

Modeling and Identification of Key Factors Affecting Groundwater Level in the Ravansar-Sanjabi Plain Using CMIP6 Climate Data

Abstract

This study aimed to predict future changes in depth of groundwater level (GWL) in the Ravansar-Sanjabi plain using a hybrid approach combining K-means and the Random Forest (RF) algorithm, based on CMIP6 climate data (precipitation, minimum and maximum temperature, relative humidity, and soil moisture). A total of 98 climate models were evaluated, and the most influential input variables were selected using Recursive Feature Elimination (RFE). The NorESM2-MM model was identified as the most effective climate model for the region, while soil moisture emerged as the most critical predictor. The RF model demonstrated robust performance, with the Kouzaran cluster achieving the highest accuracy ($R = 0.92$; $NSE = 0.83$).

Historical trend analysis (1992–2014) revealed a statistically significant decline in GWL across all clusters, with the most pronounced decreases observed in Kouzaran and TamTam, at rates of 77 and 68 cm/year, respectively. Under the SSP1-2.6 and SSP2-4.5 scenarios, a relative improvement in the near-future is projected, followed by significant GWL declines in the mid- and far-future periods. The steepest reductions is predicted in Kouzaran, with rates of 19 and 22 cm/year. Under the SSP5-8.5, a significant increasing trend is observed in the near- and mid-future, particularly in mid-future Kouzaran (24 cm/year), while a gradual decline is anticipated in far future. Seasonally, the greatest recovery is projected for fall (~4 m in Kouzaran under SSP5-8.5, far-future), and the most severe decline in spring (1.83 m in TamTam under SSP2-4.5, mid-future). These findings underscore the need for climate-adaptive groundwater management strategies in the region.

Keywords: CMIP6, GWL prediction, K-means clustering, Key variables, Random Forest algorithm

Extended abstract

Introduction:

The depletion of groundwater resources, particularly in the arid and semi-arid regions of Iran, has emerged as a major environmental and socio-economic crisis. In recent decades, excessive groundwater extraction, population growth, agricultural expansion, and climate change have placed immense pressure on aquifers. This situation underscores the urgent need for innovative approaches to forecasting and sustainable groundwater management. Among these, machine learning techniques have proven effective due to their capacity to analyze large datasets, detect complex patterns, and generate accurate predictions. The Random Forest (RF) algorithm, in particular, is favored for its robustness against overfitting and its ability to model nonlinear relationships. This study integrates RF with K-means clustering, employing climate data from CMIP6 models to analyze trends and forecast future groundwater level (GWL) changes in the Ravansar-Sanjabi plain.

Materials and Methods:

The study area (Ravansar-Sanjabi plain), located in western Iran (Kermanshah Province), covers approximately 457 km², situated between latitudes 34°25'00"N and 34°46'50"N, and longitudes 46°34'50"E and 46°50'00"E. Geologically, the plain is predominantly limestone-based, fed by karst springs and shallow aquifers.

Input data included precipitation, minimum and maximum temperature, relative humidity, and soil moisture from 98 CMIP6 climate models, as well as groundwater level observations from 23 monitoring wells (1992–2014). K-means clustering, with the Elbow method, identified three optimal clusters: Kouzaran, TamTam, and Lori. After the formation of the clusters, the center of each cluster was designated as the representative (including the average GWL time series from the wells in that area), and the Random Forest algorithm was used for groundwater level modeling.

Simulations were conducted under three climate scenarios—SSP1-2.6, SSP2-4.5, and SSP5-8.5—across three future periods: near-future (2026–2050), mid-future (2051–2075), and far-future (2076–2100). Model performance was evaluated using R, NSE, MBE, SI, and NRMSE in both training and testing phases. Recursive Feature Elimination (RFE) was applied to reduce dimensionality and enhance model precision, while model validation used 5-fold cross-validation.

Results and Discussion:

K-means clustering revealed a clear spatial structure in GWL data, delineating three distinct regions. RF modeling showed the highest accuracy in the Kouzaran cluster ($R = 0.92$, $NSE = 0.83$), while the Lori cluster showed relatively lower performance ($R = 0.78$, $NSE = 0.60$).

Among the 98 CMIP6 models, NorESM2-MM consistently outperformed others across all clusters. Soil moisture was identified as the most influential variable in predicting GWL. Incorporating additional models (ACCESS-CM2, INM-CM5-0, MIROC6, and CESM2-WACCM) further improved model accuracy, reaching up to 98%.

Historical trend analysis (1992–2014), using the Mann-Kendall test, indicated significant declining trends in all clusters: 77 cm/year in Kouzaran, 68 cm/year in TamTam, and approximately 56 cm/year in Lori. Future projections showed that under SSP1-2.6, a slight GWL improvement is expected in the near future, followed by a significant decline in the mid-term (e.g., -19 cm/year in Kouzaran). Under SSP2-4.5, moderate short-term recovery is followed by continued declines through the mid- and far-future periods (e.g., -22 cm/year in Kouzaran). Under SSP5-8.5, the near- and mid-future periods show substantial GWL increases (e.g., +24 cm/year in Kouzaran), while far-future trends point to gradual declines. Seasonally, fall is projected to show the greatest GWL

recovery (up to 4 meters in Kouzaran under SSP5-8.5, far- future), whereas spring may experience the steepest decline (e.g., -1.83 meters in TamTam under SSP2-4.5, mid- future).

Conclusion:

This study demonstrates that integrating RF and K-means algorithms with CMIP6 climate data provides an effective framework for accurately predicting future GWL trends. NorESM2-MM, with soil moisture as the dominant predictor, was identified as the most reliable model. RF achieved strong performance across all clusters, particularly in Kouzaran, which exhibited greater fluctuations in groundwater levels.

Despite potential near-future improvements, long-term projections—especially during spring—suggest substantial declines in GWL and increased aquifer instability. These findings highlight the urgent need for climate-adaptive groundwater management strategies in the Ravansar-Sanjabi plain.

Author Contributions

Conceptualization, Kobra Soltani, Seyed Ehsan Fatemi and Jafar Masoompour Samakosh; methodology, Seyed Ehsan Fatemi and Jafar Masoompour Samakosh; software, Seyed Ehsan Fatemi and Kobra Soltani; validation, Jafar Masoompour Samakosh and Maryam Hafezparast Mavadat; analysis, Kobra Soltani, Seyed Ehsan Fatemi, and Jafar Masoompour Samakosh; investigation, Kobra Soltani and Seyed Ehsan Fatemi; resources, Kobra Soltani and Maryam Hafezparast Mavadat; writing—original draft preparation, Kobra Soltani; writing—review and editing, Jafar Masoompour Samakosh, Seyed Ehsan Fatemi and Maryam Hafezparast. All authors have read and agreed to the published version of the manuscript.

Data Availability Statement

Data can be sent from the corresponding author by email upon request.

Acknowledgements

The authors would like to thank all participants of the present study.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

مدلسازی و شناسایی عوامل کلیدی سطح آب زیرزمینی در دشت روانسر – سنجابی با استفاده از داده های اقلیمی CMIP6

چکیده

در این پژوهش، با هدف پیش‌بینی تغییرات آبی عمق سطح آب زیرزمینی (GWL) در دشت روانسر – سنجابی، از ترکیب الگوریتم‌های K-means و جنگل تصادفی (RF) با داده‌های اقلیمی CMIP6 (بارش، دمای حداقل و حداکثر، رطوبت نسبی و رطوبت خاک) استفاده شد. داده‌های ۹۸ مدل اقلیمی استخراج و با روش حذف بازگشتی ویژگی‌ها (RFE)، مهم‌ترین متغیرها شناسایی شد. مدل NorESM2-MM به‌عنوان مؤثرترین مدل اقلیمی در منطقه و رطوبت خاک به‌عنوان مهم‌ترین عامل پیش‌بینی شناسایی گردید. عملکرد مدل RF نشان داد که خوشه کوزران با ضریب همبستگی ۰/۹۲ و نش-ساتکلیف ۰/۸۳، بهترین نتایج را ارائه داده است.

تحلیل روند تاریخی (۱۹۹۲-۲۰۱۴) افت معنادر GWL در همه خوشه‌ها را نشان داد؛ بیشترین کاهش مربوط به کوزران و تهم به‌شیب‌های ۷۷ و ۶۸ سانتی‌متر در سال بوده. براساس سناریوهای اقلیمی، در SSP1-2.6 و SSP2-4.5 در آینده نزدیک بهبود نسبی، و در آینده میانی و دور کاهش معنادر GWL پیش‌بینی می‌شود؛ بیشترین افت در کوزران با نرخ ۱۹ و ۲۲ سانتی‌متر در سال پیش‌بینی می‌شود. در SSP5-8.5، آینده نزدیک و میانی با روند افزایشی معنادر همراه است و بیشترین افزایش در آینده میانی کوزران (۲۴ سانتی‌متر در سال) رخ می‌دهد؛ اما در آینده دور کاهش تدریجی پیش‌بینی می‌شود. از نظر فصلی، بیشترین بهبود در پاییز (حدود ۴ متر در کوزران تحت SSP5-8.5 در آینده دور) و بیشترین افت در بهار (۱/۸۳ متر در تهم تحت SSP2-4.5 در آینده میانی) پیش‌بینی می‌شود. این نتایج بر ضرورت برنامه‌ریزی اقلیمی محور برای حفاظت از منابع آب زیرزمینی منطقه تأکید دارد.

واژگان کلیدی: الگوریتم جنگل تصادفی، پیش‌بینی GWL، خوشه‌بندی CMIP6 K-means، متغیرهای کلیدی

مقدمه

در سال‌های اخیر، مدیریت پایدار منابع آب در ایران با چالش‌هایی نظیر افزایش تقاضا، بهره‌برداری بیش از حد، و کاهش منابع تجدیدپذیر مواجه شده است. (Madani, 2014; Amiraslani & Caiserman, 2020; Nouri et al., 2023) این چالش‌ها به‌ویژه در مناطق خشک و نیمه‌خشک، تحت تأثیر تغییرات اقلیمی، نیاز به راهکارهای نوآورانه برای مدیریت مؤثر منابع آبی را تشدید کرده‌اند (Fatemi & Parvini, 2022). مدل سازی عمق سطح آب زیرزمینی (GWL) (عمق آب زیر زمینی یعنی ارتفاع آب از سطح زمین) با استفاده از فناوری‌های پیشرفته، ابزاری حیاتی برای بهینه سازی بهره‌برداری و حفظ پایداری آبخوان‌ها محسوب می شود (فاطمی و همکاران، ۱۳۹۷؛ Biswas و همکاران، ۲۰۲۵). در این زمینه، با افزون شدن پیامدهای ناشی از تغییرات اقلیمی، رشد جمعیت، الگوریتم‌های یادگیری ماشین (ML)، با دقت بالا، سرعت محاسباتی و توانایی تحلیل داده‌های پیچیده و بزرگ، نسبت به روش‌های سنتی برتری یافته‌اند (Hirko et al., 2025; Ahmadi et al., 2022; Uc-Castillo et al., 2023). مدل‌هایی چون جنگل تصادفی (RF)، شبکه عصبی مصنوعی (ANN)، رگرسیون بردار پشتیبانی (SVR) و یادگیری عمیق (DL) توانسته‌اند پیش‌بینی‌های قابل اتکایی برای عمق GWL در مقیاس‌های زمانی مختلف ارائه دهند (Igwebuike et al., 2025; Boo et al., 2024; Khan et al., 2023). در این میان ویژگی‌های ساختاری مدل RF، از جمله تعمیم‌پذیری بالا، تفسیرپذیری متغیرها، و سازگاری با شرایط متنوع هیدروژئولوژیکی، آن را به گزینه‌ای مناسب برای مدل‌سازی سطح آب زیرزمینی تبدیل کرده است (Ma et al., 2024; Bhadani et al., 2023).

مطالعات متعددی در نقاط مختلف جهان، از آفریقای جنوبی (Elmotawakkil et al., 2024)، تونس در شمال غربی آفریقا (Trabelsi et al., 2022)، هند (Gupta et al., 2024; Saha et al., 2025) گرفته تا مکزیک (Sanchez & Capurata, 2024) عملکرد مطلوب الگوریتم جنگل تصادفی را در پیش‌بینی سطح آب زیرزمینی یا مطالعات پتانسیل آب زیرزمینی تأیید کرده‌اند. بطور کلی در ایران نیز، پژوهش‌هایی در پیرانشهر (Davoudi Moghaddam et al., 2020)، کرمان (Tavakoli et al., 2024)، دشت موسیان ایلام (سلیمی و همکاران ۱۴۰۲)، بیرجند (پورصالحی و همکاران، ۱۴۰۰)، شبستر (Norouzi & Shahmohammadi, 2019)، تسوج (مختاری و همکاران، ۱۳۹۸) و بوکان (نوروزی و ندیری، ۱۳۹۷) نشان داده‌اند که مدل RF در مقایسه با سایر روش‌ها از دقت بالاتری برخوردار است. افزون بر آن، اعتبارسنجی مدل‌های ML با روش‌هایی مانند K-fold cross-validation به کاهش بیش‌برازش و افزایش اعتماد به عملکرد مدل کمک می‌کند (Lal et al., 2024; Goodarzi et al., 2025). تلفیق این مدل‌ها با داده‌های محیطی گوناگون، قابلیت پیش‌بینی تغییرات سطح آب زیرزمینی را در شرایط متغیر اقلیمی ارتقاء می‌بخشد (Bamal et al., 2024; Hanane et al., 2024). از منظر متغیرهای کلیدی، موفقیت مدل‌سازی سطح آب زیرزمینی در شرایط اقلیمی متغیر، در گرو انتخاب دقیق داده‌های ورودی مؤثر است. متغیرهای اقلیمی مانند بارش، دما، تبخیر و تعرق، رطوبت نسبی و ذوب برف، به‌عنوان محرک‌های اصلی چرخه هیدرولوژیکی، نقش بسزایی در نوسانات عمق GWL دارند. مطالعات داخلی و بین‌المللی به‌روشنی این نقش را تأیید کرده‌اند؛ چنان‌که بارش به‌عنوان متغیر کلیدی در تغییرات GWL معرفی شده (Iqbal et al., 2020; Crosett et al., 2023) و عواملی مانند تبخیر، تعرق و ذوب برف نیز در کنار آن اهمیت یافته‌اند (Wu et al., 2020). در مطالعات داخلی نیز، مدل‌سازی GWL با تکیه بر داده‌های بارش، دما و رطوبت نسبی (پورصالحی و همکاران، ۱۴۰۰؛ عسکری و اگدرنژاد، ۱۴۰۱؛ سراج‌ابراهیمی و همکاران، ۱۴۰۱؛ ربیعی و کرمی، ۱۴۰۱) و یا رطوبت خاک (سلطانی و همکاران، ۱۴۰۴) را مورد تأکید قرار داده‌اند. برخی مطالعات نیز به

¹ GroundWater Level

² Machine learning

³ Random Forest

⁴ Artificial Neural Network

⁵ Support Vector Regression

⁶ Deep Learning


داده‌های اقلیمی بارش، دما و ذخایر برف در بررسی تغییرات GWL دشت روانسر-سنجابی (دشت مورد بررسی در مطالعه حاضر) اکتفا کرده‌اند (سلطانی و همکاران، ۱۴۰۱؛ سهرابی و همکاران، ۱۳۹۵).

