

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

Abstract

This study predicts groundwater level (GWL) variations in the Eslamabad plain using the Random Forest (RF) and CMIP6 climate data. GWL data from 20 wells (1997–2014) were collected and, after processing and clustering using the K-Means, modeling was conducted for different climate scenarios in three regions: Jangeh, Barfabab, and Bureg.

The results showed that in the observational period, Barfabab, with variations of 8.7 to 10.2 meters, had the best GWL values, while the Bureg, with 15.5 to 17.3 meters, had the worst. The highest availability was observed in spring and the lowest depth in Fall. Predictions indicate that in the distant future (2076–2100), under the SSP5-8.5 scenario, the greatest GWL increase (3 to 3.5 meters) will occur in Jangeh in Fall. In SSP1-2.6, the greatest decline in Bureg, with a drop of 3.5 to 4 meters, is projected for spring and summer. Under the SSP1-2.6 and SSP2-4.5 scenarios, conditions will be more stable in the distant future.

During the observational period, GWL showed a decreasing trend in all regions, with the highest annual decline (1 meter) recorded in Barfabab. In SSP1-2.6, the GWL decrease in the near future in Bureg (-0.21 m/year) and in the mid-future in Jangeh (-0.14 m/year) will continue. In SSP2-4.5, this decrease in the distant future is significant in all regions, with the highest value (-0.16 m/year) in Bureg. The RF model performed very well ($R = 0.97$, NSE between 0.89 and 0.98), and the NorESM2-MM model improved prediction accuracy up to 99.5%.

Keywords: CMIP6, Eslamabad-e-Gharb, Groundwater level, Modeling, Random Forest

Extended abstract

Introduction:

Effective groundwater resource management in arid and semi-arid regions is paramount, especially in the context of climate change. The depletion of groundwater levels (GWL) due to excessive extraction, declining precipitation, and rising temperatures poses severe challenges for agricultural sustainability and potable water availability. Predicting GWL variations is crucial for ensuring long-term water security. Recent advancements in machine learning and climate modeling have significantly enhanced prediction accuracy, facilitating informed decision-making in water resource management. This study employs the Random Forest (RF) algorithm in conjunction with CMIP6 climate data to predict GWL variations in the Eslamabad-e-Gharb plain, incorporating the K-Means clustering method to enhance model precision.

Materials and Methods:

The study area, Eslamabad-e-Gharb plain, situated in western Iran, experiences a semi-humid cold climate with an average annual precipitation of 463 mm. Data were collected from 20 observation wells spanning the period 1997–2014. Historical GWL data were sourced from the national water data repository, while soil moisture data from MERRA2 and future climate projections from CMIP6 models were integrated into the analysis.

The K-Means clustering technique was utilized to classify observation wells into three distinct clusters: Jangeh, Barfabab, and Bureg. The RF algorithm was employed to identify the most relevant CMIP6 soil moisture models for predicting GWL under three future climate scenarios: SSP1-2.6, SSP2-4.5, and SSP5-8.5. The models were trained using 80% of the dataset, with the remaining 20% allocated for validation. Model performance was evaluated using Nash-Sutcliffe Efficiency (NSE), correlation coefficient (R), mean absolute error (MAE), and normalized root mean square error (NRMSE).

Results and Discussion:

During the observational period (1997–2014), all study regions exhibited a pronounced downward trend in GWL. The most significant decline was recorded in Barfabab, with an annual reduction of 1 meter, followed by Bureg (0.715 m/year) and Jangeh (0.59 m/year).

Under the SSP1-2.6 scenario, GWL is projected to continue its decline in the near future, with Bureg experiencing a substantial reduction (-0.21 m/year). In the mid-term period (2051–2075), Jangeh is anticipated to undergo the most pronounced decrease (-0.14 m/year). The SSP2-4.5 scenario suggests a significant long-term decline across all regions, with Bureg exhibiting the steepest decrease (-0.16 m/year).

Future projections under SSP5-8.5 indicate a notable GWL increase in Jangeh (3 to 3.5 meters) in the late 21st century (2076–2100). Conversely, under SSP1-2.6, Bureg is expected to experience the most substantial decline (3.5 to 4 meters) in spring and summer during the mid-21st century. The low-emission scenarios (SSP1-2.6 and SSP2-4.5) suggest a more stabilized GWL condition in the distant future.

The RF model exhibited high predictive accuracy, with an R-value of 0.97 and NSE ranging from 0.89 to 0.98. The NorESM2-MM model emerged as the most reliable climate model for GWL prediction, enhancing forecasting precision by up to 99.5%. The findings underscore the pivotal role of climate change in GWL depletion within the Eslamabad-e-Gharb plain. Even under the most optimistic climate scenario (SSP1-2.6), GWL is projected to decline further, highlighting the necessity of implementing sustainable water management strategies. The study reinforces that machine learning models, particularly RF, surpass traditional numerical models in GWL prediction.

The integration of K-Means clustering with RF enhanced model precision by selecting the most relevant climate predictors for each region. These results align with previous research, indicating that hybrid machine learning approaches significantly improve groundwater modeling. The exceptional predictive capability of RF supports its potential for future groundwater management applications.

Conclusion:

This study demonstrates that RF, when integrated with CMIP6 climate data, serves as an effective tool for predicting future GWL variations in the Eslamabad-e-Gharb plain. The findings indicate that during the observational period, Barfabab exhibited the most favorable GWL conditions (8.7–10.2 meters), whereas Bureg experienced the least favorable levels (15.5–17.3 meters). Water availability peaked in spring and reached its lowest levels in fall. Projections suggest that under SSP5-8.5, Jangeh will experience the highest GWL increase (3–3.5 meters) in fall (2076–2100), whereas SSP1-2.6 predicts the most severe decline in Bureg (3.5–4 meters) during spring and summer. The SSP1-2.6 and SSP2-4.5 scenarios suggest more stable GWL conditions over the long term.

Overall, GWL displayed a declining trend, with Barfabab experiencing the most substantial drop (1 meter per year). Under SSP1-2.6, GWL is projected to decline in Bureg (-0.21 m/year) in the near future and in Jangeh (-0.14 m/year) in the mid-future. Under SSP2-4.5, a significant long-term decline is anticipated across all regions, with Bureg experiencing the steepest reduction (-0.16 m/year). The RF model demonstrated outstanding performance ($R = 0.97$, $NSE = 0.89–0.98$), while the NorESM2-MM model significantly enhanced prediction accuracy up to 99.5%. These findings emphasize the critical role of advanced machine learning methodologies in groundwater resource management, providing a robust framework for future hydrological assessments and policy-making initiatives.

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 and Seyed Ehsan Fatemi; 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.

