قرار می‌گیرد (Zouache et al., 2019). این الگوریتم توسط منگ و همکاران (Meng et al., 2014) ارائه گردیده است. بهینه‌سازی ازدحام مرغ از نظم سلسله‌مراتبی و رفتارهای یک دسته مرغ هنگام جستجوی غذا تقلید می‌کند، جایی که هر مرغ نشان‌دهنده یک راه‌حل بالقوه برای یک مسئله بهینه‌سازی است. در اصل، CSO از چهار قانون زیر برای ایده‌آل‌سازی رفتار مرغ‌ها استفاده می‌کند:


۱- دسته یا ازدحام مرغ گروه مرغ متشکل از چندین گروه است که هر گروه خروس غالب و برتر و یک جفت مرغ و جوجه دارد.

۲- در هر گروه از دسته مرغ، اعتبار و هویت مرغ (خروس، مرغ و جوجه) به ارزش و مقدار تناسب خود مرغ بستگی دارد. جوجه‌هایی که بهترین مقادیر تناسب را دارند، به عنوان خروس شناخته می‌شوند. هر کدام از آنها در یک گروه از خروس جلوتر خواهند بود. جوجه‌هایی که از نظر آمادگی جسمانی ضعیف‌تر هستند، به عنوان جوجه شناخته می‌شوند و بقیه به عنوان مرغ‌ها در نظر گرفته خواهند شد.

۳- بعد از هر چند مرحله (G)، ترتیب سلسله‌مراتبی، رابطه سلطه و رابطه مادر و کودک باید کاملاً تغییر کند.

۴- جوجه‌ها در جستجوی غذا جفت خروس خود را دنبال می‌کنند. فرض می‌شود که مرغ‌ها به طور تصادفی غذای خوبی را که دیگران پیدا کرده‌اند، می‌دزدند. جوجه‌ها در اطراف مادران خود به دنبال غذا می‌گردند. خروس در رقابت برای غذا از مزیت برخوردار است.

در این الگوریتم، هر جوجه با موقعیت خود توصیف می‌شود. فرض کنید RN ، HN ، CN و MN به ترتیب نمایانگر تعداد خروس‌ها، مرغ‌ها، جوجه‌ها و مرغ‌های مادر باشند، و معادله ریاضی، موقعیت i -امین جوجه در فضای بُعد j -ام در تکرار t -ام است که در آن $i \in \{1, \dots, N\}$ ، $j \in \{1, \dots, D\}$ و $t \in \{1, \dots, T\}$. همچنین N ، D و T به ترتیب نمایانگر تعداد کل جوجه‌ها، تعداد ابعاد و حداکثر دفعات تکرار هستند. یک خروس، یک مرغ و یک جوجه دارای فرمول‌های به روزرسانی موقعیت خاص خود هستند. برای یک خروس، موقعیت بازگشتی آن به شرح زیر تعریف می‌شود:



شکل ۳. فلوچارت الگوریتم ازدحام مرغ

Fig 3. Flowchart of the chicken swarm algorithm

۲-۶. معیار ارزیابی

در این پژوهش جهت ارزیابی مدل‌های موردبررسی به‌منظور مدل‌سازی سطح آب زیرزمینی از شاخص‌های ارزیابی زیر استفاده شد.

$$NSE = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad \infty \leq NSE \leq 1 \quad (17)$$

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

۳. نتایج و بحث

در این پژوهش به‌منظور مدل‌سازی سطح آب زیرزمینی شهرستان کوهدشت، واقع در استان لرستان، از مدل شبکه عصبی مصنوعی با الگوریتم‌های موجک و ازدحام مرغ

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (15)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad (16)$$

آموزش ماهیت سازوکار حاکم بر پدیده باعث بهبود عملکرد خواهد شد؛ بنابراین، در سناریوسازی سطح آب زیرزمینی نیز سعی گردید تا مؤثرترین داده‌های مشاهداتی به‌عنوان داده‌های آموزشی انتخاب شود (Dehghani et al., 2022). بدین‌منظور ترکیب‌های مختلفی از پارامتر ورودی به‌منظور دستیابی به مدل بهینه جهت مدل‌سازی سطح آب زیرزمینی استفاده شد که در جدول ۲ آمده است.