پژوهش حاضر برای نخستین بار با بهره‌گیری از الگوریتم RF و مدل‌های منتخب CMIP6 در سه سناریوی SSP^۷، به تحلیل همزمان اثرات بارش، دما، تبخیر و تعرق، رطوبت نسبی و رطوبت خاک بر عمق GWL خواهد پرداخت. برخلاف مطالعات پیشین که فاقد تحلیل کمی از اهمیت نسبی متغیرها بوده‌اند، این پژوهش با استفاده از ساختار تفهیم‌پذیر RF، سهم هر متغیر را در پیش‌بینی عمق GWL به صورت دقیق ارزیابی کرده و از طریق خوشه‌بندی K-Means، ناهمگنی فضایی منطقه را نیز لحاظ نموده است. بدین ترتیب، ترکیب داده‌های اقلیمی آینده‌نگر، رویکرد یادگیری ماشین و تحلیل مکانی-زمانی، الگویی دقیق و کاربردی برای مدیریت هوشمند منابع آب زیرزمینی در مناطق نیمه‌خشک و مشابه با دشت روانسر-سنجابی ارائه می‌دهد.

روش‌شناسی پژوهش

منطقه مورد مطالعه

دشت روانسر، واقع در استان کرمانشاه در غرب ایران، محدوده‌ای مستطیل شکل است که بین عرض‌های جغرافیایی $34^{\circ}25'00''$ تا $34^{\circ}46'50''$ شمالی و طول‌های جغرافیایی $46^{\circ}34'50''$ تا $46^{\circ}50'00''$ شرقی گسترده شده است. این دشت از شمال با کوه‌های گل‌راس، از غرب با ارتفاعات نووله، از شرق با رشته‌کوه‌های بابک و دزان هم‌مرز است. مساحت این دشت حدود ۴۵۷ کیلومتر مربع برآورد می‌شود. رودخانه قره‌سو، که از سراب روانسر منشأ می‌گیرد، به‌عنوان جریان اصلی آب سطحی در منطقه ایفای نقش می‌کند. از نظر زمین‌شناسی، منطقه عمدتاً از واحدهای آهکی کارستی تشکیل شده که نقش مهمی در شکل‌گیری چشمه‌های دائمی، از جمله چشمه سدراب، ایفا کرده‌اند. شرایط اقلیمی منطقه با میانگین بارندگی سالانه حدود ۵۲۰ میلی‌متر و میزان تبخیر در حدود ۲۰۰ میلی‌متر مشخص می‌شود (Parvizi & Fatehi, 2024).



شکل ۱. موقعیت جغرافیایی چاه‌های مشاهداتی در دشت روانسر-سنجابی

⁷ Shared Socioeconomic Pathways

داده‌ها

برای بررسی تأثیر تغییر اقلیم بر GWL دشت روانسر، داده‌های ماهانه ۲۳ چاه مشاهده‌ای برای دوره ۲۰۱۴-۱۹۹۲ از سازمان داده‌های آب کشور (<https://data.wrm.ir/>) جمع‌آوری شد. همچنین برای این بازه زمانی داده‌های اقلیمی شامل بارش، دمای حداقل و حداکثر و رطوبت نسبی از سازمان هواشناسی کشور (<https://www.irimo.ir/>)، رطوبت خاک با تفکیک مکانی $0.5^\circ \times 0.625^\circ$ از MERRA2 (<https://esgf-data.dkrz.de/>) استخراج گردید (جدول ۱). این داده‌ها مربوط به موقعیت ایستگاه روانسر (34.72°N , 46.65°E) و در پیکربندی r1i1p1f1 بودند. با توجه به هدف اصلی این پژوهش که ارزیابی نوسانات عمق GWL در دشت روانسر-سنجابی با استفاده از ترکیب الگوریتم‌های یادگیری ماشین و داده‌های اقلیمی مدل‌های CMIP6 بود، داده‌های اقلیمی تنها برای موقعیت ایستگاه سینوپتیک روانسر استخراج شدند. این ایستگاه با توجه به موقعیت جغرافیایی و پوشش مناسب منطقه، نماینده‌ای قابل اتکا برای شرایط اقلیمی دشت روانسر محسوب می‌شود. استفاده از داده‌های نقطه‌ای ایستگاهی (به‌ویژه در مناطق با ناهمگونی اقلیمی مانند روانسر) از دقت بالاتری نسبت به داده‌های میان‌یابی‌شده شبکه‌ای برخوردار است. از سوی دیگر، داده‌های CMIP6 نیز برای مختصات همین ایستگاه بازایی شده‌اند تا همگنی مکانی بین داده‌های مشاهده‌ای و شبیه‌سازی‌شده حفظ گردد و دقت مدل افزایش یابد.

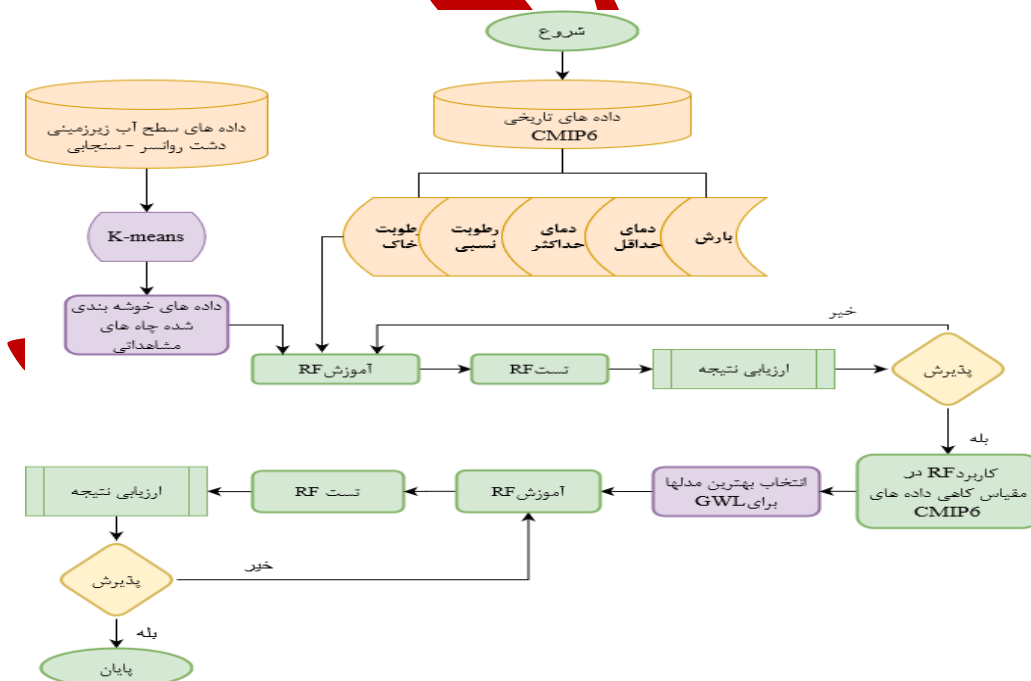
جدول ۱- مدل‌های CMIP6 استفاده شده از متغیرهای مختلف در پژوهش حاضر

نام مدل	بارش	دمای حداکثر	دمای حداقل	رطوبت نسبی	رطوبت خاک	وضوح مکانی (کیلومتر)
ACCESS-CM2	×	×	×	×	×	۱۰۰
AWI-CM-1-1-MR	×	×	×			۱۰۰
BCC-CSM2-MR	×	×	×		×	۱۰۰
CAMS-CSM1-0	×					۱۰۰
CanESM5	×	×		×		۵۰۰
CIESM		×	×			۱۰۰
CAS-ESM2-0	×					۱۰۰
CESM2-WACCM	×			×	×	۱۰۰
CMCC-CM2-SR5	×			×	×	۱۰۰
CMCC-ESM2	×			×		۱۰۰
EC-Earth3	×			×		۱۰۰
EC-Earth3-Veg	×		×			۱۰۰
EC-Earth3-Veg-LR	×	×		×		۲۵۰
FGOALS-f3-L	×			×		۱۰۰
FGOALS-g3	×	×	×	×		۲۵۰
FIO-ESM-2-0	×	×	×	×		۱۰۰
GFDL-ESM4	×	×	×	×		۱۰۰
IITM-ESM	×					۲۵۰
INM-CM4-8	×	×	×	×	×	۱۰۰
INM-CM5-0	×	×	×	×	×	۱۰۰
IPSL-CM6A-LR	×	×	×	×	×	۲۵۰
KACE-1-0-G	×	×	×	×		۲۵۰
KIOST-ESM	×			×		۲۵۰
MIROC6	×	×	×	×	×	۲۵۰

MPI-ESM1-2-HR	×	×	×	×	×	۱۰۰
MPI-ESM1-2-LR	×	×	×	×	×	۲۵۰
MRI-ESM2-0	×	×	×	×	×	۱۰۰
NESM3	×	×	×			۲۵۰
NorESM2-MM	×			×	×	۱۰۰
NorESM2-LM				×		۲۵۰
TaiESM1	×					۱۰۰
تعداد کل مدلها = ۳۱	۲۹	۱۸	۱۷	۲۲	۱۲	

داده‌های مدل‌ها برای آینده (۲۰۲۶-۲۱۰۰) تحت سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5 به سه بازه زمانی آینده نزدیک، میانی و دور تقسیم شد. سپس با الگوریتم RF و نسبت ۷۰٪ آموزش و ۳۰٪ تست، برای ایستگاه روانسر ریزمقیاس‌نمایی شدند.

برای تحلیل بهتر، داده‌های عمیق GWL با K-means خوشه‌بندی شده و از اعتبارسنجی K-fold استفاده شد. انتخاب ویژگی‌ها (مدل‌های CMIP6 ورودی از متغیرهای مختلف) با ترکیب الگوریتم RF و روش حذف بازگشتی ویژگی‌ها (RFE) یا متغیرها و مدل‌های منتخب انجام گرفت تا ویژگی‌های مؤثر شناسایی و موارد کم‌اهمیت حذف شوند. آزمون و خطا نشان داد که تخصیص ۸۰٪ داده‌ها به آموزش، نتایج بهتری به همراه دارد. در نهایت، مدل‌های منتخب برای پیش‌بینی عمق GWL توسط RF، در سه دوره زمانی آینده مورد استفاده قرار گرفتند. برای درک بهتر از روند کلی این تحقیق، مراحل پیش‌بینی عمق GWL دشت روانسر در شکل ۲ ارائه شده است.



شکل ۲. مراحل تحقیق

روش K-میانگین (K-means)

روش K-means یک الگوریتم خوشه‌بندی است که به طور گسترده‌ای در مسائل یادگیری بدون نظارت استفاده می‌شود. هدف اصلی این روش، تقسیم داده‌ها به k گروه متمایز و کشف الگوهای نهفته در داده‌ها است. در این روش، ابتدا تعداد خوشه‌ها (k) باید تعیین شود. در مرحله اول، K-means، مراکز اولیه خوشه‌ها را به صورت تصادفی انتخاب کرده و سپس نمونه‌ها را بر اساس فاصله اقلیدسی به این مراکز گروه‌بندی می‌کند. این الگوریتم به دنبال کمینه کردن فاصله بین نمونه‌ها و مراکز خوشه‌ها است تا بهترین تقسیم‌بندی ممکن را ارائه دهد. K-means به عنوان یک روش مؤثر برای تحلیل داده‌ها و بهبود فرآیندها، در زمینه‌های مختلف به کار می‌رود (Rizwan et al., 2021).

به منظور انتخاب مجموعه‌ای نماینده از چاه‌های مشاهده‌ای در دشت روانسر-سنجابی، ابتدا فرآیند خوشه‌بندی با الگوریتم K-means بر پایه مختصات UTM چاه‌ها انجام شد. برای تعیین تعداد بهینه خوشه‌ها، از روش Elbow بهره گرفته شد؛ بدین صورت که با محاسبه مجموع خطاهای درون خوشه‌ای برای مقادیر مختلف k ، نقطه‌ای که کاهش خطا روند کندتری به خود می‌گیرد (نقطه زانو) به عنوان مقدار بهینه k در نظر گرفته شد. پس از شکل‌گیری خوشه‌ها، مرکز هر خوشه به عنوان نماینده (شامل سری زمانی میانگین GWL از چاه‌های آن منطقه) معرفی شد.

الگوریتم جنگل تصادفی (RF)

RF یکی از روش‌های پرکاربرد در حوزه یادگیری ماشین است که برای تحلیل مسائل رگرسیون و طبقه‌بندی به کار می‌رود. این الگوریتم بر مبنای ساختار درخت‌های تصمیم و با استفاده از روش‌های نمونه‌برداری تصادفی (bootstrap) توسعه یافته است. در RF، چندین درخت تصمیم به صورت مستقل و بر پایه نمونه‌های مختلف از داده‌های آموزش ایجاد می‌شوند. در کاربردهای رگرسیون، که متغیر هدف پیوسته است، نتیجه نهایی مدل بر اساس میانگین خروجی تمام درخت‌ها محاسبه می‌شود (Wang, 2024).