روشی نوین در پیش‌بینی تغییرات آبی سطح آب زیرزمینی با الگوریتم‌های k-means و جنگل تصادفی با داده‌های اقلیمی CMIP6 در دشت اسلام آباد غرب

چکیده

این پژوهش تغییرات سطح آب زیرزمینی (GWL) دشت اسلام آباد را با استفاده از الگوریتم جنگل تصادفی (RF) و داده‌های اقلیمی CMIP6 پیش‌بینی کرده است. داده‌های GWL از ۲۰ چاه (۱۹۹۷-۲۰۱۴) جمع‌آوری و پس از پردازش و خوشه‌بندی با روش K-Means، مدل‌سازی برای سناریوهای اقلیمی SSP1-2.6، SSP2-4.5 و SSP5-8.5 در سه منطقه جنگه، برف‌آباد و بورگ انجام شد. نتایج نشان داد که در دوره مشاهداتی، منطقه برف‌آباد با تغییرات ۸/۷ تا ۱۰/۲ متر مطلوب‌ترین و منطقه بورگ با ۱۵/۵ تا ۱۷/۳ متر نامطلوب‌ترین مقدار GWL را داشته است. بیشترین سطح دسترسی در بهار و کمترین عمق در پاییز مشاهده شد. پیش‌بینی‌ها نشان می‌دهد که در آینده دور (۲۰۷۶-۲۱۰۰) تحت سناریوی SSP5-8.5، بیشترین افزایش GWL (۳ تا ۳/۵ متر) در جنگه در پاییز رخ خواهد داد. در SSP1-2.6، بیشترین کاهش در بورگ با افت ۲/۵ تا ۴ متر در بهار و تابستان پیش‌بینی شده است. تحت سناریوهای SSP1-2.6 و SSP2-4.5 در آینده دور شرایط پایدارتر خواهد بود. در دوره مشاهداتی، GWL در تمام مناطق روند نزولی داشته و بیشترین افت سالانه (۱ متر) در برف‌آباد ثبت شد. در SSP1-2.6، کاهش GWL در آینده نزدیک در بورگ (۰/۲۱- m/year) و در آینده میانی در جنگه (۰/۱۴- m/year) ادامه خواهد داشت. در SSP2-4.5، این کاهش در آینده دور در تمامی مناطق معنادار بوده و در بورگ بیشترین مقدار (۰/۱۶- m/year) را خواهد داشت. مدل RF عملکرد بسیار خوبی داشته (R=۰/۹۷ و NSE بین ۰/۸۹ تا ۰/۹۸) و مدل NorESM2-MM دقت پیش‌بینی را تا ۹۹/۵٪ افزایش داده است.

واژگان کلیدی: CMIP6، اسلام‌آباد غرب، جنگل تصادفی، سطح آب زیرزمینی، مدل‌سازی

مقدمه

یکی از عوامل کلیدی در مدیریت مؤثر در هر حوزه، داشتن نگرش و دیدگاه مناسب است. این نگرش به درک بهتر از وضعیت موجود و نیازهای آن حوزه کمک می‌کند. به‌ویژه در زمینه منابع آب، آگاهی از وضعیت منابع آبی در یک منطقه می‌تواند نقش مهمی در برنامه‌ریزی‌های آبی و کشاورزی ایفا کند. امروزه با توجه به پیشرفت‌های فناوری، مدل‌سازی پیشرفته شبیه‌سازی سطح آب زیرزمینی (GroundWater Level- GWL) و سیستم‌های آبخوان به ما این امکان را می‌دهند که وضعیت آینده را پیش‌بینی کنیم. این ابزارها شرایط مناسبی را برای مدیریت و استفاده بهینه از منابع آب فراهم می‌آورند (فاطمی و همکاران، ۱۳۹۷).

آب زیرزمینی از بارش‌هایی نشأت می‌گیرد که به لایه‌های خاک و سنگ نفوذ می‌کند و آبخوان‌ها را پر می‌کند. این ماده ۹۷٪ از کل آب شیرین مایع را تشکیل می‌دهد و به عنوان یک منبع حیاتی برای نیازهای آشامیدنی، کشاورزی و صنعتی در سراسر جهان عمل می‌کند. آب‌های زیرزمینی از منابع حیاتی تأمین آب برای اکوسیستم‌ها و فعالیت‌های انسانی به شمار می‌روند (Islam, 2023). Mannik et al., 2024) و کاهش سطح آن‌ها می‌تواند پیامدهای جدی برای کشاورزی و تأمین آب آشامیدنی به همراه داشته باشد. مدیریت مؤثر آب‌های زیرزمینی به دلیل فشارهای فزاینده ناشی از شهرنشینی و صنعتی شدن، که خطر آلودگی را تشدید می‌کند بسیار مهم است (Islam, 2023). منابع آب زیرزمینی برای جمعیت شهری و روستایی حیاتی است، به ویژه در مناطق خشک که آب سطحی در آنها کم است (Williams et al., 2024).

علیرغم مطالعات متعدد در حوزه پیش‌بینی GWL، هنوز چالش‌هایی مانند ضعف در بهره‌گیری هم‌زمان از حداقل متغیر و مؤثرترین مدل‌های اقلیمی و داده‌محور و آگاهی از میزان اثرگذاری هر کدام، یا عدم تفکیک فضایی منطقه در مدل‌سازی وجود دارد. در حالیکه

منابع آب زیرزمینی به عنوان یکی از چالش‌های مهم مدیریت منابع آب در سرزمین‌های خشک و نیمه‌خشک، مانند ایران، که بخش اعظم آن را مناطق خشک و نیمه‌خشک فراگرفته (Araghi و همکاران، ۲۰۱۸؛ سلطانی و همکاران، ۱۴۰۲)، از اهمیت ویژه‌ای برخوردار است.

در این راستا، مطالعه حاضر پژوهش‌های بررسی شده را به دو گروه عمده تقسیم می‌کند: دسته اول مدل‌های آماری و سنتی نظیر ARIMA و HWES و... هستند که گرچه در تحلیل روند بلندمدت کاربرد دارند، اما نیاز به داده‌های گسترده داشته و در مواجهه با داده‌های غیرخطی محدودیت دارند (Pourmorad et al., 2024). دسته دوم روش‌های مبتنی بر هوش مصنوعی مانند ANN، LSTM و GRU هستند که قابلیت یادگیری از داده‌های پیچیده را دارا بوده، ممکن است گاهی در انتخاب بهینه متغیرها یا ساختار مکانی ضعف داشته باشند (Eghrari et al., 2023). در ادامه روش‌های نوین یادگیری ماشین مانند مدل جنگل تصادفی (Random Forest)، که در سال‌های اخیر مورد توجه قرار گرفته‌اند قابلیت تحلیل فضایی بیشتری دارند و امکان انتخاب ابعاد مناسب در پیش‌بینی را فراهم می‌سازند.