جدول ۲. ترکیب‌های منتخب پارامتر ورودی مدل‌های هیبریدی مورد بررسی

Table 2. Selected combinations of input parameters of the hybrid models under study

شماره	ساختار ورودی	خروجی
Number	Input	Output
1	T(t)	H(t)
2	T(t), P (t)	H(t)
3	T(t), P (t), q (t)	H(t)
4	T(t), P (t), q (t), H (t-1)	H(t)

مقابل، مدل GFDL-ESM4 با بیشترین خطا $MAE=0.7^{\circ}C$ برای دما و $MAE=70mm$ برای بارش) و برآورد ضعیف قابل توجه در شبیه‌سازی بارش ($380mm$ در مقابل $450mm$ مشاهداتی) ضعیف‌ترین عملکرد را دارد. مدل‌های MIROC6 و EC-Earth3 اگرچه در شبیه‌سازی دما نسبتاً موفق عمل کرده‌اند (به‌ترتیب با $MAE=0.5^{\circ}C$ و $0.4^{\circ}C$)، اما در شبیه‌سازی بارش با خطای قابل توجهی مواجه هستند (به‌ترتیب $MAE=40mm$ و $30mm$). این نتایج تأیید می‌کند که CANESM5 به‌دلیل پارامترسازی دقیق‌تر فرآیندهای فیزیکی مرتبط با اقلیم نیمه‌خشک، گزینه مناسب‌تری برای مطالعات تغییر اقلیم در منطقه مورد مطالعه محسوب می‌شود. همچنین جهت ریز مقیاس نمایی نیز از مدل Lars WG 8 استفاده شد.

نتایج حاصل از ارزیابی داده‌های تولید شده با استفاده از مدل LARS-WG و داده‌های مشاهده شده دو حلقه چاه پیژومتری باغزال و بوگلان در دوره پایه در جدول ۴ آورده شده است. نتایج نشان می‌دهد مقدار ضریب تبیین در کلیه مدل‌های مورد بررسی بیشتر از 0.96 محاسبه گردید و میانگین خطای مطلق (MAE) برای شبیه‌سازی بارش، دمای حداقل، دمای حداکثر به‌ترتیب $25/1$ میلی‌متر و $0.3^{\circ}C$ ، $0.4^{\circ}C$ درجه سانتیگراد به‌دست آمد که نشان می‌دهد خطای شبیه‌سازی بارش بیشتر از بقیه پارامترهاست. شاخص‌های RMSE و NRMSE نیز در

استفاده شد. پارامترهای بارش (P)، دما (T)، سطح آب زیرزمینی (H) و برداشت از منابع آب (q) به‌صورت ماهانه در سال‌های ۱۳۹۲ تا ۱۴۰۲، به‌عنوان ورودی و سطح آب زیرزمینی (H) به‌عنوان پارامتر خروجی مدل در چاه‌های پیژومتری باغزال و بوگلان به کار برده شد. 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

همچنین در این پژوهش از مدل گردش عمومی جو CMIP6 جهت پیش‌بینی پارامترهای هواشناسی نظیر بارش و دما طی سال‌های ۲۰۲۲ تا ۲۰۴۲ استفاده شد. به‌منظور پیش‌بینی پارامترهای هواشناسی در مدل گردش عمومی جو از سه سناریو اقلیمی SSP245، SSP126 و SSP585 استفاده شد. همانطور که مشاهده می‌گردد سناریو SSP 126 به‌صورت خوش‌بینانه، SSP245 نرمال و SSP585 به‌صورت بدبینانه در نظر نظر گرفته شد. همچنین از مدل اقلیمی Can esm 5 که در در شبیه‌سازی تغییرپذیری بارش‌های فصلی و روند دمایی بلندمدت در مناطق نیمه‌خشک (مانند کوهدشت) عملکرد مطلوبی نشان داده است و بیشترین سازگاری با منطقه دارد، در نظر گرفته شد (Jeong et al., 2019). در جدول ۳ نتایج مدل‌های مورد بررسی در دوره پایه ۲۰۰۲ تا ۲۰۲۲ شهرستان کوهدشت نشان داده شده است. نتایج مقایسه مدل‌های CMIP6 با داده‌های مشاهداتی منطقه کوهدشت نشان می‌دهد که مدل CANESM5 با دارا بودن کمترین خطای مطلق ($MAE=0.2^{\circ}C$ برای دما و $MAE=15mm$ برای بارش) و نزدیک‌ترین مقادیر به داده‌های واقعی (دمای $16/3^{\circ}C$ در مقابل مشاهدات $16^{\circ}C$ و بارش $435mm$ در مقابل $450mm$)، از دقت بالاتری نسبت به سایر مدل‌ها برخوردار است. این مدل به‌ویژه در شبیه‌سازی پارامترهای اقلیمی منطقه نیمه‌خشک کوهدشت عملکرد مطلوبی از خود نشان داده است. در