یکی از ویژگی‌های برجسته RF توانایی آن در تشخیص اهمیت نسبی متغیرها در فرآیند آموزش است، که این قابلیت برای مدل‌سازی پدیده‌های محیطی مانند GWL بسیار مفید است. همچنین، استفاده از زیرمجموعه‌های تصادفی ویژگی‌ها در ایجاد درخت‌ها به افزایش پایداری و کاهش بیش‌برازش (overfitting) کمک می‌کند (Madani & Niyazi, 2023). در این پژوهش، الگوریتم RF با بهره‌گیری از ۱۰۰ درخت تصمیم استفاده شد. برای ارزیابی کیفیت تفکیک در هر گره، معیار پس‌فرض جینی (Gini) به کار گرفته شد که میزان نابرابری در توزیع کلاس‌ها را اندازه‌گیری می‌کند؛ کاهش مقدار این شاخص بیانگر افزایش یکنواختی و خلوص نمونه‌ها در گره‌های حاصل از تقسیم است. در فرآیند آموزش مدل، عمق درخت‌ها محدود شد و هر درخت تا زمانی رشد یافت که گره‌های نهایی (برگ‌ها) حاوی نمونه‌هایی با برچسب یکسان بودند. به بیان دیگر، فرآیند تقسیم تا خالص‌سازی کامل داده‌ها در هر برگ ادامه یافت تا به حداکثر تمایز در طبقه‌بندی دست یابد. در پژوهش حاضر برای ریزمقیاس‌نمایی و پیش‌بینی از RF استفاده شد. چراکه بزرگ بودن مقیاس سلول‌های مدل‌های اقلیم جهانی (GCMs) برای استفاده در مطالعات با مقیاس مکانی کوچک نیاز به ریزمقیاس‌نمایی دارند (الماسی و همکاران، ۱۴۰۳).

به منظور پیش‌بینی تغییرات آبی عمق GWL در دشت روانسر-سنجابی نیز از الگوریتم RF به عنوان یکی از روش‌های یادگیری ماشین غیرخطی و دقیق، جهت مدل‌سازی روابط پیچیده میان متغیرهای اقلیمی و عمق GWL استفاده شد. در این فرآیند، ابتدا داده‌های اقلیمی مشاهداتی شامل بارش، دمای حداقل، دمای حداکثر، رطوبت نسبی و رطوبت خاک در بازه زمانی ۱۹۹۲ تا ۲۰۱۴ برای ایستگاه سینوپتیک روانسر گردآوری گردید. همچنین، داده‌های اقلیمی شبیه‌سازی شده از مدل‌های منتخب CMIP6 برای همین بازه زمانی، در موقعیت جغرافیایی ایستگاه روانسر استخراج شد. در ادامه، مدل RF برای یادگیری رابطه بین متغیرهای اقلیمی مدل‌های CMIP6 (به عنوان ورودی) و داده‌های اقلیمی مشاهده‌ای ایستگاه روانسر (به عنوان خروجی هدف) آموزش داده شد. این مدل برای هر متغیر اقلیمی به صورت جداگانه و با استفاده از نسبت ۷۰٪ داده‌ها برای آموزش و ۳۰٪ برای تست مدل توسعه یافت.

متغیرهای ورودی (Predictors) شامل بارش، دمای حداقل، دمای حداکثر، رطوبت نسبی و رطوبت خاک از داده‌های مدل‌های CMIP6 بودند و متغیرهای هدف (Targets) همان متغیرها از داده‌های ایستگاه سینوپتیک روانسر و رطوبت خاک از پایگاه داده MERRA-2 بودند.

پس از آموزش مدل، الگوریتم RF برای ریزمقیاس‌نمایی داده‌های اقلیمی آینده مدل‌های CMIP6 در دوره زمانی ۲۰۲۶ تا ۲۱۰۰ تحت سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5 مورد استفاده قرار گرفت. در نهایت، داده‌های اقلیمی ریزمقیاس شده برای تحلیل نو سانات عمق GWL در دشت روانسر - سنجابی به کار گرفته شد. عملکرد مدل RF نیز با استفاده از شاخص‌های آماری مناسب ارزیابی گردید.

اعتبارسنجی متقابل K-Fold

در این پژوهش، به منظور آموزش و ارزیابی عملکرد مدل‌ها در بازه زمانی ۱۹۹۲ تا ۲۰۱۴ از روش اعتبارسنجی متقابل K-Fold استفاده شده است. در این شیوه، مجموعه داده‌های مشاهده‌ای به k بخش مساوی تقسیم می‌شوند. در هر تکرار، یکی از این بخش‌ها به عنوان داده تست در نظر گرفته شده و $k-1$ بخش باقی‌مانده برای آموزش مدل مورد استفاده قرار می‌گیرند. این فرآیند به گونه‌ای طراحی شده است که هر زیرمجموعه دقیقاً یک‌بار در جایگاه داده تست قرار می‌گیرد و در سایر دفعات به عنوان داده آموزش استفاده می‌شود (Darabi Cheghabaleki et al., 2024). در چارچوب این مطالعه، مقدار k برابر ۵ تعیین شده که با توجه به بازه زمانی ۲۳ ساله داده‌ها، هر فولد نماینده حدود ۴/۶ سال است. این روش نه تنها امکان ارزیابی دقیق‌تری از عملکرد مدل فراهم می‌کند، بلکه به کاهش خطای ناشی از تقسیم تصادفی داده‌ها نیز کمک می‌نماید.

شاخص‌های ارزیابی عملکرد

برای ارزیابی تفاوت بین داده‌های مشاهده‌شده و شبیه‌سازی‌شده (۲۰۱۴-۱۹۹۲)، از تکنیک‌های آماری استفاده شد که شامل شاخص‌های زیر است: شاخص پراکندگی (SI)، خطای میانگین انحراف (MBE)، خطای مربع ریشه نرمال شده (NRMSE)، کارایی نش-ساتکلیف (NSE) و ضریب همبستگی (R). این شاخص‌ها به صورت روابط ۱ تا ۵ تعریف می‌شوند (Moeeni et al., 2017; Farasati et al., 2024). که در آن‌ها Y_i داده‌های مشاهده شده، $\bar{Y}$ میانگین داده‌های مشاهده شده و n تعداد کل داده‌ها است.

$$SI = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}} \quad \text{رابطه ۱}$$

$$MBE = \frac{\sum_{i=1}^n (Y_i - \bar{Y})}{n} \quad \text{رابطه ۲}$$

$$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}}}{Y_{\max} - Y_{\min}} \quad \text{رابطه ۳}$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \right] \quad \text{رابطه ۴}$$


$$R = \frac{\sum_{i=1}^N (X_{\text{obs},i} - \bar{X}_{\text{obs}})(X_{\text{sim},i} - \bar{X}_{\text{sim}})}{\sqrt{\sum_{i=1}^N (X_{\text{obs},i} - \bar{X}_{\text{obs}})^2 \sum_{i=1}^N (X_{\text{sim},i} - \bar{X}_{\text{sim}})^2}} \quad \text{رابطه ۵}$$

آزمون روند من-کندال (Mann-Kendall- MK)

MK به عنوان یک روش ناپارامتری برای تعیین روند سری‌های زمانی متغیرها در مطالعات مختلف به کار می‌رود. نتایج تحقیقات نشان می‌دهد که آزمون MK یکی از بهترین گزینه‌ها برای تحلیل روند داده‌ها است (Wang et al., 2020). فرض صفر این آزمون بر تصادفی بودن و عدم وجود روند در داده‌ها دلالت دارد و رد فرض صفر نشان‌دهنده وجود روند در داده‌ها است (Shah & Kiran, 2021). از آن جا که این آزمون در حالت استاندارد، فرض استقلال زمانی داده‌ها را در نظر می‌گیرد، برای کاهش اثر احتمالی خودهمبستگی، داده‌های مورد استفاده به مقیاس سالانه تبدیل گردید. این تبدیل باعث کاهش معنی‌دار خودهمبستگی در سری‌های زمانی می‌شود (Collaud Coen et al., 2020). به منظور مطالعه بیشتر و نحوه انجام مراحل آزمون MK به مطالعه Das و همکاران (۲۰۲۲) مراجعه فرمایید. در مطالعه حاضر سطح اطمینان ۹۵٪ در نظر گرفته شده است.

یافته‌های پژوهش خوشه‌بندی

بر اساس الگوریتم K-means و با بهره‌گیری از روش Elbow برای تعیین تعداد بهینه خوشه‌ها، داده‌های مکانی چاه‌ها خوشه‌بندی شدند. نقطه‌ای که کاهش خطا از حالت مربع به حالت کند تغییر می‌کند (شکل زانو یا Elbow point)، بهترین تعداد خوشه‌ها را نشان می‌دهد، زیرا پس از آن افزودن خوشه‌های بیشتر، بهبودی اندک در کارایی مدل دارد. بنابراین تعداد بهینه ۳ در نظر گرفته شد (شکل ۳-الف). در نتایج گرافیکی، خوشه‌ها به وضوح از یکدیگر تفکیک شده و توزیع جغرافیایی چاه‌ها به نحوی سازمان‌دهی گردید که هر خوشه دارای مرکز مشخصی است (شکل ۳-ب). این ساختار خوشه‌ای منجر به انتخاب نماینده‌های مکانی مؤثر برای مدلسازی GWL در دشت روانسر-سنجابی شد و پایه‌ای قابل اعتماد برای الگوریتم‌های یادگیری ماشین فراهم می‌سازد.




شکل ۳. انتخاب تعداد بهینه خوشه‌ها با روش K-means (الف) و موقعیت مراکز خوشه‌ها در دشت روانسر-سنجابی (ب)

انتخاب ویژگی‌های برتر

در این پژوهش، با هدف پیش‌بینی تغییرات GWL دشت روانسر-سنجابی، از داده‌های ۹۸ مدل اقلیمی CMIP6 مربوط به متغیرهای بارش، دمای حداقل و حداکثر، رطوبت نسبی و رطوبت خاک استفاده گردید. به منظور انتخاب مؤثرترین مدل‌ها، از الگوریتم RF به

همراه روش RFE بهره گرفته شد. آزمون و خطا نشان داد که اختصاص ۸۰٪ از داده‌های تاریخی به آموزش و ۲۰٪ به تست در فرآیند آموزش مدل نتایج بهتری به همراه دارد.

بررسی نتایج نشان داد که در خوشه لری، با استفاده از ۸ ویژگی (مدل CMIP6) مرتبط‌تر، میانگین دقت آزمون حدود ۶۷٪ حاصل شد (شکل ۳-الف). اگرچه افزایش تعداد ویژگی‌ها به ۱۶ مدل منجر به بهبود نسبی دقت تا حدود ۷۲٪ گردید، اما این افزایش اندک در مقابل رشد چشمگیر حجم محاسباتی چندان توجیه‌پذیر نبود. در تم‌تم، میانگین دقت آزمون با استفاده از ۶ ویژگی اولیه به حدود ۸۵٪ رسید (شکل ۳-ب). در خوشه کوزران، عملکرد بهتری نسبت به دو خوشه دیگر مشاهده شد. میانگین دقت آزمون در این منطقه با ۵ ویژگی به حدود ۹۲٪ رسید (شکل ۳-ج) و تعداد بهینه‌ای از ویژگی‌های ورودی (مدل‌های اقلیمی) برای دستیابی به حداکثر دقت ممکن با حداقل پیچیدگی محاسباتی، انتخاب شد.



شکل ۳. ارزیابی تعداد مدل‌های ورودی برای هر منطقه از دشت روانسر-سنجایی

برای افزایش دقت مدل RF در پیش‌بینی عمق GWL، از راهبرد تجمیع تدریجی مدل‌های اقلیمی منتخب CMIP6 با استفاده از روش RFE استفاده شد. در این فرایند، ابتدا یک مدل پایه با دقت اولیه مشخص انتخاب گردید (F_0) و سپس در مراحل بعدی،

مدل‌های دیگر به صورت تدریجی به آن افزوده شدند. در هر مرحله، با آموزش مجدد مدل RF بر اساس ترکیب جدید، دقت پیش‌بینی مجدداً ارزیابی شد. روند افزایشی دقت مدل نشان‌دهنده اثر مثبت افزودن مدل‌های مکمل بود.

با بهره‌گیری از الگوریتم RF، میزان تأثیرگذاری مدل‌های اقلیمی مختلف در پیش‌بینی عمق GWL برای سه خوشه (منطقه) از دشت روانسر شامل لُری، تم‌تم و کوزران مورد ارزیابی قرار گرفت. نتایج حاصل (جدول ۲) نشان داد که مدل NorESM2-MM در هر سه خوشه مؤثرترین مدل پایه است، به گونه‌ای که دقت پیش‌بینی اولیه آن به ترتیب در خوشه‌های لُری، تم‌تم و کوزران معادل ۹۳٪، ۷۲٪ و ۸۲٪ بود. این مقادیر گویای توانایی بالای این مدل در بازتولید روندهای عمق GWL در مناطق مورد بررسی است.

در خوشه لُری علاوه بر مدل NorESM2-MM با دقت اولیه ۹۳٪ به عنوان مدل پایه (F_0) افزوده شدن مدل‌های ACCESS-CM2 و INM-CM5-0 (F_1)، دقت به ۹۴٪ رسید. سپس با اضافه شدن مدل INM-CM4-8 (F_2) دقت به ۹۶٪ ارتقا یافت. افزودن MIROC6 در مرحله F_3 باعث افزایش دقت به ۹۷٪ گردید و در نهایت با افزودن مدل‌های FGOALS-g3 از متغیر بارش، CESM2-WACCM و CMCC-CM2-SR5 (F_4) دقت نهایی به ۹۸٪ رسید. در خوشه تم‌تم پس از مدل پایه NorESM2-MM با دقتی معادل ۷۲٪، اضافه شدن CMCC-CM2-SR5 (F_1) دقت را به ۸۷٪ افزایش داد. در مراحل بعدی، به ترتیب INM-CM5-0 (F_2)، INM-CM4-8 (F_3)، MIROC6 (F_4) و نهایتاً CESM2-WACCM (F_5) اضافه شدند و دقت مدل تا ۹۸٪ افزایش یافت. در منطقه کوزران نیز علاوه بر مدل NorESM2-MM که با دقت اولیه ۸۲٪ آغازگر فرآیند بود، اضافه شدن INM-CM5-0 (F_1) دقت را به ۹۱٪ رساند. سپس MIROC6 (F_2)، CMCC-CM2-SR5 (F_3) و نهایتاً CESM2-WACCM (F_4)، به ترتیب افزوده شدند و دقت نهایی به حدود ۹۹٪ افزایش یافت.