Mohammed و همکاران (۲۰۲۳) از روش‌های ترکیبی GA-ANN و ICA-ANN به همراه مدل‌های ELM و ORELM برای پیش‌بینی GWL در دشت سنقر استفاده کردند. نتایج آن‌ها نشان داد که مدل ORELM با ضریب همبستگی ۰/۹۶، دقت بالایی در پیش‌بینی GWL ارائه می‌دهد و عملکرد آن در مقایسه با مدل‌های عددی سنتی که نیاز به داده‌های زیاد و فرآیند کالیبراسیون دارند، بهتر است. اسمعیلی و مجرد (۱۴۰۳) به بررسی رابطه بین شاخص بارش استاندارد شده (SPI) و شاخص منبع آب زیرزمینی (GRI) (یک دوره ۲۰ ساله) در دشت اسلام‌آباد غرب پرداختند. نتایج ایشانی نشان داده که که بیشترین همبستگی بین SPI و GRI در شرایط تأخیر زمانی ۱۲ ماهه وجود دارد. پیش‌بینی‌ها نشان‌دهنده افت GWL به میزان ۵/۱۷، ۶/۰۲ و ۸/۰۸ متر تحت سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 است. یافته‌های مطالعه گرگانی و همکاران (۱۳۹۶) نیز بیانگر پایین رفتن سطح ایستابی و کاهش بارش سال‌های ۱۳۹۳ تا ۱۴۱۰ در دشت ماهیدشت (کرمانشاه) است. همچنین نتایج مطالعه‌ای دیگر در چند شهر از جمله کرمانشاه و ارومیه نشان داده که بارندگی در دوره‌های آتی، به‌ویژه تحت سناریوی SSP5-8.5، در برخی ماه‌ها کاهش خواهد یافت (باقری خانقاهی و همکاران، ۱۴۰۴). این تغییرات اقلیمی می‌تواند از عوامل مؤثر بر کاهش GWL در مناطق نیمه‌خشک باشد و اهمیت استفاده از مدل‌های دقیق برای پیش‌بینی GWL را دوچندان می‌سازد.

Eghrari و همکاران (۲۰۲۳) به کارگیری شبکه‌های عصبی بازگشتی عمیق و ارزیابی عدم قطعیت الگوریتم‌های LSTM و GRU را برای مدل‌سازی اثرات پارامترهای هواشناسی بر GWL مورد بررسی قرار دادند. در این مطالعه، مقادیر R^2 تقریباً ۹۶٪ برای LSTM و GRU، نشان‌دهنده توانمندی بالای این الگوریتم‌ها در پردازش داده‌های زمانی بود. Sakizadeh و همکاران (۲۰۱۶) نیز از مدل‌های ARIMA و HWES برای تحلیل روند بلندمدت GWL در دشت ملایر استفاده کردند و نشان دادند که مدل ARIMA در مقایسه با داده‌های تاریخی عملکرد بهتری دارد.

RF نیز به‌عنوان یکی از تکنیک‌های پیشرفته یادگیری ماشین، موفقیت‌های قابل توجهی در پیش‌بینی GWL به‌دست آورده است. به‌عنوان مثال، در جنوب مرکزی پنجاب (هند)، مدل RF با کارایی نش ساتکلیف ۰/۹۹۷ در طول فصل پس از موسمی، دقت پیش‌بینی بالایی نسبت به سایر تکنیک‌های یادگیری ماشین مانند Bagging-REPTree و Bagging-DSTree نشان داده است (Gupta et al., 2024). همچنین در یک مطالعه دیگر، RF در مقایسه با رگرسیون خطی (LR)، پیشی گرفته و مقدار R^2 برابر با ۰/۹۷ را ارائه داد که توانایی آن در مدیریت چالش‌های محیطی را مورد تأکید قرار می‌دهد (Alamsyah et al., 2024). همچنین در مطالعه‌ای دیگر برای پیش‌بینی عمق آب‌شستگی پایه پل، مدل RF در کنار سایر الگوریتم‌های درخت تصمیم به کار گرفته شد. نتایج

نشان داد که RF با ضریب تعیین 0.73 عملکرد بهتری نسبت به مدل‌های درخت تصمیم (DT) و تقویت گرادیان (GB) دارد. تحلیل حساسیت نیز نشان داد که RF به‌درستی تأثیر پارامترهایی مانند عرض و طول پایه را در پیش‌بینی عمق آب شستگی شناسایی کرده است (کما سی و دالوند، ۱۴۰۴).

در مطالعه‌ای دیگر بر روی دشت بوکان، مدل RF در مقایسه با شبکه‌های عصبی مصنوعی و منطق فازی، دقت بالاتری در پیش‌بینی GWL نشان داد و به‌عنوان الگوریتمی با توانایی بیشتر در شبیه‌سازی پارامترهای هیدروژئولوژیکی معرفی شد، به‌ویژه آنکه برای نخستین‌بار در آن منطقه مورد استفاده قرار گرفته است (نوروزی قوشبلاغ و ندیری، ۱۳۹۷). همچنین در مطالعه‌ای بر روی آبخوان آزاد دشت بیرجند، مدل جنگل تصادفی با عملکرد بهتر نسبت به مدل‌های درخت تصمیم و شبکه عصبی مصنوعی، توانایی بالایی در شبیه‌سازی سطح ایستابی نشان داد و مؤثرترین متغیرها شامل بارندگی، رطوبت و موقعیت چاه‌های مرکزی شناسایی شدند (پورصالحی و همکاران، ۱۴۰۰). در مطالعه‌ای دیگر، رگرسیون جنگل تصادفی برای پیش‌بینی تراز GWL با در نظر گرفتن پنج پارامتر تأثیرگذار شامل دبی رودخانه، دما، کسری اشباع، بارندگی و ظرفیت تبخیر به‌کار گرفته شد. نتایج نشان داده که سطح آب پیش‌بینی‌شده با مقادیر واقعی تطابق خوبی داشته و خطای نسبی کمتر از ۵ درصد بوده است. همچنین، تحلیل اهمیت ویژگی‌ها نشان داد که بارندگی با بیش از ۵۰ درصد سهم، بیشترین تأثیر را بر GWL دارد و کسری اشباع کمترین نقش را ایفا می‌کند (Wang et al., 2024). در یک مطالعه موردی در منطقه بلوایر رنج (Belvoir Ranch) واقع در حوزه دنور (Denver) ایالت وایومینگ آمریکا، از الگوریتم جنگل تصادفی برای مدل‌سازی رابطه بین سطح آب رودخانه و GWL در بخش‌های محصور و غیرمحصور یک سفره استفاده شد. نتایج نشان داده که در بخش محصور، سطح آب رودخانه مهم‌ترین عامل پیش‌بینی GWL است، که به‌واسطه نفوذ مستقیم آب رودخانه از طریق کارست‌های سطحی و تغذیه متمرکز ناشی از ذوب برف توضیح داده شده است. در مقابل، در بخش غیرمحصور با خاک‌های آبرفتی، رطوبت خاک و بارش نقش‌های اصلی را ایفا کرده‌اند. این مطالعه قدرت الگوریتم RF را در تفکیک مکانی مکانیسم‌های تغذیه در سیستم‌های آب زیرزمینی با زمینه‌های زمین‌شناختی متفاوت برجسته می‌سازد (Akurugu, 2024). همچنین، در مطالعه‌ای دیگر در هند، عملکرد پنج الگوریتم مختلف در پیش‌بینی منابع آب مورد مقایسه قرار گرفت که در آن الگوریتم RF با داشتن مقادیر خطای کمتر ($MSE = 0.002$) و دقت بالاتر، برتر از سایر مدل‌ها ارزیابی شد (Gaber & Singla, 2025). این یافته‌ها، کارایی بالای مدل جنگل تصادفی را در تحلیل الگوهای پیچیده آب زیرزمینی، توانایی پردازش داده‌های پیچیده، قابلیت ارزیابی اهمیت ویژگی‌ها، پایداری بیشتر نسبت به نویز و داده‌های پرت و عملکرد مطلوب در مجموعه‌های داده با اندازه متوسط و مدیریت پایدار منابع آبی نشان می‌دهند.