بلند مدت بیست ساله سناریوهای مورد بررسی نشان داد کلیه سناریوها اختلاف ناچیزی با یکدیگر دارند اما مدل SSP126 از دمای میانگین بلند مدت سالانه کمتری نسبت به سایر سناریوهای برخوردار است.

از سوی دیگر میزان بارش از ماه ژانویه تا سپتامبر روند نزولی داشته است. همچنین طبق میانگین بلندمدت سالانه مشاهده می‌گردد میانگین بلندمدت سالانه بارش سناریوهای مورد بررسی تقریباً مشابه یکدیگر هستند؛ اما سناریو SSP126 از میزان بیشتری برخوردار است.

شبیه‌سازی بارش نسبت به دیگر پارامترها به‌مراتب بیشتر بوده (به‌ترتیب ۵/۱۸ و ۱۲/۳۶) و خطای بیشتری را نشان می‌دهد؛ بنابراین توانایی مدل LARS-WG در شبیه‌سازی پارامترهای هواشناسی تأیید شده ولی باین‌حال مدل در شبیه‌سازی بارش دقت کمتری را نشان می‌دهد.

در جدول ۵ نتایج گزارش ششم برای پارامترهای بارش و دما نشان داده شده است. همانطور که مشاهده می‌گردد در ماههای ژانویه تا سپتامبر دما افزایش یافته است که در همه سناریوها این امر مشهود می‌باشد. همچنین میانگین

جدول ۳. مقایسه عملکرد مدل‌های گردش عمومی جو محدوده مطالعاتی کوه‌دشت در دوره پایه (۲۰۰۲-۲۰۲۲)

Table 3. Comparison of the performance of atmospheric general circulation models in the Kuhdasht study area in the base period (2002-2022)

خطای بارش MAE	بارش میانگین Average precipitation	خطای دما MAE	دمای میانگین Average temperature	مدل Model
	450		16	Observation
15	435	0.2	16.3	CANESM5
40	410	0.5	15.7	MIROC6
30	420	0.4	16.5	EC-Earth3
70	380	0.7	15.2	GFDL-ESM4

جدول ۴. شاخص آماری ارزیابی مدل LARS-WG 8

Table 4. Statistical index of LARS-WG 8 model evaluation

MAE	NRMSE	RMSE	R ²	پارامتر Parameters
0.25	12.36(mm)	5.18(mm)	0.960	بارش Precipitation
0.03	2.41(°C)	0.25(°C)	0.980	مینیمم دما Minimum temperature
0.04	0.97(°C)	0.30(°C)	0.980	ماکزیمم دما Maximum temperature

جدول ۵. عملکرد سناریوهای گزارش ششم در پیش بینی دما و بارش

Table 5. Performance of the Sixth Report Scenarios in Forecasting Temperature and Precipitation

		دمای ماکزیمم T max (°C)		
Month	Base Time (2002-2022)	SSP126(2022-2042)	SSP245(2022-2042)	SSP585(2022-2042)
Jan	15.99	16.98	17.08	17.65
Feb	18.06	19.13	19.16	19.81
Mar	21.76	23.07	22.95	23.98
Apr	23.41	24.19	23.90	25.30
May	27.09	27.35	27.50	28.72

Jun	32.20	33.47	33.99	34.64
Jul	35.96	38.26	38.67	38.80
Aug	35.50	38.14	38.54	38.51
Sep	31.78	34.55	35.19	35.12
Oct	26.03	28.40	29.18	29.24
Nov	20.19	22.81	23.53	23.94
Dec	16.58	18.34	18.75	19.43
Average	25.38	27.06	27.37	27.93