این روند نشان می‌دهد که انتخاب مدل‌های مکمل با دقت مناسب و ساختارهای متنوع، در کنار فرایند تدریجی و کنترل‌شده ترکیب، می‌تواند موجب افزایش قابل توجه دقت مدل‌های یادگیری ماشین گردد. شایان ذکر است که سهم مدل‌هایی که در ترکیب نهایی مشارکت نداشتند (یعنی ۹۰ مدل در لُری، ۹۲ مدل در تم‌تم و ۹۳ مدل در کوزران) در افزایش دقت نهایی تابع پیش‌بینی حدود ۲٪ برآورد می‌شود؛ این امر دلالت بر کفایت و جامعیت مدل‌های منتخب در پوشش‌دهی کامل ویژگی‌های اقلیمی مؤثر بر عمق GWL دارد و استفاده از سایر مدل‌ها صرفاً تأثیری جزئی دارد.

جدول ۲. مدل‌ها و متغیرهای انتخاب‌شده بر اساس حساسیت RF به ورودی‌های اقلیمی

نام خوشه	متغیر مؤثر	میزان تأثیر (%)	مدل‌های مؤثر در هر خوشه
لُری	رطوبت خاک	۹۳	$F_0 = \text{NorESM2-MM}$
	رطوبت خاک + رطوبت خاک	۹۴	$F_1 = F_0 + \text{ACCESS-CM2} + \text{INM-CM5-0}$
	رطوبت خاک	۹۶	$F_2 = F_1 + \text{INM-CM4-8}$
	رطوبت خاک	۹۷	$F_3 = F_2 + \text{MIROC6}$
	رطوبت خاک + رطوبت خاک + بارش	۹۸	$F_4 = F_3 + \text{FGOALS-g3} + \text{CESM2-WACCM} + \text{CMCC-CM2-SR5}$
تم‌تم	رطوبت خاک	۷۲	$F_0 = \text{NorESM2-MM}$
	رطوبت خاک	۸۷	$F_1 = F_0 + \text{CMCC-CM2-SR5}$
	رطوبت خاک	۹۱	$F_2 = F_1 + \text{INM-CM5-0}$
	رطوبت خاک	۹۶	$F_3 = F_2 + \text{INM-CM4-8}$
	رطوبت خاک	۹۷	$F_4 = F_3 + \text{MIROC6}$
کوزران	رطوبت خاک	۹۸	$F_5 = F_4 + \text{CESM2-WACCM}$
	رطوبت خاک	۸۲	$F_0 = \text{NorESM2-MM}$
	رطوبت خاک	۹۱	$F_1 = F_0 + \text{INM-CM5-0}$
	رطوبت خاک	۹۲	$F_2 = F_1 + \text{MIROC6}$
	رطوبت خاک	۹۷	$F_3 = F_2 + \text{CMCC-CM2-SR5}$
	رطوبت خاک	۹۸/۷	$F_4 = F_3 + \text{CESM2-WACCM}$

نتایج ارزیابی عملکرد الگوریتم RF پس از ریزمقیاس‌نمایی داده‌های اقلیمی برای پیش‌بینی عمق GWL در دشت روانسر نشان داد (جدول ۳) که مدل در خوشه کوزران بهترین عملکرد را داشته است، به‌طوری که مقادیر R و NS در مرحله تست به ترتیب برابر با ۰/۹۲ و ۰/۸۳ به دست آمد. در خوشه تم‌تم نیز عملکرد مدل رضایت‌بخش بود (R= ۰/۹۰ و NS=۰/۸۱)، هرچند افزایش مقادیر SI و NRMSE نسبت به مرحله آموزش مشهود بود. در خوشه لُری، افت دقت بیشتری مشاهده شد (R=۰/۷۸ و NS=۰/۶۰)، که می‌تواند به پویایی‌های بالاتر داده‌های عمق GWL یا محدودیت تعداد داده‌ها در این مرحله (۵۴ مقدار از GWL) نسبت داده شود. به‌طور کلی، نتایج بیانگر آن است که الگوریتم RF پس از ریزمقیاس‌نمایی توانسته است سطح قابل قبولی از دقت را در پیش‌بینی تغییرات GWL ارائه دهد، هرچند دقت مدل در مواجهه با داده‌های مشاهده‌نشده در خوشه‌های مختلف متفاوت بوده است.


جدول ۳. عملکرد مدل RF در مراحل آموزش و تست

نام خوشه	آموزش					تست				
	MBE	NS	R	NRMSE	SI	MBE	NS	R	NRMSE	SI
لُری	-۰/۰۰۲	۰/۹۵	۰/۹۸	۰/۰۲۹	۰/۰۴۹	-۰/۰۱۳	۰/۶۰	۰/۷۸	۰/۱۱۱	۰/۱۲۵
تم‌تم	۰/۰۶۰	۰/۹۸	۰/۹۹	۰/۰۳۶	۰/۰۸۶	۰/۴۰۷	۰/۸۱	۰/۹۰	۰/۱۱۹	۰/۲۴۵
کوزران	۰/۰۴۳	۰/۹۹	۰/۹۹	۰/۰۳۱	۰/۰۵۱	۰/۴۷۷	۰/۸۳	۰/۹۲	۰/۰۳۱	۰/۱۷۵

پیش‌بینی نوسانات ماهانه در دشت روانسر-سنجابی

دوره مشاهداتی

نمودار ۱ الگوی ماهانه GWL را در دوره مشاهداتی (۱۹۹۲-۲۰۱۴) نشان می‌دهد. بر اساس نتایج نوسانات این متغیر، میانگین عمق GWL در پیژومترهای منطقه کوزران ۱۲ متر، در لُری ۷/۷۲ متر و در تم‌تم ۶/۵ متر بوده است. بالاترین عمق GWL در منطقه لُری، تم‌تم و کوزران در ماه‌های بهار (به ترتیب در عمق ۷/۱، ۷/۷ و ۱۱ متر) و پایین‌ترین عمق یعنی بدترین شرایط در ماه‌های فصل پاییز به ترتیب در عمق ۸/۲ و ۱۰ متری در لُری و تم‌تم، و عمق حدودی ۱۳ متری در تابستان و پاییز برای کوزران مشاهده شده است. این مقادیر نشان‌دهنده تأثیر بارندگی‌های فصلی بر منابع آب زیرزمینی، تاخیر تا زمان اثرگذاری آن بر منابع آب زیرزمینی و کاهش قابل توجه آن پس از افزایش تقاضا در فصول کشت است.



نمودار ۱. میانگین ماهانه عمق GWL دوره مشاهداتی در مناطق مختلف دشت روانسر-سنجابی

سناریوی SSP1-2.6


در دشت روانسر، میانگین عمق GWL در خوشه کوزران در آینده نزدیک (۲۰۲۶-۲۰۵۰) افزایش چشم‌گیری نسبت به مشاهدات (۱۳ متر) پیش‌بینی می‌شود. به‌ویژه در تابستان (۲/۶ متر) و پاییز (۳/۴ متر)، که نشان‌دهنده بهبود منابع آب زیرزمینی است. در آینده میانی (۲۰۵۱-۲۰۷۵)، به‌جز کاهش‌هایی در بهار (۱/۹ متر) و زمستان (تا ۱/۲ متر)، سایر ماه‌ها روند افزایشی دارند. در آینده دور (۲۱۰۰-۲۰۷۶) نیز به‌جز افت ۱ متری بهار، عمق GWL بهبود می‌یابد (نمودار ۲-الف). در خوشه لُری، آینده نزدیک نیز بهبود نسبی عمق GWL را نشان می‌دهد، با بیشترین افزایش در پاییز (۱/۷ متر، از ۸/۲ به ۶/۵ متر). در آینده میانی و دور، به‌جز کاهش متوسط ۰/۵ متری در بهار، در سایر فصول افزایش عمق GWL پیش‌بینی می‌شود؛ بیشینه افزایش پاییزه به ترتیب ۰/۸۱ و ۰/۶۵ متر پیش‌بینی می‌شود (نمودار ۲-ب). در تمام نیز عمق GWL در آینده نزدیک افزایش خواهد یافت. بیشترین افزایش در فصل پاییز به میزان ۲/۵ متر در آینده نزدیک و ۱/۵ متر در آینده‌های میانی و دور و در ماه دسامبر نسبت به دوره مشاهداتی رخ خواهد داد. هرچند در برخی ماه‌های بهار و تابستان (مستثنای دوره)، کاهش‌هایی پیش‌بینی می‌شود. بیشترین کاهش مربوط به فصل بهار آینده‌های میانی و دور است (به ترتیب ۱/۸ و ۰/۹۶ متر نسبت به ۸/۷ متر مشاهداتی) (نمودار ۲-ج).

سناریوی SSP2-4.5

در منطقه کوزران از دشت روانسر، آینده نزدیک با افزایش قابل‌توجه عمق GWL در پاییز (میانگین ۲/۲ متر) و افت ملایم در بهار (۰/۶ متر) همراه است. در آینده میانی، تمامی فصول با افزایش عمق GWL مواجه‌اند، به‌ویژه پاییز و زمستان به ترتیب با ۳/۹ و ۳/۷ متر افزایش. در آینده دور، به‌جز کاهش ۰/۶ تا ۱/۱ متری در بهار نسبت به مقدار مشاهداتی (۱۱ متر)، سایر فصول افزایش نشان می‌دهند؛ بیشترین آن در دسامبر با ۲/۲ متر بهبود نسبت به مقدار ۱۲/۷ متر دوره پایه است (نمودار ۲-الف). در لُری، به‌جز کاهش ۰/۲ و ۰/۵ متری در بهار آینده نزدیک و دور (نسبت به ۷/۱ متر مشاهداتی)، در سایر دوره‌ها افزایش عمق GWL پیش‌بینی می‌شود. بیشترین افزایش به ترتیب ۱، ۱/۴ و ۰/۹ متر در پاییز سه بازه آینده نسبت به مقدار مشاهداتی ۸/۲ متر پیش‌بینی می‌شود (نمودار ۲-ب). در تمام، به‌استثنای کاهش‌های جزئی در جولای آینده نزدیک (۰/۲ متر) و بهار و تابستان آینده دور (۰/۵ و ۰/۷ متر)، سایر زمان‌ها شاهد افزایش عمق GWL خواهند بود. بیشترین افزایش در آینده نزدیک و میانی در پاییز و زمستان به ترتیب با ۲ و ۱/۶ متر و سپس ۳/۱ و ۲/۶ متر نسبت به مقادیر ۱۰/۴ متر (پاییز) و ۹ متر (زمستان) مشاهداتی پیش‌بینی می‌شود. در آینده دور، زمستان با افزایش ۱/۵ متری بیشترین افزایش را خواهد داشت (نمودار ۲-ج).

سناریوی SSP5-8.5

در این سناریو، میانگین عمق GWL در سه منطقه مورد بررسی نشان‌دهنده روندی افزایشی در اغلب فصول و زیردوره‌های آینده است. در کوزران به‌جز فصل بهار آینده نزدیک با افت ملایم ۰/۵ متر، سایر فصول در آینده شاهد افزایش محسوس‌تری هستند. بیشترین افزایش در پاییز آینده نزدیک، میانی و دور به ترتیب ۱/۳، ۳/۶ و ۴ متر نسبت به مقدار مشاهداتی پاییز (۱۲/۸ متر) پیش‌بینی می‌شود و در زمستان آینده دور نیز افزایشی معادل ۴/۳ متر نسبت به ۱۱/۳ متر مشاهداتی پیش‌بینی می‌شود (نمودار ۲-الف). در لُری اکثر فصول، عمق GWL افزایش نشان می‌دهد. تنها کاهش جزئی (۰/۳ متر) در مارس و آوریل آینده نزدیک نسبت به ۷/۲ متر مشاهداتی پیش‌بینی می‌شود. بیشترین افزایش در پاییز به‌طور میانگین ۰/۸، ۱/۱ و ۱/۶ متر برای سه زیردوره نسبت به مقدار مشاهداتی ۸/۲ متر رخ خواهد داد (نمودار ۲-ب). در تمام به‌استثنای افت جزئی ۰/۳ متری در بهار آینده نزدیک نسبت به ۸/۷ متر مشاهداتی، سایر دوره‌ها با افزایش عمق GWL همراه‌اند. بالاترین افزایش در پاییز آینده نزدیک، میانی و دور به ترتیب ۱/۱، ۲/۶ و ۳/۱ متر نسبت به ۱۰/۴ متر پاییز دوره مشاهداتی پیش‌بینی می‌شود (نمودار ۲-ج).




نمودار ۲. تفاضل میانگین ماهانه عمق GWL آینده نسبت به مشاهدات در مناطق مختلف دشت روانسر-سنجایی تحت سناریوهای مختلف

روند نوسانات GWL در دشت روانسر-سنجایی

مشاهداتی

نمودار ۳ روند نوسانات GWL طی دوره مشاهداتی در سه منطقه لری، تم و کوزران دشت روانسر نشان می‌دهد. براساس این نمودار، هر سه منطقه با کاهش معنادار و شدیدی در سالهای ۱۹۹۲-۲۰۱۴ مواجه بوده‌اند. بر اساس نتایج آزمون روند در منطقه کوزران، مقدار احتمال کمتر از ۰/۰۰۰۱ و نرخ تغییر شیب ۰/۷۷- متر در سال بوده است که بیانگر یک روند کاهشی بسیار شدید و معنادار است. در منطقه تم، مقدار احتمال کمتر از ۰/۰۰۰۱ و با نرخ تغییر ۰/۶۸- متر در سال، شدت کاهش نسبت به کوزران حتی بیشتر بوده است. میانگین چاه‌های منطقه لری نیز با مقدار احتمال کمتر از ۰/۰۰۰۱ و نرخ تغییر ۰/۱۶- متر در سال را نشان می‌دهد که در مقایسه با دو منطقه دیگر، شدت کاهش کمتر ولی همچنان معنادار و قابل توجهی داشته است. به طور کلی، مشاهدات نشان‌دهنده یک افت بحرانی عمق GWL در دشت روانسر طی سال‌های گذشته است که احتمالاً ناشی از ترکیبی از برداشت بی‌رویه، تغییرات اقلیمی، و کاهش تغذیه آبخوان‌ها می‌باشد.