ادغام و انتخاب ویژگی‌ها در مدل‌های RF نیز توانسته است دقت پیش‌بینی را به صورت قابل توجهی ارتقا دهد. به‌طوری که، در مدل Deep Forest مبتنی بر انتخاب ویژگی، مقدار R^2 در مرحله آزمایش به ۹۰٪ رسیده است (Liu et al., 2024). پیش‌بینی GWL با استفاده از خوشه‌بندی K-Means به‌عنوان یک رویکرد نوآورانه شناخته شده است که به بهبود طراحی شبکه‌های نظارت بر آب‌های زیرزمینی کمک می‌کند. این روش موجب جمع‌آوری داده‌ها و افزایش دقت مدل می‌شود و برای شناسایی الگوهای فضایی در داده‌های آب زیرزمینی و تسهیل استراتژی‌های نظارت و مدیریت کارآمدتر بسیار مؤثر است.

پیش‌بینی GWL به‌عنوان یکی از چالش‌های مهم در مدیریت منابع آبی، به‌ویژه در دشت اسلام‌آباد غرب، ضروری است. خوشه‌بندی K-Means به‌طور خاص برای تعیین مؤثرترین مکان‌ها برای چاه‌های مشاهده‌ای و اطمینان از پوشش جامع مشخصات آبخوان مورد استفاده قرار می‌گیرد. مدل‌هایی که از K-Means بهره می‌برند، به نسبت سریع‌تر اجرا می‌شوند، که این امر در نظارت و

تصمیم‌گیری به‌موقع بسیار حیاتی است (Teimoori et al., 2023). به‌علاوه، Kayhomayoon و همکاران (۲۰۲۱) یک رویکرد سه مرحله‌ای شامل خوشه‌بندی K-Means برای شبیه‌سازی GWL پیشنهاد کردند که دقت بالایی در پیش‌بینی‌ها در خوشه‌های مختلف نشان داده است. همچنین Kayhomayoon و همکاران (۲۰۲۲) ادغام روش‌های K-Means با هوش مصنوعی از جمله ANN و الگوریتم‌های بهینه‌سازی را سبب بهبود نتایج و کاهش خطا معرفی کرده‌اند.

مدل‌های RF به دلیل توانایی و دقت بالا در مدیریت مجموعه داده‌های پیچیده، به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند. مطالعات متعدد اثربخشی RF را در پیش‌بینی GWL، به‌ویژه در مناطق با شیوه‌های کشاورزی فشرده و شرایط آب‌وهوایی متنوع، تأیید کرده‌اند (Bogireddy & Murar, 2024; Irmanda et al., 2024). روش‌های انتخاب متغیرهای ورودی مبتنی بر RF، عملکرد در پیش‌بینی را افزایش می‌دهد، این امر نشان دهنده اهمیت انتخاب پیش‌بینی کننده‌های مرتبط است (Fang et al., 2024).

از مزایای دیگر RF، ریزمقیاس‌نمایی است؛ که در مقایسه با روش‌های ریزمقیاس‌نمایی دیگر در چندین مطالعه برجسته شده است. به عنوان مثال استفاده از RF در بولیوی برای ریزمقیاس‌نمایی داده‌های بارش مدل اقلیمی جهانی (Global Climate Models_GCMs) نشان داده که این مدل در مناطق کوهستانی عملکرد خوبی داشته و RF در بیشتر موارد از ماشین‌های بردار پشتیبانی (SVM) بهتر عمل کرد (Mendoza Paz et al., 2024). در ریزمقیاس‌نمایی میانگین سالانه دمای سطح زمین، بهترین عملکرد را نسبت به سایر مدل‌های یادگیری ماشین مانند شبکه عصبی مصنوعی، رگرسیون شبکه الاستیک و ماشین بردار پشتیبان دارد (عتباتی و ادب، ۱۴۰۱). Amnuaylojaroen (۲۰۲۳) RF و DT را به عنوان روش‌های برتر یادگیری ماشین در ریزمقیاس‌نمایی دما در آسیای جنوب شرقی در مقایسه با ماشین تقویت‌کننده گرادیان (GBM) شناسایی کرد. Pang و همکاران (۲۰۱۷) RF را برای ریزمقیاس‌نمایی میانگین دمای روزانه داده‌های NCEP در حوضه رودخانه پرل در جنوب چین مورد استفاده قرار داده‌اند. نشان داده شده است که RF در مقایسه با مدل‌های رگرسیون خطی چندگانه (MLR)، ANN و SVM، برتر است. در مطالعه Tang و همکاران (۲۰۲۴) RF به عنوان بهترین الگوریتم یادگیری ماشین برای تصحیح بارش ماهانه پیش‌بینی شده نسبت به مدل‌های LR و SVR معرفی شده است. نتایج نشان که که مدل RF دارای بالاترین مقادیر R و NSE و کمترین مقادیر MAE و RMSE است، که نشان‌دهنده دقت بالاتر آن در ریزمقیاس‌نمایی GCMs می‌باشد. در مطالعه‌ای دیگر در استان جیانگ‌سو چین، RF در کنار مدل رگرسیون جغرافیایی وزن‌دار (GWR) برای افزایش تفکیک‌پذیری مکانی داده‌های GRACE استفاده شده و مدل RF عملکرد پیش‌بینی بهتری از خود نشان داده است (Yang et al., 2025).