بارش

Prc (mm)

Month	Base Time (2002-2022)	SSP126(2022-2042)	SSP245(2022-2042)	SSP585(2022-2042)
Jan	63.47	60.19	59.86	46.95
Feb	49.04	37.54	45.40	29.37
Mar	35.60	16.64	25.26	16.00
Apr	52.84	39.41	49.18	42.32
May	31.76	32.53	34.33	30.10
Jun	9.60	8.12	8.39	7.49
Jul	2.35	0.35	0.23	0.34
Aug	5.21	3.65	2.18	3.34
Sep	27.95	17.36	11.25	17.39
Oct	67.61	43.50	34.84	44.13
Nov	91.87	60.47	56.09	49.86
Dec	96.41	94.95	91.49	72.82
Average	44.48	34.56	34.88	30.01

مصنوعی با الگوریتم‌های موجک و ازدحام مرغ بهینه سازی شده و بهینه‌ترین مقدار برآورد شد سپس تحلیل حساسیت پارامترهای ورودی طبق جدول ۶ صورت گرفت و سپس با توجه به شاخص ارزیابی ریشه میانگین مربعات خطا، ساختار ترکیبی شماره ۴ که دارای کمترین میزان خطا بود، برگزیده شد. در جدول ۶ نتایج حاصل از مدل‌های مختلف تحت ساختارهای مختلف نشان داده شده است همانطور که مشاهده می‌گردد ساختار ترکیبی شماره ۴ در چاه‌های پیژومتری مورد بررسی از عملکرد مناسب تری برخوردار است همچنین نتایج حاصل از تحلیل حساسیت پارامترهای ورودی طبق جدول ۲ و جدول ۶ نشان می‌دهد پارامترهای بارش و میزان برداشت از آبخوان نسبت به پارامتر دما تأثیر بیشتری دارند. در مجموع نتایج حاصل از بررسی عملکرد مدل‌ها در جدول ۵ نشان داده شده است در این جدول مدل شبکه عصبی مصنوعی-موجک عملکرد بهتری نسبت به مدل شبکه

در این پژوهش فرض شد میزان برداشت از آبخوان‌ها مطابق ۲۰ سال گذشته بوده و افزایشی رخ نخواهد داد. بنابراین با فرض مذکور شبیه‌سازی صورت گرفت. بدین‌منظور ابتدا عملکرد مدل‌های فرا کاوشی در طی سال‌های ۲۰۲۲-۲۰۰۲ مورد بررسی قرار گرفت سپس با توجه به عملکرد مدل‌های مورد بررسی ساختار ترکیبی بهینه انتخاب و فرآیند پیش‌بینی صورت پذیرفت. به‌منظور برآورد نوسانات سطح آب زیرزمینی دشت کوهدشت استان لرستان واقع در کشور ایران مدل‌ها و الگوریتم‌های نوین با یک مجموعه داده مشاهداتی ارزیابی شد و کارایی مدل‌ها بررسی گردید. به‌منظور مدل‌سازی مدل‌های هیبریدی و منفرد شامل شبکه عصبی مصنوعی-موجک و شبکه عصبی مصنوعی -ازدحام مرغدر نرم‌افزار متلب (MATLAB 2018 Rb) فرآیند کدنویسی صورت گرفت. به‌منظور مدل‌سازی سطح آب زیرزمینی دشت کوهدشت ابتدا میزان وزن‌ها و بایاس مدل شبکه عصبی


است. همچنین مدل CSO-ANN نیز از دقت مطلوبی برخوردار است و مقادیر محاسباتی را به خوبی برآورد نموده است. این دو نتیجه نشان می‌دهد که، اگر چه ANN از جمله مدل‌های هوشمند و دقیق است، اما نمی‌تواند مقادیر بیشینه را به خوبی پیش‌بینی کند. اما وقتی با الگوریتم‌ها یا مدل‌های فرا کاوشی از جمله تبدیل موجک WT ترکیب شود، عملکرد آن در پیش‌بینی مقادیر بیشینه بسیار بهبود می‌یابد که با نتایج پژوهش بهمنی و همکاران (Bahmani et al., 2021) زیدعلی نژاد و دهقانی (Zeidalinejad and Dehghani., 2023) مطابقت دارد.