نمودار ۳. روند عمق GWL سالانه دوره مشاهداتی در مناطق مختلف دشت روانسر-سنجایی

سناریوی SSP1-2.6

بر اساس نمودار ۴-الف، در خوشه لری، طی آینده نزدیک، عدم وجود روند معنادار پیش‌بینی می‌شود (مقدار احتمال ۰/۲۷). در آینده میانی، روند کاهشی معناداری (احتمال کمتر از ۰/۰۰۰۱) با نرخ کاهش سالانه ۰/۰۱ متر پیش‌بینی می‌شود، در حالی که در آینده دور روندی افزایشی و معنادار (مقدار احتمال ۰/۰۰۰۱) با نرخ ۰/۰۶ متر در سال پیش‌بینی می‌شود. در خوشه تم (۴-ب)، آینده نزدیک کاهشی ضعیف و نزدیک به آستانه معنی‌داری (مقدار احتمال ۰/۰۷) را نشان می‌دهد. آینده میانی حاکی از یک روند کاهشی معنادار (احتمال ۰/۰۰۴) با نرخ ۰/۱۲- متر در سال است، اما آینده دور فاقد روند معنادار بوده و تنها افزایش ضعیفی نشان می‌دهد. در خوشه کوزران (۴-ج)، آینده نزدیک فاقد روند معنادار خواهد بود (مقدار احتمال ۰/۳۹)، در حالی که آینده میانی با روند کاهشی قوی و معنادار (مقدار احتمال کمتر از ۰/۰۰۰۱) همراه با نرخ کاهش ۰/۱۹ متر در سال همراه خواهد بود. در آینده دور، یک روند افزایشی معنادار (احتمال ۰/۰۰۸) با نرخ ۰/۲ متر در سال پیش‌بینی می‌شود.


سناریوی SSP2-4.5

در شرایط سناریوی SSP2-4.5، در آینده نزدیک خوشه لری با مقدار احتمال 0.001 روند افزایشی معنادار و نرخ تغییر شیب 0.07 متر در سال عمق GWL را نشان می‌دهد. در آینده میانی، روند معکوس شده و افتی (با مقدار احتمال 0.004) با نرخ تغییر 0.04 متر در سال پیش‌بینی می‌شود. در آینده دور، مقدار احتمال 0.6 به دست آمده که عدم وجود روند معنادار را نشان می‌دهد (نمودار ۴-الف). در خوشه تم‌تم، در آینده نزدیک، روند افزایشی معنادار (مقدار احتمال 0.007) با نرخ تغییر 0.19 متر در سال پیش‌بینی می‌شود، در حالی که در آینده میانی و دور، روند کاهشی معنادار با نرخ‌های تغییر 0.19 و 0.17 متر در سال غالب خواهد بود (نمودار ۴-ب). در منطقه کوزران، آینده نزدیک روند افزایشی غیرمعنادار دارد (مقدار احتمال 0.09). اما در آینده میانی و دور، روند کاهشی قوی و معنادار (مقدار احتمال 0.001) با نرخ‌های تغییر 0.22 و 0.17 متر در سال پیش‌بینی می‌شود (نمودار ۴-ج). این الگو بیانگر آن است که تحت SSP2-4.5، اگرچه در کوتاه‌مدت بهبود نسبی وجود دارد، در بلندمدت کاهش عمق GWL محتمل خواهد بود.

سناریوی SSP5-8.5

تحت سناریوی SSP5-8.5 نتایج متفاوتی در خوشه‌ها پیش‌بینی می‌شود. در خوشه لری، آینده نزدیک بدون روند معنادار (مقدار احتمال 0.94) است. اما در آینده میانی، روند افزایشی بسیار قوی (مقدار احتمال کمتر از 0.0001) با نرخ تغییر شیب 0.1 متر در سال پیش‌بینی می‌شود. آینده دور با روند منفی غیر معنادار نسبت به گذشته باقی خواهد ماند (نمودار ۴-الف). در خوشه تم‌تم، برای آینده نزدیک و میانی روند افزایشی معنادار (مقدار احتمال 0.002 و 0.001) با نرخ‌های تغییر 0.14 و 0.23 متر در سال پیش‌بینی می‌شود. در حالی که در آینده دور روند کاهشی غیرمعنادار (با مقدار احتمال 0.09) خواهد بود (نمودار ۴-ب). در خوشه کوزران، آینده نزدیک و میانی روند افزایشی قوی و معنادار (مقادیر احتمال 0.004 و 0.0001) با شیب 0.14 و 0.24 متر در سال خواهد بود، اما در آینده دور، تغییر منفی اما غیرمعنادار (مقدار احتمال 0.79 و شیب کاهشی 0.03) پیش‌بینی می‌شود (نمودار ۴-ج). این روندها نشان می‌دهد که تحت SSP5-8.5، عمق GWL در کوتاه‌مدت ممکن است افزایش داشته باشد، اما در بلندمدت پایداری آبخوان‌ها با تهدید روبه‌رو خواهد شد.

لازم به ذکر است که علی‌رغم اینکه سناریوی SSP1-2.6 به عنوان سناریوی خوش‌بینانه با کاهش گازهای گلخانه‌ای و اجرای سیاست‌های زیست‌محیطی مطرح است، و انتظار می‌رود وضعیت منابع آب زیرزمینی در این سناریو نسبت به SSP5-8.5 مطلوب‌تر باشد، اما نتایج مدل در برخی خوشه‌ها و بازه‌های زمانی نشان‌دهنده روندی معکوس است. این موضوع بیانگر آن است که واکنش GWL به سناریوهای اقلیمی، لزوماً خطی یا قابل پیش‌بینی صرف براساس شدت سناریو نیست، بلکه عوامل متعددی مانند الگوی زمانی و مکانی بارش، تغییرات دما و تبخیر و تعرق، رطوبت خاک و خصوصیات هیدروژئولوژیکی محلی در این واکنش‌ها مؤثر هستند. برای نمونه، در سناریوی SSP5-8.5 علیرغم افزایش دما، در برخی بازه‌ها بارش فصلی یا نگهداشت رطوبت خاک افزایش یافته و باعث تغذیه بهتر سفره‌های آب زیرزمینی شده است. همچنین، در SSP1-2.6 ممکن است با وجود کاهش انتشار گازهای گلخانه‌ای، کاهش تغذیه مؤثر یا توزیع غیربهمینه بارش منجر به افت GWL شود. بنابراین، رفتار سیستم آب زیرزمینی در مقیاس محلی می‌تواند تحت تأثیر ترکیب پیچیده‌ای از عوامل باشد و نیازمند تفسیرهای دقیق‌تر و محلی‌محور است.




نمودار ۴. روند عمق GWL سالانه آینده نزدیک، میانی و دور در مقایسه با مشاهدات در شرایط سناریوهای مختلف و دشت‌های روانسر-سنجایی

در نمودار ۵، روند تغییرات زمانی GWL طی دوره ۲۰۲۶ تا ۲۱۰۰ در هر سه منطقه دشت روانسر، تحت سه سناریوی اقلیمی مختلف نمایش داده شده است. نمودار ۵-الف، ۵-ب و ۵-ج به ترتیب تغییرات GWL را برای مناطق کوزران، لری و تم-تم تحت سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 را نمایش می‌دهند. بر اساس این شکل، در تمامی مناطق و در تمامی سناریوها، روندی کاهشی در GWL تا حدود دهه‌های ۲۰۶۰ و ۲۰۷۰ میلادی پیش‌بینی می‌شود که منطبق بر اثرات اولیه تغییرات اقلیمی و بهره‌برداری‌های انسانی است. با این حال، از دهه ۲۰۷۰ به بعد، به‌ویژه در نمودار ۵-ج، تحت سناریوی SSP5-8.5، افزایشی در مقادیر GWL رخ

خواهد داد که این روند در دهه‌های ۲۰۸۰ و ۲۰۹۰ نیز ب شکل مقطعی و ضعیف‌تر تداوم دارد. در مقابل، در سناریوی SSP1-2.6 چنین بازگشتی دیده نمی‌شود و روند کاهش سطح آب تا انتهای دوره پابرجاست.

این تفاوت معنادار را می‌توان به پدیده تأخیر زمانی (lag time) در واکنش آبخوان به تغییرات اقلیمی نسبت داد. به عبارتی دیگر، اثر تغییرات اقلیمی و مدیریتی - از جمله کاهش یا افزایش بارندگی، تغییر در دما، یا رطوبت خاک - لزوماً به صورت هم‌زمان در GWL ظاهر نمی‌شود، بلکه ممکن است با چند دهه تأخیر بروز کند. در واقع، سامانه‌های هیدروژئولوژیکی دارای حافظه دینامیکی هستند و رفتار آن‌ها تابعی از شرایط تجمعی گذشته است، نه صرفاً شرایط لحظه‌ای اقلیمی. بنابراین این تفاوت‌ها، نه تنها بیانگر اثرات مختلف سناریوهای اقلیمی است، بلکه نقش مهم lag time در برآورد بلندمدت منابع آب زیرزمینی را نشان می‌دهد. بنابراین، نمودارهای شکل ۶ علاوه بر مقایسه بین سناریویی، امکان تحلیل زمانی رفتار سفره آب زیرزمینی را فراهم کرده و بر این نکته تأکید دارد که تحلیل‌های کوتاه‌مدت نمی‌توانند واقعیت کاملاً پویایی از سیستم‌های آب زیرزمینی را آشکار سازند. برای دستیابی به درک صحیح‌تر از آینده منابع آب، تحلیل‌های درازمدت با لحاظ کردن تأخیر زمانی در پاسخ آبخوان، ضروری است.



نمودار ۵. تغییرات زمانی GWL در دشت روانسر - سنجابی طی سال‌های ۲۰۲۶ تا ۲۱۰۰ تحت سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5

بحث

نتایج پژوهش حاضر در راستای مطالعات گذشته بر توانمندی الگوریتم RF در مدل‌سازی عمق GWL تأکید دارد، اما در عین حال نوآوری‌هایی، بویژه در ساختار، متغیرهای ورودی، روش‌شناسی و مقیاس تحلیل به کار گرفته شده که آن را از تحقیقات پیشین متمایز می‌سازد. اغلب پژوهش‌های انجام‌شده در سطح کشور و بین‌المللی، نظیر مطالعات در آفریقای جنوبی (Elmotawakkil et al., 2024)، تونس (Trabelsi et al., 2022)، هند (Gupta et al., 2024; Saha et al., 2025) و ایران (Davoudi Moghaddam et al., 2020; Tavakoli et al., 2024)، استفاده از الگوریتم RF را تأیید کرده‌اند، اما اغلب این مطالعات با تمرکز محدود بر یک یا چند متغیر اقلیمی نظیر بارش یا دما، به ارزیابی عملکرد مدل پرداخته‌اند. در مقابل، این پژوهش با ترکیب هم‌زمان داده‌های پنج متغیر اقلیمی (بارش، دمای حداقل و حداکثر، رطوبت نسبی و رطوبت خاک) از تمام مدل‌های در دسترس CMIP6 برای منطقه مطالعه (۹۸ مدل)، گامی فراتر نهاده و تأثیر نسبی هریک از این عوامل را بر عمق GWL تحلیل کرده است.

یکی از تفاوت‌های کلیدی این تحقیق با مطالعات پیشین، استفاده از الگوریتم RFE برای انتخاب ویژگی‌های بهینه و تحلیل تدریجی تأثیر آن‌ها بر دقت مدل است. این روش، که به ندرت در پژوهش‌های مشابه داخلی به کار رفته، امکان ارزیابی علمی و کمی میزان اهمیت مدل‌های اقلیمی مختلف را در خوشه‌های متفاوت فراهم ساخته است. همانطور که اشاره شد استفاده از الگوریتم RFE در بستر مدل RF توانایی بالایی در تعمیم به مجموعه داده‌های مختلف و شناسایی عوامل کلیدی دارد (Ma et al., 2024; Bhadani et al., 2023). بطوریکه مدل NoRESM2-MM به عنوان قوی‌ترین مدل اقلیمی در سه خوشه‌ی لری، تهم و کوزران شناسایی شد و ترکیب آن با سایر مدل‌های CMIP6 موجب افزایش قابل توجه دقت پیش‌بینی گردید (تا ۹۸٪).