در مطالعات اخیر، یادگیری ماشین به طور گسترده‌ای در مطالعات مختلف برای ریزمقیاس‌نمایی (Jin et al., 2023) و پیش‌بینی متغیرهای آب‌وهوایی با نتایج موفقیت‌آمیز به کار رفته است و انتظار می‌رود که این روش در تحقیقات آینده نیز نقش مهمی ایفا کند (Fatemi & Parvini, 2022; Bochenek & Ustrnu, 2022; Rampal et al., 2024). آب‌های زیرزمینی به‌عنوان یکی از مهم‌ترین منابع تأمین آب محلی برای انسان، در سال‌های اخیر تحت تأثیر عوامل متعددی قرار گرفته است؛ که منجر به کاهش قابل توجه سطح آن‌ها (GWL) در برخی مناطق گردیده است. به‌عنوان مثال، تأثیر تغییرات اقلیمی نظیر افزایش دما، کاهش بارندگی و تغییرات رطوبت خاک، بررسی و مدل‌سازی اثرات این عوامل بر GWL را ضروری می‌سازد (Eghrari et al., 2023).


با وجود پیشرفت‌های چشمگیر در مدل‌سازی GWL، بسیاری از مطالعات پیشین یا بر روش‌های سنتی عددی متکی بوده‌اند که نیازمند داده‌های فراوان و کالیبراسیون پیچیده‌اند، یا از الگوریتم‌های یادگیری ماشین بدون توجه به ساختارهای مکانی داده و پیش‌بینی بهینه و با دقت بالا، با حداقل پارامترها استفاده کرده‌اند. در این تحقیق، برای نخستین بار در دشت اسلام‌آباد غرب، الگوریتم

K-means به منظور خوشه‌بندی مکانی و انتخاب نمایندگان منطقه‌ای، و مدل RF برای ریزمقیاس‌نمایی و پیش‌بینی GWL در ترکیب با مدل‌های منتخب رطوبت خاک از تمام مدل‌های این متغیر از CMIP6 به کار گرفته شده است. نوآوری این پژوهش در ادغام هدفمند این دو روش، حذف ویژگی‌های ناکارآمد، و انتخاب مدل‌های برتر رطوبت خاک با ارزیابی مبتنی بر دقت و اثرگذاری، و پیش‌بینی GWL تحت سه سناریوی اقلیمی آینده در مناطق خشک و نیمه‌خشک نهفته است. این رویکرد می‌تواند شکاف موجود میان مدل‌های جهانی اقلیمی و پیش‌بینی‌های کاربردی محلی را کاهش داده و روشی نوین برای تصمیم‌گیری مبتنی بر داده در مدیریت منابع آب زیرزمینی فراهم کند.

روش‌شناسی پژوهش

منطقه مورد مطالعه

شهرستان اسلام‌آباد یکی از شهرستان‌های واقع در استان کرمانشاه در غرب ایران است. ایستگاه سینوپتیک اسلام‌آباد در طول و عرض جغرافیایی ۴۶/۴۶ و ۳۴/۱۱ واقع شده است. بر اساس آمار ثبت شده در ایستگاه هواشناسی اسلام‌آباد، میانگین بارش سالانه این منطقه ۴۶۳ میلی‌متر و میانگین دمای آن ۱۳/۸ درجه سانتی‌گراد است. این منطقه دارای اقلیم نیمه‌مرطوب سرد، مرطوب سرد و ارتفاعات شناخته می‌شود. همچنین این ایستگاه تقریباً پنج ماه از سال تحت تأثیر خشکی قرار دارد. دشت اسلام‌آباد در ارتفاعی حدود ۱۳۰۰ متری از سطح دریا قرار دارد و از سمت شرق و شمال با شهرستان کرمانشاه، از غرب با شهرستان‌های دالاهو و گیلانغرب و از سمت جنوب با شهرستان سیروان در استان ایلام هم‌مرز می‌باشد (باقرآبادی، ۱۴۰۱؛ اسمعیلی و مجرد، ۱۴۰۳؛ نعمتی پیکانی و همکاران، ۱۴۰۰).



شکل ۱. موقعیت جغرافیای دشت اسلام‌آباد و موقعیت چاه‌های مشاهداتی و خوشه‌بندی شده

داده‌ها

در این پژوهش به منظور بررسی اثر تغییر اقلیم بر GWL دشت اسلام‌آباد داده‌های ماهانه^{۲۰} چاه مشاهداتی آبخوان دشت اسلام‌آباد از دفتر اطلاعات و داده‌های آب کشور^۱ اخذ شد. داده‌های میانگین رطوبت خاک MERRA2 نیز از وبسایت ناسا (<https://giovanni.gsfc.nasa.gov/giovanni>) برای ۲۴ سال (۱۹۹۱-۲۰۱۴) در موقعیت ایستگاه سینوپتیک اسلام‌آباد جمع‌آوری شد. همچنین، داده‌های تاریخی و سناریوهای آینده از مدل‌های مختلف CMIP6 از اتحادیه داده‌های سیستم زمین-ESGF (<https://esgf.org>) (data.dkrz.de/projects/esgf-dkrz/) اخذ شد (جدول ۱). وبسایت ESGF به کاربران اجازه می‌دهد داده‌های مدل‌های اقلیمی را برای گزارش ارزیابی IPCC بازیابی کنند و دسترسی به مجموعه وسیعی از آن‌ها را فراهم می‌آورد.

این مطالعه شامل تمام مدل‌های موجود رطوبت خاک با ویژگی Lmon و اجرای r1i1p1f1 در تفکیک‌های مکانی مختلف (جدول ۱) برای عرض جغرافیایی ۳۴/۳۵ و طول جغرافیایی ۴۷/۱۵ (اسلام‌آباد غرب) است. برای بازیابی مدل‌ها، از کتابخانه intake-ESM و یک API پایتون استفاده شد. API توسعه یافته، دسترسی به داده‌های اقلیمی متنوع را برای هر مدل، مکان و زمان تسهیل کرده و به سادگی داده‌های CMIP6 JSON file را با فرمت Zarr حاصل کرد. این روش به کاربران اجازه می‌دهد تا بدون نیاز به دانلود فایل‌های سنگین NetCDF، به‌طور موثر به داده‌ها از مدل‌های مختلف CMIP6 دسترسی پیدا کنند. در ششمین مرحله CMIP، موسوم به CMIP6، مسیرهای تمرکز نماینده CMIP5 (RCPs) با مسیرهای اجتماعی-اقتصادی مشترک CMIP6 (SSPs) ادغام شده است (الماسی و همکاران، ۱۴۰۳). سناریوهای SSP تحولات جایگزین جامعه آینده را بدون در نظر گرفتن تغییرات اقلیمی یا سیاست‌های مرتبط توصیف می‌کنند. پروژه CMIP6 شامل پنج سناریو اصلی SSP است. سناریوهای SSP1 و SSP5 به توسعه انسانی و سرمایه‌گذاری‌های قابل توجه در بخش‌های آموزش و بهداشت، رشد سریع اقتصادی و نهادهای با عملکرد بالا اشاره دارند، در حالی که SSP1 به سمت شیوه‌های پایدار و SSP5 بر پایه اقتصاد وابسته به سوخت‌های فسیلی استوار است. در مقابل، SSP3 و SSP4 روندی بدبینانه را نشان می‌دهند که شامل سرمایه‌گذاری کم در آموزش و بهداشت، رشد سریع جمعیت و افزایش نابرابری‌ها می‌شود. در SSP3، کشورها در امنیت مناطق خود تمرکز دارند و SSP4 نیز با نابرابری‌های قابل توجهی مواجه است. سناریو SSP2 یک مسیر میانه را ارائه می‌دهد که در آن جوامع به روند الگوهای تاریخی خود ادامه می‌دهند (Gidden et al., 2019; O'Neill et al., 2016).