عصبی مصنوعی -ازدحام مرغ دارد به گونه‌ای که در چاه پیزومتری باغزال دارای مقادیر $R=0.970$, $RMSE=0.231$ m, $MAE=0.121$ m و $NS=0.980$ و در چاه پیزومتری بوگلان دارای مقادیر $R=0.982$, $RMSE=0.124$ m, $MAE=0.068$ m و $NS=0.990$ می‌باشد. در شکل ۴ نمودار سری زمانی مدل‌های مورد بررسی در چاه‌های پیزومتری باغزال و بوگلان نشان داده شده است. همانطور که مشاهده می‌گردد مدل WANN نسبت به سایر مدل‌های مورد بررسی در تخمین کلیه نقاط از عملکرد قابل قبولی برخوردار است به گونه‌ای که مقادیر محاسباتی را نزدیک به مقادیر مشاهداتی تخمین زده

جدول ۶. عملکرد مدل‌های مورد بررسی در برآورد سطح آب زیرزمینی

Table 6. Performance of the studied models in estimating groundwater levels

باغزال									
Baghzal									
آزمون				آموزش				ساختار	مدل
Testion				Training					
NSE	MAE (m)	RMSE (m)	R	NSE	MAE (m)	RMSE (m)	R	Structure	Model
0.935	0.322	0.628	0.928	0.925	0.432	0.856	0.918	1	WANN شبکه عصبی مصنوعی-موجک
0.950	0.224	0.455	0.943	0.935	0.324	0.642	0.930	2	
0.964	0.184	0.342	0.958	0.950	0.258	0.531	0.940	3	
0.980	0.121	0.231	0.970	0.960	0.235	0.422	0.945	4	
0.930	0.447	0.876	0.923	0.910	0.536	1.08	0.904	1	CSO-ANN شبکه عصبی مصنوعی-ازدحام مرغ
0.942	0.356	0.672	0.934	0.925	0.436	0.866	0.917	2	
0.950	0.258	0.546	0.941	0.940	0.373	0.753	0.928	3	
0.960	0.214	0.435	0.950	0.955	0.352	0.694	0.940	4	
بوگلان									
Bogelan									
آزمون				آموزش				ساختار	مدل
Testion				Training					
NSE	MAE (m)	RMSE (m)	R	NSE	MAE (m)	RMSE (m)	R	Structure	Model
0.950	0.264	0.572	0.942	0.947	0.322	0.628	0.938	1	WANN شبکه عصبی مصنوعی-موجک
0.970	0.153	0.363	0.964	0.960	0.234	0.452	0.952	2	
0.980	0.122	0.246	0.972	0.965	0.176	0.341	0.960	3	
0.990	0.068	0.124	0.982	0.974	0.118	0.237	0.965	4	
0.940	0.325	0.652	0.933	0.930	0.432	0.855	0.916	1	CSO-ANN شبکه عصبی مصنوعی-ازدحام مرغ
0.960	0.178	0.348	0.952	0.950	0.324	0.644	0.934	2	
0.970	0.147	0.282	0.964	0.960	0.293	0.573	0.940	3	
0.980	0.088	0.178	0.971	0.968	0.240	0.484	0.950	4	




شکل ۴. نمودار سری زمانی مدل‌های مورد بررسی

Figure 4. Time series chart of the models under study

نرم‌تر می‌شود، بر همین اساس مدل WANN نسبت به سایر مدل‌ها ارجح‌تر است. بنابراین مدل WANN انتخاب گردید و پیش‌بینی سطح آب زیرزمینی با توجه به پارامترهای اقلیمی شبیه‌سازی شده توسط مدل‌های تغییر اقلیم انجام گردید که نتایج در شکل ۵ قابل مشاهده است. همانطور که مشخص است با فرض ثابت بودن برداشت از آبخوان‌ها که عامل مؤثر بر نوسانات سطح آب زیرزمینی می‌باشد میزان افت در چاه‌های پی‌زومتر دشت کوهدشت با وجود ممنوعه بودن دشت به لحاظ حفر چاه، کاهش یافته و روند نزولی دارد به‌طوری‌که افت سطح آب زیرزمینی در چاه پی‌زومتر باغزال در طی سال‌های ۲۰۳۸-۲۰۳۴ مشهود می‌باشد. همچنین چاه پی‌زومتر بوگلان بیشترین افت