تحلیل جداول انتخاب ویژگی‌های برتر نشان داد که متغیر اقلیمی رطوبت خاک در هر سه خوشه بیشترین نقش را در پیش‌بینی تغییرات GWL دشت روانسر-سنجابی ایفا کرده. این یافته درحالی‌به‌دست آمده که بیشتر مطالعات پیشین داخلی و خارجی، متغیرهایی مانند بارش، دما و رطوبت نسبی را به‌عنوان عوامل اصلی مؤثر بر GWL معرفی کرده‌اند (پور صالحی و همکاران، ۱۴۰۰؛ ربیعی و کرمی، ۱۴۰۰؛ Iqbal و همکاران، ۲۰۲۰؛ Crosett و همکاران، ۲۰۲۳). بر خلاف پژوهش‌های قبلی در دشت روانسر-سنجابی (سلطانی و همکاران، ۱۴۰۱؛ سهرابی و همکاران، ۱۳۹۵) نیز که صرفاً به استفاده از متغیرهای بارش، دما و ذخایر برف اکتفا کرده‌اند، تحقیق حاضر با افزودن متغیر رطوبت خاک، ابعاد جدیدی از تأثیرگذاری اقلیم بر آب زیرزمینی را روشن ساخته است. این امر نشان‌دهنده نقش ویژه این پارامتر در مناطق نیمه‌خشک مانند دشت روانسر-سنجابی است. از میان سایر متغیرها، تنها بارش و در خوشه لری اثرگذاری کمتر از ۱٪ در دقت پیش‌بینی ۹۸٪ نشان داد. این تفاوت در دامنه متغیرهای ورودی، نقش کلیدی در افزایش دقت مدل و شناخت عمیق‌تر روابط علی داشته است. حضور مکرر این متغیر در میان ویژگی‌های منتخب، تأکیدی بر حساسیت عمق GWL به تغییرات رطوبت خاک در مقیاس فصلی و بلندمدت دارد. دلایل این تفاوت را می‌توان در چند جنبه مهم جست‌وجو کرد. ابتدا ویژگی‌های خاص هیدروژئولوژیکی دشت روانسر-سنجابی اهمیت رطوبت خاک را برجسته می‌سازد؛ چرا که تغذیه آبخوان‌ها در این منطقه عمدتاً از طریق نفوذ رطوبت خاک به لایه‌های زیرین صورت می‌پذیرد و بنابراین تغییرات رطوبت خاک نشانگر مستقیمی از فرآیند تغذیه و تأثیرات آن بر سطح آب زیرزمینی است. علاوه بر این، استفاده از الگوریتم RF به‌عنوان یک روش یادگیری ماشین با قابلیت مدل‌سازی روابط غیرخطی و تعیین اهمیت نسبی متغیرها، کمک کرده است تا سهم واقعی و مستقل رطوبت خاک از سایر متغیرهای اقلیمی با دقت بالا مشخص شود. همچنین، بهره‌گیری از مجموعه کاملی از مدل‌های CMIP6 برای تمام متغیرهای کلیدی اقلیمی (در مجموع ۹۸ مدل) به افزایش دقت ارزیابی اهمیت متغیرها کمک کرده و از سوگیری احتمالی ناشی از انتخاب محدود مدل‌ها و متغیرها جلوگیری نموده است. نکته مهم دیگر، به‌کارگیری الگوریتم K-means برای خوشه‌بندی مکانی داده‌ها، امکان تحلیل تفاوت‌های محلی و شناسایی متغیر برتر در هر خوشه را فراهم آورده است، که این خود موجب بهبود دقت و کارایی مدل در

مقیاس‌های مکانی متفاوت شده است. بنابراین، می‌توان نتیجه گرفت که رطوبت خاک به عنوان متغیر کلیدی مرتبط تر باید در آینده در اولویت مدل‌سازی‌ها و مدیریت منابع آب این منطقه قرار گیرند.

مطابق با مطالعه Hanane و همکاران (۲۰۲۲)، Ahmad و همکاران (۲۰۲۴)، Lal و همکاران (۲۰۲۴) و Goodarzi و همکاران، (۲۰۲۵)، استفاده از اعتبار سنجی K-fold در آموزش مدل‌ها، دقت پیش‌بینی را بهبود می‌بخشد و از بیش‌برازش جلوگیری می‌کند. در این تحقیق نیز با استفاده از اعتبار سنجی K-fold، مدل RF موفق شد تعمیم خوبی به داده‌ها داشته باشد و عملکرد قوی خود را حفظ کند. با این حال، باید توجه داشت که نتایج مربوط به خوشه لری مقداری افت دقت نسبت به سایر خوشه‌ها مواجه بود ($R=0.78$) و $NS=0.60$ (در مرحله تست). این موضوع احتمالاً ناشی از پویایی‌های بیشتر GWL در این ناحیه بوده است. با توجه به نتایج به‌دست‌آمده، مدل RF عملکرد مناسبی در پیش‌بینی عمق GWL نشان داده و توانست الگوهای فصلی و مکانی را با دقت قابل قبولی بازنمایی کند.

نتایج این مطالعه نشان داد که در برخی بازه‌ها، سناریوهای اقلیمی مختلف تأثیرات متفاوتی بر سطح آب زیرزمینی دارند. به‌طور مشخص، در منطقه کوزران، عمق GWL در آینده دور تحت SSP1-2.6 در فصل بهار تا ۱ متر کاهش خواهد یافت، در حالی که تحت SSP5-8.5 در پاییز همان دوره تا ۴ متر افزایش خواهد داشت. در خوشه لری نیز در حالی که SSP1-2.6 افتی حدود ۰/۵ متر در بهار آینده میانی ایجاد کرده، در SSP5-8.5 افزایش ۱/۶ متری در پاییز آینده دور پیش‌بینی شده است. الگوی مشابهی در خوشه تم‌تم مشاهده شد که تحت SSP1-2.6 در بهار آینده میانی افت ۱/۸ متری و در پاییز SSP5-8.5 افزایش تا ۳/۱ متر رخ داده است. این تضاد رفتاری را نمی‌توان صرفاً با شدت سناریو (شدت گرم شدن یا افزایش گازهای گلخانه‌ای) توضیح داد، بلکه باید آن را در بستر تفاوت‌های مکانی و فصلی در بارش، تبخیر-تعرق، تغذیه و به‌ویژه رطوبت خاک تحلیل کرد. در این پژوهش، اگرچه تبخیر-تعرق و تغذیه مستقیم مدل‌سازی نشده‌اند، اما رطوبت خاک (که در مطالعه حاضر بعنوان کلیدی‌ترین متغیر در ارتباط با GWL شناخته شد) به‌عنوان شاخصی از وضعیت هیدروکلیماتیک منطقه، مستقیماً وارد مدل RF شده است. برای تبیین علمی رفتار متضاد سناریوها در مقاله حاضر، مطالعات منطقه‌ای مستقل نیز مورد بررسی قرار گرفته‌اند. از جمله، مطالعه سلطانی و همکاران (۱۴۰۴ ب) که به بررسی تغییرات رطوبت خاک در دشت اسلام‌آباد پرداخته، نشان داد که در آینده میانی (۲۰۵۰-۲۰۷۵)، رطوبت خاک در SSP1-2.6 کاهش یافته در حالی که در SSP5-8.5 این کاهش بسیار ملایم‌تر خواهد بود. همچنین در آینده دور (۲۰۷۶-۲۱۰۰)، شیب تغییرات رطوبت خاک در SSP5-8.5 به سمت افزایش گرایش خواهد یافت. این رفتار می‌تواند به‌طور غیرمستقیم توجیه‌کننده بهبود GWL در برخی سناریوهای شدیدتر باشد. در مطالعه‌ای دیگر توسط سلطانی و همکاران (۱۴۰۴ الف) نتایج نشان داده که در آینده دور (۲۰۷۶-۲۱۰۰)، بیشترین افزایش GWL در پاییز تحت SSP5-8.5 رخ خواهد داد، در حالی که بیشترین افت در فصول بهار و تابستان تحت SSP1-2.6 پیش‌بینی شده است. این نتایج نیز به‌روشنی نشان‌دهنده تناقضات فصلی و رفتاری میان سناریوهای اقلیمی است. در مطالعه اقلیمی سلطانی و همکاران (۱۴۰۱) نیز در منطقه روانسر، الگوی بارندگی را در ماه‌های مختلف آینده غیرخطی و نوسانی گزارش کرده است. در دشت بیرجند، نیرومندفر و همکاران (۲۰۲۳) نشان دادند که افت سطح آب زیرزمینی در SSP1-2.6 بیشتر از SSP5-8.5 خواهد بود. در آبخوان کارستی خرم‌آباد، زیدعلی‌نژاد و همکاران (۲۰۲۴) گزارش کردند که تحت سناریوی SSP5-8.5 میانگین بارش ماهانه در دوره ۲۰۴۱-۲۰۶۰ به میزان ۲/۹ میلی‌متر افزایش خواهد یافت و دبی چشمه کیو نسبت به دوره پایه با و بدون در نظر گرفتن پوشش برف تا ۵۷ و ۳۶ لیتر بر ثانیه افزایش خواهد یافت، که نشان‌دهنده بهبود عملکرد سیستم کارستی در شرایط این سناریو است. در مطالعه‌ای در شهر هوشی‌مین ویتنام نیز خوی و همکاران (۲۰۲۲) روند افزایشی تغذیه آب زیرزمینی را در شرایط سناریوهای خوشبینانه و بدبینانه نتیجه گرفتند. این شواهد نشان می‌دهند که پیش‌بینی واکنش سطح آب زیرزمینی به تغییر اقلیم، مستلزم درک عمیق از ویژگی‌های هیدروژئولوژیکی محلی، نوع آبخوان (آبرفتی یا کارستی)، وضعیت رطوبت خاک و الگوی بارش فصلی است. بنابراین، تناقض‌های مشاهده‌شده در نتایج GWL تحت سناریوهای مختلف، نه‌تنها قابل توجیه، بلکه با مطالعات مشابه در مناطق

دیگر نیز همخوان است. از این رو، سناریوهای اقلیمی باید در بستر ویژگی‌های محلی و فصلی تفسیر شوند و تحلیل‌های حساسیت، در سطوح مکانی و زمانی، ضروری خواهد بود.

لازم به ذکر است که یکی از چالش‌های مهم در مدل‌سازی تغییرات عمق GWL، در دسترس نبودن داده‌های دقیق و مستمر مربوط به میزان برداشت و تغذیه آبخوان است. در بسیاری از مناطق کشور، اطلاعات برداشت تنها برای چاه‌های مجاز و عمدتاً به صورت سالانه ثبت شده‌اند، در حالی که حجم قابل توجهی از تخلیه توسط چاه‌های غیرمجاز انجام می‌شود که فاقد هرگونه آمار رسمی است. با این حال، در مدل‌سازی انجام شده، اثر تجمعی برداشت به صورت غیرمستقیم در مقادیر مشاهده شده عمق GWL در دوره مشاهداتی بازتاب یافته است. به عبارت دیگر، مدل RF از الگوهای گذشته عمق GWL که خود متأثر از برداشت و عوامل اقلیمی است، برای یادگیری استفاده کرده و این اثرات در خروجی مدل لحاظ شده‌اند، اگرچه به صورت غیرمستقیم. همچنین داده‌های تغذیه (نظیر نفوذ بارش، برگاب، و جریان‌های سطحی) به طور مستقیم اندازه‌گیری نمی‌شوند و تخمین آن‌ها نیازمند مدل‌های پیچیده هیدروژئولوژیکی است. از این رو، استفاده از مدل‌های داده‌محور مانند RF در این پژوهش، به عنوان روشی جایگزین و مبتنی بر داده‌های مشاهداتی عمق GWL، راهکاری عملی و قابل اتکا در غیاب اطلاعات بیلان آب زیرزمینی محسوب می‌شود. علاوه بر این، پیش‌بینی آینده‌نگر میزان برداشت تحت سناریوهای مختلف اقلیمی و مدیریتی مستلزم بهره‌گیری از مدل‌های ترکیبی (هیدرولوژیکی-اقتصادی- کاربری زمین) است که در چارچوب این مطالعه نگنجانده است.

یکی دیگر از چالش‌های مدل‌سازی تغییرات سطح آب زیرزمینی، لحاظ نکردن مقدار این متغیر در گام‌های زمانی پیشین به عنوان ورودی مدل است. در این مطالعه، با توجه به اینکه هدف، تمرکز بر تأثیر مستقیم متغیرهای اقلیمی بر عمق آب زیرزمینی بود، از این رو متغیر سطح آب زیرزمینی در گام‌های پیشین وارد مدل نشد تا وابستگی درون‌زمانی (temporal autocorrelation) حذف شده و تحلیل بر پایه ورودی‌های اقلیمی متمرکز شود. از سوی دیگر، از آنجا که این پژوهش عمق آب زیرزمینی (depth to GWL) را بررسی کرده و نه تراز مطلق آن (elevation of GWL)، به کارگیری lag زمانی با محدودیت‌هایی در هم‌ترازی و هم‌مقیاس‌سازی داده‌ها مواجه بود. با وجود این، باید اذعان کرد که وارد کردن مقادیر تأخیری (lag values) می‌تواند دقت مدل را بهبود بخشد، چراکه فرآیندهای برداشت و تغذیه آبخوان‌ها اغلب با تأخیر زمانی در GWL منعکس می‌شوند. از این رو، استفاده از سری‌های زمانی گذشته GWL در کنار داده‌های اقلیمی به عنوان ورودی مدل، می‌تواند به عنوان پیشنهاد مهمی برای مطالعات آتی مطرح شود.

روش ترکیبی استفاده شده در این تحقیق، مبتنی بر خوشه‌بندی مکانی با الگوریتم K-means و مدل‌سازی پیش‌بینی با الگوریتم RF، در کنار بهره‌گیری از داده‌های اقلیمی به‌روزشده CMIP6، مزایای قابل توجهی برای تحلیل تغییرات عمق GWL در اختیار قرار داده است. از جمله مهم‌ترین مزایای این رویکرد توانایی مدل RF در بازنمایی روابط پیچیده و غیرخطی میان متغیرهای اقلیمی و عمق GWL، که در محیط‌های نیمه‌خشک با دینامیک بالای منابع آب زیرزمینی، شناسایی متغیرهای کلیدی مؤثر، بدون نیاز به داده‌های پیچیده هیدروژئولوژیکی یا پارامترهای فیزیکی پرهزینه، کاربردپذیری روش K-means در تفکیک مکانی نواحی با رفتار هیدرولوژیکی متفاوت، به منظور بهبود دقت مدل در مقیاس‌های محلی و امکان استفاده از مجموعه کامل مدل‌های اقلیمی CMIP6 و ایجاد سناریوهای ترکیبی برای کاهش خطای پیش‌بینی است. با وجود این مزایا، برخی محدودیت‌ها نیز باید در تفسیر نتایج مدنظر قرار گیرند، از جمله عدم لحاظ مستقیم داده‌های برداشت آب زیرزمینی به دلیل نبود اطلاعات سری‌زمانی جامع و قابل اطمینان در سطح چاه‌ها یا خوشه‌ها، محدودیت در تعمیم‌پذیری مدل به سایر مناطق، مگر با بازآموزی مجدد، چالش‌های ذاتی داده‌های CMIP6 از جمله ناهمگنی و عدم قطعیت در خروجی‌ها و عدم لحاظ تغییرات کاربری اراضی، رشد جمعیت و سیاست‌های مدیریتی آینده به عنوان عوامل انسانی مؤثر بر عمق GWL. به طور کلی، رویکرد حاضر با تکیه بر قدرت الگوریتم‌های یادگیری ماشین و تنوع بالای داده‌های اقلیمی، ابزار قدرتمندی برای تحلیل روندهای آینده GWL در مناطق خشک و نیمه‌خشک ارائه کرد و می‌تواند به عنوان الگویی برای تحقیقات آتی توسعه یابد.