مدل‌های ماهانه موجود CMIP6 برای رطوبت خاک در منطقه مطالعه انتخاب شدند که داده‌های ۱۹۹۱-۲۰۱۴ و ۲۰۲۶-۲۱۰۰ را تحت سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 پوشش می‌دهند. این داده‌ها به سه بازه زمانی: آینده نزدیک (۲۰۲۶-۲۰۵۰)، آینده میانی (۲۰۵۱-۲۰۷۵) و آینده دور (۲۰۷۶-۲۱۰۰) تقسیم شدند. سپس، با کمک الگوریتم یادگیری ماشین RF و اختصاص ۷۰٪ سری زمانی داده‌ها به آموزش و ۳۰٪ به تست، برای موقعیت ایستگاه اسلام‌آباد ریزمقیاس‌نمایی شدند.

در مرحله بعد، داده‌های GWL مشاهداتی با استفاده از الگوریتم K-means خوشه‌بندی شدند. برای در نظر گرفتن بخش‌های مختلف داده‌های GWL مشاهداتی هر خوشه و اجرای مراحل آموزش و تست از روش اعتبار سنجی K-fold استفاده کردیم. برای انتخاب بهترین ویژگی‌ها (مدل‌های رطوبت خاک CMIP6) از الگوریتم RF و روش حذف ویژگی بازگشتی استفاده شد. این رویکرد اجازه می‌دهد تا اهمیت ویژگی‌ها در هر بخش ارزیابی شود و ویژگی‌هایی که در کل بخش‌ها اهمیت کمی دارند، حذف شوند. نتیجه این فرآیند، انتخاب ویژگی‌های نهایی پایدارتر و قابل اعتمادتر خواهد بود و احتمال حذف اشتباه ویژگی‌های مهم را کاهش می‌دهد، در حالی که مدل دقت بالایی را حفظ می‌کند. آزمون و خطا نشان داد که تخصیص ۸۰٪ داده‌ها به عنوان داده آموزش و ۲۰٪ به عنوان تست، نتایج مناسب‌تری ارائه می‌کند. پس از آن، مدل‌های انتخاب شده توسط RF برای پیش‌بینی GWL در آینده نزدیک، میانی و دور مورد استفاده قرار گرفتند.

^۱ <https://data.wrm.ir/>

جدول ۱. مدل‌های CMIP6 استفاده شده رطوبت خاک در تحقیق حاضر

نام مدل	قدرت تفکیک مکانی (کیلومتر)
ACCESS-CM2	۱۰۰
BCC-CSM2-MR	۱۰۰
CESM2-WACCM	۱۰۰
CMCC-CM2-SR5	۱۰۰
INM-CM4-8	۱۰۰
INM-CM5-0	۱۰۰
IPSL-CM6A-LR	۲۵۰
MIROC6	۲۵۰
MPI-ESM1-2-HR	۱۰۰
MPI-ESM1-2-LR	۲۵۰
MRI-ESM2-0	۱۰۰
NorESM2-MM	۱۰۰

الگوریتم K-means

خوشه‌بندی یک روش یادگیری بدون نظارت است که به شناسایی گروه‌های متمایز در یک مجموعه داده می‌پردازد، به طوری که اعضای هر خوشه به یکدیگر شباهت دارند. یکی از روش‌های متداول خوشه‌بندی، روش K-means (رابطه ۱) است. در این روش نمونه‌ها به‌طور تصادفی به K خوشه تقسیم می‌گردند. هدف K-means کاهش حساسیت نسبت به داده‌های پرت در داده‌ها است. سپس فاصله هر نمونه از مرکز خوشه‌اش محاسبه می‌شود. اگر این فاصله بیشتر از میانگین فاصله نمونه‌ها در خوشه و کمتر از میانگین فاصله خوشه‌های دیگر باشد، آن نمونه به نزدیک‌ترین خوشه اختصاص می‌یابد. این فرآیند تا زمانی ادامه می‌یابد که یا تابع خطا به حداقل برسد یا تغییرات بیشتری در خوشه‌ها مشاهده نشود. فرض کنید D مجموعه داده‌ها باشد و C1، C2، ...، CK خوشه‌های مختلف برای D باشند، در این صورت تابع خطا (EF) به عنوان مجموع فاصله‌های هر نمونه از مرکز خوشه‌اش تعریف می‌شود. در اینجا، μ مرکز خوشه و $d(X, \mu(C_i))$ فاصله هر نمونه از مرکز آن خوشه است. فاصله می‌تواند بر اساس فاصله اقلیدسی یا روش‌های دیگر محاسبه شود (کریمی‌نژاد و همکاران، ۱۴۰۲؛ Kardan Moghaddam و همکاران، ۲۰۲۱).

$$w(c_k) = \sum_{i=1}^k \sum d(X, \mu(C_i)) \quad (\text{رابطه ۱})$$

برای انتخاب مجموعه‌ای نماینده از چاه‌های مشاهده‌ای در منطقه اسلام‌آباد، ابتدا خوشه‌بندی K-means بر اساس مختصات UTM چاه‌های مشاهداتی انجام شد. تعداد بهینه خوشه‌ها با استفاده از روش Elbow تعیین گردید، به طوری که مجموع خطای خوشه‌بندی (Model Score) برای مقادیر مختلف k محاسبه و نقطه زانویی منحنی به عنوان معیار انتخاب خوشه‌ها در نظر گرفته شد. پس از خوشه‌بندی، از هر خوشه نقطه مرکزی به عنوان نماینده انتخاب شد تا ضمن کاهش حجم داده‌ها، ساختار فضایی داده‌ها حفظ گردد.

الگوریتم جنگل تصادفی (Random forest)

مدل یادگیری ماشین جمعی به نام RF، که به عنوان یک ابزار برجسته شناخته می‌شود، با استفاده از تعداد زیادی درخت تصمیم تصادفی و غیرهمبسته، تخمین‌های قابل اعتمادی ارائه می‌دهد (Salman et al., 2024). این مدل به طور معمول برای حل چالش‌های مربوط به بازایی پارامترهای سطح زمین و جو و همچنین ریزمقیاس‌نمایی به کار می‌رود (Tang et al., 2021; Darabi, 2024; Cheghabaleki et al., 2024). برای ارزیابی ویژگی‌های مهم مناسب است و به محققان اجازه می‌دهد تا پیش‌بینی‌کننده‌های برتر را در زمینه‌های مختلف شناسایی کنند (Miao & Xu, 2024).