همانطور که در جدول ۵ قابل مشاهده است مدل WANN عملکرد بهتری نسبت به سایر مدل‌های مورد بررسی از خود نشان داده است. دلیل افزایش دقت و کاهش خطای مدل WANN را می‌توان ناشی از برآورد بهینه تبدیل موجک دانست زیرا تبدیل موجک WT با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد، بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال

سطح آب زیرزمینی را در طی سال‌های ۲۰۲۶-۲۰۲۹، در نهایت با توجه به نتایج ذکر شده افت سطح آب زیرزمینی دشت کوهدشت در طی سال‌های ۲۰۲۲-۲۰۴۲ و ۲۰۳۲-۲۰۳۹ دارد. حدود ۴/۵-۳ متر می‌باشد.



شکل ۵. نمودار مقادیر پیش بینی شده سطح آب زیرزمینی چاه‌های پیزومتری طی سال‌های ۲۰۲۲-۲۰۴۲

Figure 5. Graph of predicted groundwater level values of piezometric wells during the years 2022-2042

۴. نتیجه‌گیری

به‌طور کلی می‌توان ادعان کرد، صنعتی‌شدن جوامع سبب افزایش گازهای گلخانه‌ای و گرم‌شدن کره زمین می‌شود که این امر تأثیر به‌سزایی بر منابع آب زیرزمینی دارد. در این پژوهش با استفاده از مدل‌سازی تغییر اقلیم پارامترهای هواشناسی (دما و بارش) برای سال‌های ۲۰۲۲-۲۰۴۲ پیش‌بینی شد و سپس با بهره‌گیری از مدل‌های هیبریدی فرا کاوشی نظیر WANN، AIG-ANN،

افت سطح آب زیرزمینی دشت کوهدشت با استفاده از پارامترهای بارش، دما و برداشت از آبخوان‌های دو چاه پیزومتری (باغزال و بوگلان) پیش‌بینی شد. ارزیابی مدل LARS-WG با استفاده از اطلاعات دوره پایه (۲۰۲۲-۲۰۰۲) نشان داد مدل گردش عمومی جو CIMP6 عملکرد مطلوبی در پیش‌بینی پارامترهای هواشناسی دارد به‌طوری‌که تحت سناریوهای مورد بررسی اختلاف ناچیزی دارند. دمای شبیه‌سازی شده در کلیه مدل‌های اقلیمی

842-461.

<https://doi.org/10.1016/j.jhydrol.2020.125659>

Bubakran, K.S., Novinpour, E.A. & Aghdam, F.S. (2023). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in the Ziveh Aquifer–West Azerbaijan, NW Iran. *Arabian Journal of Geosciences*, 16, 287-299.

<https://doi.org/10.1007/s12517-023-11180-z>

Chang, F., Chang, Y. (2006). Adaptive neuro-fuzzy inference system for the prediction of water level in a reservoir. *Advances in Water Resources*, 1(10), 1–10. <https://doi.org/10.1016/j.advwatres.2005.04.015>

Dehghani, R., Totabi Poudeh, H., Izadi, Z. (2022). The effect of climate change on groundwater level and its prediction using a modern meta-heuristic model. *Groundwater for Sustainable Development*, 16(3), 822-845.

<https://doi.org/10.1016/j.gsd.2021.100702>

Dehghani, R., Torabi Poudeh, H., Younesi, H., Shahinejad, B. (2020). Forecasting Daily River Flow Using an Artificial Neural Network–Support Vector Machine Hybrid Modeling Approach (Case Study: Karkheh Catchment, Iran). *Air, Soil, and Water*, 14, 22-35. <https://doi.org/10.1177/1178622120969659>

Endo, H., Kitoh, A., Ose, T., Mizuta, R., and Kusunoki, S. (2012). Future changes and uncertainties in Asian precipitation simulated by multiphysics and multi-sea surface temperature ensemble experiments with high-resolution Meteorological Research Institute atmospheric general circulation models (MRI-AGCMs). *Journal of Geophysical Research*, 117, 244-256.