نتیجه گیری

این پژوهش با هدف پیش‌بینی تغییرات GWL در دشت روانسر-سنجایی، با ترکیب الگوریتم‌های K-means و RF و با بهره‌گیری از داده‌های اقلیمی CMIP6 انجام شد. ارزیابی ۹۸ مدل اقلیمی و انتخاب ویژگی‌های مؤثر با روش RFE نشان داد که مدل NorESM2-MM در هر سه خوشه‌ی لری، تم‌تم و کوزران به‌عنوان مؤثرترین مدل پایه شناخته شد؛ به‌طوری‌که دقت اولیه پیش‌بینی در این خوشه‌ها به‌ترتیب ۹۳، ۷۲ و ۸۲ درصد بود. با ترکیب تدریجی مدل‌های مکمل، دقت پیش‌بینی در تمامی خوشه‌ها به ۹۸ درصد افزایش یافت.

رطوبت خاک به‌عنوان مهم‌ترین متغیر تأثیرگذار بر تغییرات GWL شناسایی شد و بیشترین وزن را در مدل‌های پیش‌بینی به خود اختصاص داد. از نظر عملکرد مدل، خوشه کوزران بهترین نتایج را با ضریب همبستگی ۰/۹۲ و کارایی نش-ساتکلیف ۰/۸۳ نشان داد، در حالی که خوشه لری با ضرایب ۰/۷۸ و ۰/۶۰ عملکرد نسبتاً پایین‌تری نشان داد.

تحلیل روند تغییرات نشان داد که در دوره مشاهداتی (۱۹۹۲ تا ۲۰۱۴)، هر سه خوشه با روند کاهشی معنادار مواجه بودند؛ به‌طوری‌که بیشترین افت GWL در خوشه کوزران با شیب ۰-۰/۷۷۲ متر در سال و سپس در خوشه تم‌تم با ۰-۰/۶۸۲ متر در سال رخ داد، در حالی که منطقه لری کاهشی ملایم‌تر با نرخ ۰-۰/۱۶۰ متر در سال داشت.

بر اساس نتایج سناریوهای اقلیمی، در سناریوی SSP1-2.6، در آینده نزدیک بهبود نسبی مشاهده شد و در آینده دور روند افزایشی معناداری پیش‌بینی گردید؛ هرچند در آینده میانی بیشترین افت با نرخ ۰-۰/۱۹۳ متر در سال در خوشه کوزران پیش‌بینی می‌شود. در سناریوی SSP2-4.5، به‌رغم روند افزایشی کوتاه‌مدت، در آینده میانی، بیشترین کاهش در کوزران با نرخ ۰-۰/۲۲۳ متر در سال پیش‌بینی گردید. در سناریوی SSP5-8.5، روند افزایشی قوی در آینده نزدیک و میانی پیش‌بینی شد؛ به‌طوری‌که در کوزران در آینده میانی نرخ تغییر ۰/۲۳۸ متر در سال گزارش شد، ولی در آینده دور نشانه‌هایی از ناپایداری منابع آب مشاهده گردید. از منظر نوسانات فصلی، بیشترین بهبود GWL در فصل پاییز پیش‌بینی شد؛ به‌ویژه در خوشه کوزران که تحت سناریوی SSP5-8.5 در آینده دور، افزایش عمق GWL به میزان حدود ۴ متر نسبت به دوره مشاهداتی مشاهده می‌شود. در مقابل، بیشترین کاهش عمق GWL مربوط به فصل بهار خواهد بود؛ به‌طوری‌که در خوشه تم‌تم تحت سناریوی SSP2-4.5 در آینده میانی، افتی به میزان ۱/۸۳ متر نسبت به دوره مشاهداتی پیش‌بینی شد.

در مجموع، نتایج این تحقیق بیانگر آن است که اگرچه در کوتاه‌مدت امکان بهبود نسبی GWL در فصل‌های مرطوب وجود دارد، اما در بلندمدت، به‌ویژه در فصل بهار و در دوره‌های آینده میانی و دور، منابع آب زیرزمینی دشت روانسر با تهدید جدی کاهش و ناپایداری مواجه خواهد شد. این نتایج ضرورت برنامه‌ریزی مدیریتی سازگار با تغییرات اقلیمی را بیش از پیش برجسته می‌سازد.

منابع

- پورصالحی، فاطمه؛ خاشعی سیوکی، عباس و هاشمی، سید رضا (۱۴۰۰). بررسی عملکرد الگوریتم جنگل تصادفی در پیش‌بینی نوسانات سطح ایستابی در مقایسه با دو مدل درخت تصمیم و شبکه عصبی مصنوعی (مطالعه موردی: آبخوان آزاد دشت بیرجند). *اكوهیدرولوژی*، ۱۸(۴)، ۹۶۱-۹۷۴. <https://doi.org/10.22059/ije.2022.327263.1526>
- ربیعی، مبینا و کرمی، حجت (۱۴۰۱). تخمین تغییرات زمانی و مکانی سطح آب زیرزمینی با تلفیق مدل‌های هوشمند و روش‌های زمین آماری (دشت سمنان)، *آبیاری و آب ایران*، ۱۲(۳)، ۲۴۲-۲۲۰. <https://doi.org/10.22125/iwe.2022.146404>
- سراج ابراهیمی، رضا؛ اسلامیان، سعید و زارعیان، محمد جواد (۱۴۰۱). پیش‌بینی اثرات تغییر اقلیم بر منابع آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت تالش). *مدیریت آب و آبیاری*، ۱۲(۳)، ۵۶۱-۵۷۹. <https://doi.org/10.22059/jwim.2022.340171.975>

سلطانی، کبری؛ فاطمی، سید احسان؛ معصوم پور سماکوش، جعفر و حافظ پرست مودت، مریم (۱۴۰۴ الف). روش نوین در پیش‌بینی تغییرات آبی سطح آب‌زیرزمینی با الگوریتم‌های K-means و جنگل تصادفی با داده‌های اقلیمی CMIP6 در دشت اسلام‌آباد غرب. *تحقیقات آب و خاک ایران*. <https://doi.org/10.22059/ijswr.2025.392467.669910>

سلطانی، کبری؛ معصوم پور، جعفر؛ فاطمی، سید احسان و حافظ پرست مودت، مریم (۱۴۰۴ ب). پیش‌بینی پایدار رطوبت خاک در دشت اسلام‌آباد: رویکرد یادگیری ماشین برای انتخاب مدل‌های اقلیمی و ریزمقیاس‌نمایی، *جغرافیا و پایداری محیط*، ۱۵(۲)، ۴۳-۶۱. <https://doi.org/10.22126/ges.2025.11696.2832>

سلطانی، میلاد؛ سلیمانی، کریم؛ جلیلی، خلیل؛ ساداتی نژاد، سید جواد و شکران، فاطمه (۱۴۰۱). بررسی تغییرات سطح آب زیرزمینی دشت روانسر-سنجایی تحت سناریوهای اقلیمی CIMP5. *مهندسی اکوسیستم بیابان*، ۱۱(۳۷)، ۷۱-۸۴. <https://doi.org/10.22052/deej.2023.248647.1001>

سلیمی، نازنین؛ فرامرزی، مرزبان؛ توکلی، محسن و فتحی زاد، حسن (۱۴۰۲). استفاده از الگوریتم‌های یادگیری ماشین برای مدل‌سازی منابع آب زیرزمینی در دشت موسیان استان ایلام. *تحلیل فضایی مخاطرات محیطی*، ۱۰(۳)، ۱۶۳-۱۸۲. <http://dx.doi.org/10.61186/jsteh.10.3.163>

سهرابی، مهدی؛ محمدزاده، حسین و اسکندری، جواد (۱۳۹۵). بررسی کمی منابع آب زیرزمینی محدوده مطالعات روانسر کرمانشاه. *دومین کنفرانس بین‌المللی علوم زمین و توسعه شهری*، تبریز. <https://civilica.com/doc/526390>

عسکری، جیدان و اکدر نژاد، اصلا (۱۴۰۱). مدلسازی آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت دزفول-اندیمشک)، *پژوهش در بهداشت محیط*، ۱۸(۲)، ۱۷۱-۱۶۰. <https://doi.org/10.22038/jreh.2022.61396.1457>

فاطمی، سید احسان؛ قیابیان، رسول و پاک‌بین، مژگان (۱۳۹۷). پیش‌بینی عمق آب زیرزمینی با استفاده از مدل طیف سنجی سری‌های زمانی. *دانش آب و خاک*، ۲۸(۱)، ۱۴۵-۱۵۸. https://water-soil.tabrizu.ac.ir/article_7600.html

الماسی، آرینا؛ فاطمی، سید احسان و اقبال زاده، افشین (۱۴۰۳). پیش‌بینی بارندگی ماهانه ایستگاه سینوپتیک کرمانشاه تحت سناریوهای اجتماعی-اقتصادی گزارش ششم تغییر اقلیم. *فناوری‌های پیشرفته در بهره‌وری آب*، ۴(۱)، ۴۰-۶۴. <http://dx.doi.org/10.22126/atwe.2024.10245.1097>

مختاری، داود؛ ابراهیمی، حمید و سلمانی، سعید (۱۳۹۸). مدل‌سازی خطر وقوع فروزش‌ست زمین با استفاده از الگوریتم جنگل تصادفی (مطالعه موردی: حوزه آبریز دشت تسوج). *سنجش‌ازدور و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۱۰(۴)، ۹۳-۱۰۵. <http://dx.doi.org/10.226767082.1398.10.3.6.7>

نوروزی قوش‌بلاغ، حسین و ندیری، عطاالله (۱۳۹۷). پیش‌بینی سطح آب زیرزمینی دشت بوکان با استفاده از مدل‌های منطق فازی، جنگل تصادفی و شبکه عصبی. *مرتع و آب‌خیزداری*، ۷۱(۳)، ۸۲۹-۸۴۵. <https://doi.org/10.22059/irwm.2018.68924>

Ahmad, N., & Nath, V. (2024). Evaluating Nine Machine Learning Algorithms for GaN HEMT Small Signal Behavioral Modeling through K-fold Cross-Validation. *Engineering, Technology & Applied Science Research*, 14(4), 15784-15790. <https://doi.org/10.48084/etasr.7726>

Ahmadi, A., Olyaei, M., Heydari, Z., Emami, M., Zeynolabedin, A., Ghomlaghi, A., ... & Sadegh, M. (2022). Groundwater level modeling with machine learning: a systematic review and meta-analysis. *Water*, 14(6), 949. <https://doi.org/10.3390/w14060949>

Almasi, A., Fatemi, S. E., & Eghbalzadeh, A. (2024). The prediction of monthly rainfall in Kermanshah Synoptic Station under the social-economic scenarios of the sixth climate change report. *Advanced Technologies in Water Efficiency*, 4(1), 40-64. <https://doi.org/10.22126/atwe.2024.10245.1097> (In Persian).

Amiraslani, F., & Caiserman, A. (2020). *Contemporary water resource management and its role in tackling land degradation and desertification in Iran*. Standing up to Climate Change: Creating Prospects for a Sustainable Future in Rural Iran, Springer Cham, 65-87. https://doi.org/10.1007/978-3-030-50684-1_4

Askari, J. & Egdernezhad, A. (2022). Groundwater modeling using artificial intelligence methods (Case study: Dezful-Andimeshk plain). *Journal of Research in Environmental Health*, 8(2), 160-171. doi: 10.22038/jreh.2022.61396.1457 (In Persian).