الگوریتم RF اصول درخت تصمیم را به کار می‌گیرد. این الگوریتم یک مجموعه درخت ایجاد می‌کند که هر درخت بر روی یک زیرمجموعه تصادفی منحصر به فرد از داده‌ها آموزش می‌بیند. برای ایجاد تصادفی بودن، از روش "Bagging" یا تجمع بوت‌استرپ استفاده می‌کند. با ترکیب پیش‌بینی‌های هر درخت، مدل به طور جمعی نتایج را تعیین می‌کند. یکی از نقاط قوت RF، کارایی آن در مدیریت مجموعه‌های داده بزرگ با ابعاد متعدد است. استفاده از درخت‌های متعدد دقت را افزایش می‌دهد و مشکل بیش‌برازش، که معمولاً با درخت‌های تصمیم منفرد وجود دارد، را کاهش می‌دهد. RF با بهره‌گیری از الگوهای فضایی و ارتباطات داده‌ها، پیش‌بینی‌های دقیقی به ویژه در ریزمقیاس‌نمایی ارائه می‌دهد. این ویژگی RF را به عنوان یک راه‌حل مناسب برای داده‌های اقلیمی پیچیده معرفی می‌کند. در اصل، الگوریتم RF بر پایه هوش جمعی استوار است و شامل مجموعه‌ای از مدل‌های نسبتاً مستقل، یا درخت‌ها، است که به عنوان یک گروه عمل می‌کنند تا از مدل‌های فردی پیشی بگیرند (Amnuaylojaroen, 2023). در این مطالعه، مدل جنگل تصادفی با استفاده از ۱۰۰ درخت تصمیم پیاده‌سازی گردید. برای سنجش کیفیت تقسیم‌بندی در هر گره، شاخص پیش‌فرض Gini به عنوان معیار انتخاب ویژگی‌ها مورد استفاده قرار گرفت. معیار Gini معیاری از نابرابری در توزیع داده‌هاست که کاهش آن نشان‌دهنده افزایش خلوص گره‌هاست. فرآیند رشد درخت‌ها بدون محدودیت در عمق انجام شد، به گونه‌ای که گسترش گره‌ها تا مرحله‌ای ادامه یافت که تمامی برگ‌ها به طور کامل خالص سازی شدند؛ در واقع، تقسیم‌ها تا زمانی ادامه داشت که تمامی نمونه‌های هر برگ به یک کلاس تعلق داشتند.

معیارهای ارزیابی

برای ارزیابی تفاوت بین داده‌های مشاهده‌شده و شبیه‌سازی‌شده (۱۹۹۱-۲۰۱۴)، از تکنیک‌های آماری استفاده شد که شامل شاخص‌های زیر است: شاخص پراکندگی (SI)، خطای میانگین انحراف (MBE)، خطای مربع ریشه نرمال شده (NRMSE)، خطای مطلق میانگین (MAE)، انحراف مطلق میانگین (MAD)، کارایی نش-ساتکلیف (NSE) و ضریب همبستگی (R). این شاخص‌ها به صورت روابط ۲ تا ۹، موجود در جدول ۲ تعریف می‌شوند. که در آن Y_i داده‌های مشاهده‌شده، Y داده‌های مدل، $\bar{Y}$ میانگین داده‌های مشاهده‌شده و n تعداد کل داده‌ها است (Moeeni et al., 2017; Adib & Harun, 2022).

جدول ۲. تکنیک‌های آماری ارزیابی عملکرد

شاخص	
رابطه ۲	$\frac{\sum_{i=1}^N (Y_i - Y)}{n}$
رابطه ۳	$NRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (Y_i - Y)^2}{n}}}{Y_{i\max} - Y_{i\min}}$
رابطه ۴	$MAE = \frac{\sum Y_i - Y}{n}$
رابطه ۵	$MAD = \frac{\sum_{i=1}^n Y_i - Y }{n}$
رابطه ۶	$SI = \sqrt{\frac{\sum_{i=1}^n (Y_i - Y)^2}{\bar{Y}_i}}$
رابطه ۷	$NSE = 1 - \left[\frac{\sum_{i=1}^n (Y_i - Y)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \right]$
رابطه ۸	$R = \frac{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})(X_{sim,i} - \bar{X}_{sim})}{\sqrt{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})^2 \sum_{i=1}^N (X_{sim,i} - \bar{X}_{sim})^2}}$
رابطه ۹	$MBE = \frac{\sum_{i=1}^N (Y_i - Y)}{n}$

آزمون روند من - کندال (Mann-Kendall)

جهت تعیین روند سری زمانی متغیرهای مورد بررسی در این مطالعه از آزمون ناپارامتری من - کندال (MK) استفاده شد. نتایج بررسی منابع نشان دهنده آن است که از بین آزمون‌های ناپارامتری، آزمون MK بهترین انتخاب برای بررسی روند داده‌ها است (پناهی و همکاران، ۱۳۹۶). روش MK ابتدا توسط Mann (۱۹۴۵) ارائه و سپس توسط Kendall (۱۹۷۰) بسط و توسعه یافت. فرض صفر آزمون M-K بر تصادفی بودن و عدم وجود روند در سری داده‌ها دلالت دارد و پذیرش فرض یک (رد فرض صفر) دال بر وجود روند در سری داده‌ها می‌باشد. در این روش ابتدا اختلاف بین هر یک از مشاهدات با تمام مشاهدات پس از آن محاسبه شده و پارامتر S مطابق رابطه زیر به دست می‌آید:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x_j - x_k) \quad \text{رابطه ۱۰}$$

که در آن n تعداد مشاهدات سری، و x_j و x_k به ترتیب داده‌های زام k و ام سری می‌باشند. تابع علامت sgn نیز به صورت زیر قابل محاسبه است:

$$\begin{aligned} \text{sgn}(x_j - x_k) &= +1 & \text{for } (x_j - x_k) > 0 \\ \text{sgn}(x_j - x_k) &= 0 & \text{for } (x_j - x_k) = 0 \\ \text{sgn}(x_j - x_k) &= -1 & \text{for } (x_j - x_k) < 0 \end{aligned} \quad \text{رابطه ۱۱}$$

در مرحله بعد واریانس با استفاده از یکی از روابط زیر محاسبه می‌شود:

$$\text{for } n > 10 \quad \text{var}(S) = \frac{n(n-1)(2n+5) - \sum_{j=1}^m t(t-1)(2t+5)}{18} \quad \text{رابطه ۱۲}$$

$$\text{for } n < 10 \quad \text{var}(S) = \frac{n(n-1)(2n+5)}{18} \quad \text{رابطه ۱۳}$$