<https://doi.org/10.1029/2012JD017874>

Feng, F., Ghorbani, H., Radwan, A. (2024). Predicting groundwater level using traditional and deep machine learning algorithms. *Frontiers in Environmental Science*. 12(4), 525-537.

<https://doi.org/10.3389/fenvs.2024.1291327>

Hornik, K. (1998). Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2(5), 359–366.

[https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)

Irwin, S.E., Rubaiya, S., Leanna, M., King, S., Simonovic, P. (2012). Assessment of climatic vulnerability in the Upper Thames River basin: Downscaling with LARS-WG. *Water Resources Research Report*, 12(2), 258-272.

<https://doi.org/10.4296/cwrj2011-938>

Jahangir, M.H., Haghighi, P., Daneshkar, S.H. (2022). Downscaling climate parameters in Fars province using models of the fifth report and RCP scenarios. *Ecological Informatics*, 68(4), 558-562.

<https://doi.org/10.1016/j.ecoinf.2022.101558>

(SSp126, SSP245 و SSP585) مورد بررسی در دوره آبی (۲۰۲۲-۲۰۴۲) نسبت به دوره پایه در تمام ماه‌ها افزایش داشته در حالی که میانگین بارش روند مشخصی از خود نشان نداده است. نتایج حاصل از عملکرد مدل‌های هیبریدی WANN و CSO-ANN با توجه به دوره آماری ۲۰۰۲-۲۰۲۲ نشان داد مدل‌های مورد بررسی در ساختار ترکیبی شامل کلیه پارامترهای ورودی از عملکرد بهتری به دلیل افزایش حافظه برخوردار هستند و مدل WANN دقت بیشتر و خطای کمتری نسبت به سایر مدل‌های مورد بررسی دارد. نتایج حاصل از پیش‌بینی سطح آب زیرزمینی در سال‌های آبی نشان داد روند نزولی در تمامی چاه‌های پیژومتری مورد بررسی وجود دارد به گونه‌ای که این افت در حدود ۴/۵-۳ متر با فرض ثابت بودن برداشت از آبخوان‌ها می‌باشد. بنابراین با توجه به افت سطح آب زیرزمینی طی ۲۰ سال آینده پیشنهاد می‌گردد نصب کنتور هوشمند بر روی تمامی چاه‌های کشاورزی و صنعتی صورت گیرد و همچنین از حفر چاه‌های غیرمجاز جلوگیری به عمل آید همچنین با اطلاع رسانی به مالکان چاه‌های کشاورزی از کشت محصولات آب دوست جلوگیری شود. این راهکار به نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های زیرزمینی مفید می‌باشد و گامی در جهت اتخاذ تصمیمات مدیریتی به منظور بهبود کمیت منابع آب‌های زیرزمینی است.

منابع

Abbasian, M., Moghim, S., & Abrishamchi, A. (2019). Performance of the general circulation models in simulating temperature and precipitation over Iran. *Theoretical and Applied Climatology*, 135, 1465–1483. <https://doi.org/10.1007 / s00704-018-2456-y>

Affandi, A., Watanabe, K. (2007). Daily groundwater level fluctuation using a soft computing technique. *Journal Nature and Science*, 5(2), 1–10. <https://doi.org/10.1007 / s00521-019-04234-5>

Afzaal, H., Farooque, A.A., Abbas, F., Acharya, B., Esau, T. (2019). Groundwater estimation from major physical hydrology components using artificial neural networks and deep learning. *Water* 12(1), 5–23. <https://doi.org/10.3390/w12010005>

Bahmani, R., Taha, B.M., Ouarda, J. (2021). Groundwater level modeling with hybrid artificial intelligence techniques. *Journal of Hydrology*, 595,