Bamal, A., Uddin, M. G., & Olbert, A. I. (2024). Harnessing machine learning for assessing climate change influences on groundwater resources: a comprehensive review. *Heliyon*, 10 (17), e37073. <https://doi.org/10.1016/j.heliyon.2024.e37073>

- Bhadani, V., Singh, A., Kumar, V., & Gaurav, K. (2023, May). *Machine learning models to predict groundwater level in a Semi-arid river catchment, Central India*. In EGU General Assembly Conference Abstracts (pp. EGU-12629). <https://doi.org/10.5194/egusphere-egu23-12629>
- Biswas, A., Sarkar, S., Das, S., Dutta, S., Roy Choudhury, M., Giri, A., Bera, B., Bag, K., Mukherjee, B., Banerjee, K., Gupta, D., & Paul, D. (2025). Water scarcity: A global hindrance to sustainable development and agricultural production – A critical review of the impacts and adaptation strategies. *Cambridge Prisms: Water*, 3, e4. <https://doi.org/10.1017/wat.2024.16>
- Boo, K. B. W., El-Shafie, A., Othman, F., Khan, M. M. H., Birima, A. H., & Ahmed, A. N. (2024). Groundwater level forecasting with machine learning models: A review. *Water Research*, 252, 121249. <https://doi.org/10.1016/j.watres.2024.121249>
- Collaud Coen, M., Andrews, E., Bigi, A., Martucci, G., Romanens, G., Vogt, F. P., & Vuilleumier, L. (2020). Effects of the prewhitening method, the time granularity, and the time segmentation on the Mann–Kendall trend detection and the associated Sen's slope. *Atmospheric measurement techniques*, 13(12), 6945-6964.
- Crossett, C. C., Hodgkins, G. A., Menk, H., Dupigny-Giroux, L. A. L., Dudley, R., Lemcke-Stampone, M., & Hammond, J. (2023). Groundwater recharge in northern New England: Meteorological drivers and relations with low streamflow. *Hydrological Processes*, 37(3), e14832. <https://doi.org/10.1002/hyp.14832>
- Darabi Cheghabaleki, S., Fatemi, S. E., & Hafezparast Mavadat, M. (2024). Enhancing spatial streamflow prediction through machine learning algorithms and advanced strategies. *Applied Water Science*, 14(6), 110. <https://doi.org/10.1007/s13201-024-02154-x>
- Das, S., Datta, P., Sharma, D., & Goswami, K. (2022). Trends in temperature, precipitation, potential evapotranspiration, and water availability across the teesta river basin under 1.5 and 2 C temperature rise scenarios of CMIP6. *Atmosphere*, 13(6), 941, Doi: <https://doi.org/10.3390/atmos13060941>
- Davoudi Moghaddam, D., Rahmati, O., Haghizadeh, A., & Kalantari, Z. (2020). A modeling comparison of groundwater potential mapping in a mountain bedrock aquifer: QUEST, GARP, and RF models. *Water*, 12(3), 679. <https://doi.org/10.3390/w12030679>
- Elmotawakkil, A., Sadiki, A., & Enneya, N. (2024). Predicting groundwater level based on remote sensing and machine learning: a case study in the Rabat-Kénitra region. *Journal of Hydroinformatics*, 26(10), 2639-2667. <https://doi.org/10.2166/hydro.2024.494>
- Farasati, M., Seyedian, M., & Fathaabadi, A. (2024). Predicting soil hydraulic conductivity using random forest, SVM, and LSSVM models. *Natural Resource Modeling*, 37(4), e12407. <https://doi.org/10.1111/nrm.12407>
- Fatemi, S. E., & Parvini, H. (2022). The impact assessments of the ACF shape on time series forecasting by the ANFIS model. *Neural Computing and Applications*, 34(15), 12723-12736. <https://doi.org/10.1007/s00521-022-07140-5>
- Fatemi, S., Ghobadian, R. and Pakbin, M. (2018). Forecasting Groundwater Depth Using Time series Spectral Analysis. *Water and Soil Science*, 28(1), 145-158. https://water-soil.tabrizu.ac.ir/article_7600.html (In Persian)
- Goodarzi, M. R., Bafrouei, H. B., & Vazirian, M. (2025). Insight into groundwater level prediction with feature effectiveness: comparison of machine learning and numerical methods. *Hydrology Research*, 56(1), 74-92. <https://doi.org/10.2166/hr.2024.135>
- Gupta, S. K., Sahoo, S., Sahoo, B. B., Srivastava, P. K., Pateriya, B., & Santosh, D. T. (2024). Prediction of groundwater level changes based on machine learning technique in highly groundwater irrigated alluvial aquifers of south-central Punjab, India. *Physics and Chemistry of the Earth*, 135, 103603. <https://doi.org/10.1016/j.pce.2024.103603>
- Hanane, T., Ahmed, A., & Abdellah, A. (2023). Groundwater potentiality mapping using machine learning algorithms BouSbaa area, Marrakech, Morocco. <https://doi.org/10.21203/rs.3.rs-2645081/v1>
- Hirko, D. B., Du Plessis, J. A., & Bosman, A. (2025). Review of machine learning and WEAP models for water allocation under climate change. *Earth Science Informatics*, 18(3), 310. <https://doi.org/10.1007/s12145-025-01820-1>
- Igwebuike, N., Ajayi, M., Okolie, C., Kanyerere, T., & Halihan, T. (2025). Application of machine learning and deep learning for predicting groundwater levels in the west coast aquifer system, south africa. *Earth Science Informatics*, 18(1), 1-18. <https://doi.org/10.1007/s12145-024-01623-w>
- Iqbal, M., Naeem, U. A., Ahmad, A., Ghani, U., & Farid, T. (2020). Relating groundwater levels with meteorological parameters using ANN technique. *Measurement*, 166, 108163. <https://doi.org/10.1016/j.measurement.2020.108163>
- Khan, J., Lee, E., Balobaid, A. S., & Kim, K. (2023). A comprehensive review of conventional, machine learning, and deep learning models for groundwater level (GWL) forecasting. *Applied Sciences*, 13(4), 2743. <https://doi.org/10.3390/app13042743>

- Khoi, D. N., Sam, T. T., Chi, N. T. T., Linh, D. Q., & Nhi, P. T. T. (2022). Impact of future climate change on river discharge and groundwater recharge: a case study of Ho Chi Minh City, Vietnam. *Journal of Water and Climate Change*, 13(3), 1313-1325. <https://doi.org/10.2166/wcc.2022.379>
- Lal, A., Sharan, A., Sharma, K., Ram, A., Roy, D. K., & Datta, B. (2024). Scrutinizing different predictive modeling validation methodologies and data-partitioning strategies: new insights using groundwater modeling case study. *Environmental Monitoring and Assessment*, 196(7), 623. <https://doi.org/10.1007/s10661-024-12794-w>
- Ma, Y., Koch, J., & Maxwell, R. M. (2024). Using random forests to explore the feasibility of groundwater knowledge transfer between the contiguous US and Denmark. *Environmental Research Communications*, 6(12), 121005. <https://doi.org/10.1088/2515-7620/ad9b08>
- Madani, A., & Niyazi, B. (2023). Groundwater potential mapping using remote sensing and random forest machine learning model: A case study from lower part of Wadi Yalamlam, Western Saudi Arabia. *Sustainability*, 15(3), 2772. <https://doi.org/10.3390/su15032772>
- Madani, K. (2014). Water management in Iran: what is causing the looming crisis? *Journal of environmental studies and sciences*, 4, 315-328. <https://doi.org/10.1007/s13412-014-0182-z>
- Moeeni, H., Bonakdari, H., & Fatemi, S. E. (2017). Stochastic model stationarization by eliminating the periodic term and its effect on time series prediction. *Journal of hydrology*, 547, 348-364. <https://doi.org/10.1016/j.jhydrol.2017.02.012>
- Niroumand Fard, F., Khashei Siuki, A., Hashemi, S. R., & Ghorbani, K. (2023). Evaluation of the effect of scenarios in the 6th report of IPCC on the prediction groundwater level using the non-linear model of the input-output time series. *Environmental Monitoring and Assessment*, 195(11), 1359. <https://doi.org/10.1007/s10661-023-11872-9>
- Norouzi, H. & Nadiri, A. (2018). Groundwater Level Prediction of Boukan Plain using Fuzzy Logic, Random Forest and Neural Network Models. *Journal of Range and Watershed Managment*, 71(3), 829-845. doi: 10.22059/jrwm.2018.68924 (In Persian).
- Norouzi, H., & Shahmohammadi-Kalalagh, S. (2019). Locating groundwater artificial recharge sites using random forest: a case study of Shabestar region, Iran. *Environmental Earth Sciences*, 78(13), 380. <https://doi.org/10.1007/s12665-019-8381-2>
- Nouri, M., Homaee, M., Pereira, L. S., & Bybordi, M. (2023). Water management dilemma in the agricultural sector of Iran: A review focusing on water governance. *Agricultural Water Management*, 288, 108480. <https://doi.org/10.1016/j.agwat.2023.108480>
- Parvizi, Y., & Fatehi, S. (2024). Modeling and digital mapping of soil quality indicators in different land uses (a case study: Ravansar-Sanjabi Plain, Kermanshah). *Environmental Monitoring and Assessment*, 196(2), 184. <https://doi.org/10.1007/s10661-024-12349-z>
- Poursalehi, F., Khashei Siuki, A. & Hashemi, S. R. (2021). Investigating the performance of random forest algorithm in predicting water table fluctuations Compared with two models of decision tree and artificial neural network (Case study: unconfined aquifer of Birjand plain). *Journal of Ecohydrology*, 8(4), 961-974. doi: 10.22059/ije.2022.327263.1526 (In Persian).
- Rabiee, M. and karami, H. (2022). Estimation of Temporal and Spatial Variations of Groundwater Level by Combining Intelligent Models and Geostatistical Methods (Semnan Plain). *Irrigation and Water Engineering*, 12(3), 220-242. doi: 10.22125/iwe.2022.146404 (In Persian).
- Rizwan, A., Iqbal, N., Khan, A. N., Ahmad, R., & Kim, D. H. (2021). Toward effective pattern recognition based on enhanced weighted K-mean clustering algorithm for groundwater resource planning in point cloud. *IEEE Access*, 9, 130154-130169. <https://doi.org/10.1109/ACCESS.2021.3111112>
- Saha, N. C., Mondal, J. K., & Banerjee, A. (2025). *Applicability of random forest model for predicting groundwater table in Birbhum District, West Bengal India*. In Recent Advancements in Computational Intelligence and Design Engineering (pp. 79-84). CRC Press.
- Salimi, N., Faramarzi, M., Tavakoli, M., & Fathizad, H. (2023). Using machine learning algorithms for modeling groundwater resources in arid rangeland western Iran. *Journal of Spatial Analysis Environmental Hazards*, 10(3), 163-182. doi: 10.61186/jsaeh.10.3.163. (In Persian).
- Sanchez, A. G., & Capurata, R. E. O. (2024). Assessment of Supervised Machine Learning Techniques for Predicting Groundwater Availability in Mexican Aquifers. *International Journal of Combinatorial Optimization Problems and Informatics*, 15(4), 7. <https://doi.org/10.61467/2007.1558.2024.v15i4.498>
- Seraj Ebrahimi, R., Eslamian, S. and Zareian, M. J. (2022). Predicting the effects of climate change on groundwater resources using artificial intelligence methods (Case study: Talesh plain). *Water and Irrigation Management*, 12(3), 561-579. doi: 10.22059/jwim.2022.340171.975 (In Persian).

- Shah, S. A., & Kiran, M. (2021). Mann-Kendall test: Trend analysis of temperature, rainfall, and discharge of Ghotki feeder canal in district Ghotki, Sindh, Pakistan. *Environment & Ecosystem Science (EES)*, 5(2), 137-142. <http://doi.org/10.26480/ees.02.2021.137.142>
- Sohrabi, M., Mohammadzadeh, H., & Eskandari, J. (2016, May). Quantitative assessment of groundwater resources in the Ravansar region, Kermanshah. The 2nd International Congress on Earth Sciences and Urban Development, Tabriz. <https://civilica.com/doc/526390> (In Persian).
- Soltani, K. , Fatemi, S. E. , Masoompour Samakosh, J. and Hafezparast Mavadat, M. (2025). A Novel Method for Predicting Future Changes in Groundwater Level Using K-means and Random Forest Algorithms with CMIP6 Climate Data in the Eslamabad West Plain. *Iranian Journal of Soil and Water Research* <https://doi.org/10.22059/ijswr.2025.392467.669910> (In Persian).
- Soltani, K., Masoompour Samakosh, J., Fatemi, S. E., & Hafezparast Mavadat, M. (2025). Sustainable Soil Moisture Prediction in the Eslamabad Plain: A Machine Learning Approach to Climate Model Selection and Downscaling. *Geography and Environmental Sustainability*, 15(2), 43-61. <http://dx.doi.org/10.22126/ges.2025.11696.2832> (In Persian).
- Soltani, M. , solaimani, K. , jallili, K. , Sadatinejad, S. J. and Shokrian, F. (2023). Investigating Alterations in the underground water level of Ravansar- Sanjabi Plain under CIMP5 climate scenarios. *Desert Ecosystem Engineering*, 11(37), 71-84. <http://dx.doi.org/10.22052/deej.2023.248647.1001> (In Persian).
- Soltani, M., solaimani, K., jallili, K., Sadatinejad, S. J. and Shokrian, F. (2023). Investigating Alterations in the underground water level of Ravansar- Sanjabi Plain under CIMP5 climate scenarios. *Desert Ecosystem Engineering*, 11(37), 71-84. doi: 10.22052/deej.2023.248647.1001
- Tavakoli, M., Motlagh, Z. K., Sayadi, M. H., Ibraheem, I. M., & Youssef, Y. M. (2024). Sustainable Groundwater management using machine learning-based DRASTIC model in urbanizing riverine region: A case study of Kerman Province, Iran. *Water*, 16(19), 2748. <https://doi.org/10.3390/w16192748>
- Trabelsi, F., Bel Hadj Ali, S., & Lee, S. (2022). Comparison of novel hybrid and benchmark machine learning algorithms to predict groundwater potentiality: case of a drought-prone region of Medjerda Basin, northern Tunisia. *Remote Sensing*, 15(1), 152. <https://doi.org/10.3390/rs15010152>
- Uc-Castillo, J. L., Marín-Celestino, A. E., Martínez-Cruz, D. A., Tuxpan-Vargas, J., & Ramos-Leal, J. A. (2023). A systematic review and meta-analysis of groundwater level forecasting with machine learning techniques: Current status and future directions. *Environmental Modelling & Software*, 168, 105788. <https://doi.org/10.1016/j.envsoft.2023.105788>
- Wang, F., Shao, W., Yu, H., Kan, G., He, X., Zhang, D., & Ren, M. (2020). Re-evaluation of the power of the Mann-Kendall test for detecting monotonic trends in hydrometeorological time series. *Frontiers in Earth Science*, 8, 14. <https://doi.org/10.3389/feart.2020.00014>
- Wang, P. (2024, December). *Prediction of the Groundwater Levels Based on Random Forest Regression Algorithm*. In 2024 IEEE 4th International Conference on Information Technology, Big Data and Artificial Intelligence, 4, 214-217. <https://doi.org/10.1109/ICIBA62489.2024.10869277>
- Wu, W. Y., Lo, M. H., Wada, Y., Famighetti, J. S., Reager, J. T., Yeh, P. J. F., Ducharne, A., & Yang, Z. L. (2020). Divergent effects of climate change on future groundwater availability in key mid-latitude aquifers. *Nature communications*, 11(1), 3710. <https://doi.org/10.1038/s41467-020-17581-y>
- Zeydalinejad, N., Pour-Beyranvand, A., Nassery, H. R., & Ghazi, B. (2025). Evaluating climate change impacts on snow cover and karst spring discharge in a data-scarce region: a case study of Iran. *Acta Geophysica*, 73(1), 831-854. <https://doi.org/10.1007/s11600-024-01400-9>