- 22(2), 466–472. <https://doi.org/10.1016/j.engappai.2008.09.003>
- Rajaei, T., Khani, S., Ravansalar, M. (2022). Artificial intelligence-based single and hybrid models for prediction of water quality in rivers: A review. *Chemometrics and Intelligent Laboratory Systems*, 200(3), 1039-1055. <https://doi.org/10.1016/j.chemolab.2020.103978>
- Roeckner, E., Bäuml, G., Bonaventura, L., Brokopf, R., Esch, M., Giorgetta, M., Hagemann, S., Kirchner, I., Kornbluh, L., Manzini, E., Rhodin, A., Schlese, U., Schulzweida, U., Tompkins, A. (2003). The atmospheric general circulation model ECHAM5, part I: Model description. *Max-Planck-Institut für Meteorologie*, 349, 2-140. <https://hdl.handle.net/11858/00-001M-0000-0012-0144-5>
- Shin, S., Kyung, D., Lee, S., Taik, & Kim, J., and Hyun, J. (2005). An application of support vector machines in a bankruptcy prediction model. *Expert Systems with Applications*, 28(4), 127-135. <https://doi.org/10.1016/j.eswa.2004.08.009>
- Vapnik, V.N. (1995). The Nature of Statistical Learning Theory. *Springer, New York*. 8(2), 155-202. <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>
- Yang, Q., Song, G.W., Gao, X.D., Lu, Z.Y., Jeon, S.W., Zhang, J. (2023). A random elite ensemble learning swarm optimizer for high-dimensional optimization. *Complex & Intelligent Systems*, 9(5), 5467–5500. <https://doi.org/10.1007/s40747-023-00993-w>
- Zeidalinejad, N., Dehghani, R. (2023). Use of meta-heuristic approach in the estimation of the 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>
- Zouache, D., Arby, Y. O., Nouioua, F., & Abdelaziz, F. B. (2019). Multi-objective chicken swarm optimization: A novel algorithm for solving multi-objective optimization problems. *Computers & Industrial Engineering*, 129, 377-391. <https://doi.org/10.1016/j.cie.2019.01.055>
- Jalalkamali, A., JalalKamali, N. (2018). Adaptive Network-based Fuzzy Inference System-Genetic Algorithm Models for Prediction of Groundwater Quality Indices: a GIS-based Analysis. *Journal of Artificial Intelligence & Data Mining*, 6(2), 439-445. <https://doi.org/10.22044/jadm.2017.1086>
- Jeong, D.I., Yu, B. & Cannon, A.J. (2023). Climate change impacts on linkages between atmospheric blocking and North American winter cold spells in CanESM2 and CanESM5. *Clim Dyn*, 60, 477–491. <https://doi.org/10.1007/s00382-022-06307-z>
- Li, T., Zhang, L., & Murakami, H. (2015). Strengthening of the Walker circulation under global warming in an aqua-planet general circulation model simulation. *Advances in Atmospheric Sciences*, 32, 1473–1480. <https://doi.org/10.1007/s00376-015-5033-7>
- Meng, X., Liu, Y., Gao, X., & Zhang, H. (2014). A new bio-inspired algorithm: chicken swarm optimization. *In International Conference on Swarm Intelligence*, 8, 86-94. https://doi.org/10.1007/978-3-319-11857-4_10
- Mirboluki, A., Mehraein, M., Kisi, O., Kuriqi, A., Barati, R. (2024). Groundwater level estimation using improved deep learning and soft computing methods. *Earth Science Informatics*, 17, 2587–2608. <https://doi.org/10.1007/s12145-024-01300-y>
- Mirzania, E., Ghorbani, M.A., Asadi, E. (2023). Enhancement of groundwater level prediction using a hybrid ANN-HHO model: a case study (Shabestar Plain in Iran). *Arabian Journal of Geosciences*. 16(2), 464-482. <https://doi.org/10.1007/s12517-023-11584-x>
- Nakhaei, M., Saberi Nasr, A. (2012a). Predicting groundwater level fluctuations in the Qorveh Plain using a wavelet neural network and comparing it with the MODFLOW numerical model. *Advanced Applied Geology*, 2(2), 47-58. 10.22059/JGEOPE.2012.29233
- Nourani, V., Kisi, Ö., Komasi, M. (2011). Two hybrid artificial intelligence approaches for modeling rainfall–runoff process, *Journal of Hydrology*, 402(2), 41–59. <https://doi.org/10.1016/j.jhydrol.2011.03.002>
- Nourani, V., Alami, M. T., Aminfar, M.H. (2009). A combined neural-wavelet model for the prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*,