که n و m معرف تعداد دنباله‌هایی است که در آنها حداقل یک داده تکراری وجود دارد. t نیز بیانگر فراوانی داده‌های با ارزش یکسان در یک دنباله (تعداد گره‌ها) می‌باشد. در نهایت نیز آماره Z به کمک یکی از روابط زیر استخراج می‌شود:

$$\begin{aligned} \text{for } S > 0 \quad Z &= \frac{S-1}{\sqrt{\text{var}(S)}} \\ \text{for } S = 0 \quad Z &= 0 \\ \text{for } S < 0 \quad Z &= \frac{S+1}{\sqrt{\text{var}(S)}} \end{aligned} \quad \text{رابطه ۱۴}$$

با فرض دو دامنه آزمون روند، فرضیه صفر در صورتی پذیرفته می‌شود که شرط زیر برقرار باشد:

$$|Z| = Z \alpha_2 \quad \text{رابطه ۱۵}$$

که α سطح معنی‌داری است که برای آزمون در نظر گرفته می‌شود و $Z\alpha$ آماره توزیع نرمال استاندارد در سطح معنی‌داری α می‌باشد که باتوجه به دو دامنه بودن آزمون، $\alpha/2$ استفاده می‌شود. در صورتی که آماره Z مثبت باشد روند سری داده‌ها صعودی و در صورت منفی بودن آن، روند نزولی در نظر گرفته می‌شود (Das et al., 2022). در این مطالعه سطح اطمینان ۹۵٪ به کار گرفته شده است. برای درک بهتر، روندنا مربوط روند کلی این مطالعه در شکل ۲ ارائه شده است.



شکل ۲. روند مراحل تحقیق

یافته‌های پژوهش

در این تحقیق، متغیر میانگین ماهانه رطوبت خاک از تمامی مدل‌های CMIP6 با ویژگی‌های مورد نظر استخراج شد. پس از انجام ریزمقیاس نمایی با استفاده از الگوریتم یادگیری ماشین RF، روش حذف ویژگی بازگشتی RF برای انتخاب مؤثرترین ویژگی‌ها در پیش‌بینی GWL به کار گرفته شد. پیش‌بینی‌کننده RF با استفاده از ۸۰ درصد داده‌های تاریخی مدل‌های رطوبت خاک CMIP6 و مشاهداتی GWL آموزش دید و ۲۰ درصد باقی‌مانده برای ارزیابی عملکرد مدل استفاده شد. نتایج نشان داد که برخی از مدل‌های CMIP6 در منطقه مورد مطالعه نسبت به سایر مدل‌ها عملکرد بهتری دارند.

با اجرای RF، مهم‌ترین مدل در هر خوشه از دشت اسلام‌آباد برای پیش‌بینی شناسایی شد. تأثیرگذاری برترین مدل‌ها به صورت درصدی محاسبه گردید و سایر مدل‌های برتر نیز معرفی شدند، به طوری که کمترین تعداد و دقیق‌ترین مدل‌ها تا حدود ۹۹٫۵٪ دقت در پیش‌بینی مشارکت داشتند. مدل‌های برتر برای هر خوشه از دشت اسلام‌آباد در جدول ۳ ارائه شده است. همانطور که در جدول ۳ ملاحظه می‌شود مدل NorESM2-MM مؤثرترین مدل برای شبیه‌سازی و پیش‌بینی GWL با تأثیر ۷۳/۳٪، ۷۸٪ و ۷۶٪ به ترتیب در پی‌زومترهای جنگه، برف‌آباد و بورگ است. عبارتی استفاده از این مدل در پیش‌بینی GWL می‌تواند حداقل ۷۳٪ دقت را در طول دوره تست به دست آورد. ترکیب مدل INM-CM5-0 با مدل فوق در منطقه جنگه دقت را به ۸۷/۴٪ می‌رساند. یعنی چیزی حدود ۱۴٪ به دقت پیش‌بینی می‌افزاید. برای رسیدن به دقت ۹۹/۳٪ نیاز است که تابع Y5 (جدول ۳)، به عنوان ورودی در نظر گرفته شود. یعنی علاوه بر دو مدل ذکر شده پیشین، مدل‌های CMCC-CM2-SR5، INM-CM4-8، ACCESS-CM2، CESM2-WACCM و BCC-CSM2-MR باید به عنوان ورودی RF برای پیش‌بینی اضافه شوند تا ۱۱/۹٪ به دقت مدل‌ها افزوده شود.

پس از دستیابی به دقت ۷۸٪ با استفاده از مدل NorESM2-MM در منطقه برف‌آباد، افزودن مدل‌های CMCC-CM2-SR5 و INM-CM5-0 به عنوان ویژگی‌های ورودی به مدل RF به ترتیب با سهم ۵٪ و ۱۲٪ در بهبود عملکرد پیش‌بینی سطح آب زیرزمینی نقش داشتند. برای رسیدن به دقت ۹۹/۲٪ دقت پیش‌بینی در تابع Y5، باید ۴ مدل INM-CM4-8، ACCESS-CM2، CESM2-WACCM و BCC-CSM2-MR نیز اضافه شوند (جدول ۳). در بورگ نیز مدل CMCC-CM2-SR5 با ۹٪ اثرگذاری باید با NorESM2-MM در ورودی تابع RF برای پیش‌بینی شرکت کنند تا دقت ۸۵٪ حاصل شود. مدل‌های INM-CM5-0 با ۷٪، INM-CM4-8 با ۲٪، CESM2-WACCM با ۴/۲٪ و در نهایت ACCESS-CM2 و MPI-ESM1-2-HR با ۸/۰٪ اثرگذاری باید افزوده شوند تا دقت تابع پیش‌بینی به ۹۹٪ برسد (جدول ۳). دقت ۵ مدل انتخاب‌نشده از تمام مدل‌های اخذ شده در جنگه ۷/۰٪، در برف‌آباد ۸/۰٪ و در بورگ ۱٪ است. این بدان معناست که ۵ مدل باقی‌مانده افزایش جزئی در دقت پیش‌بینی‌کننده RF برای هر منطقه از دشت اسلام‌آباد ایجاد می‌کنند.

جدول ۳. مدل‌های انتخاب شده برای پیش‌بینی GWL در خوشه‌های مختلف دشت اسلام‌آباد

نام منطقه	تابع ورودی	درصد تأثیر در افزایش دقت
جنگه	$Y_0 = \text{NorESM2-MM}$	۷۳/۳٪
	$Y_1 = Y_0 + \text{INM-CM5-0}$	۸۷/۴٪
	$Y_2 = Y_1 + \text{CMCC-CM2-SR5} + \text{INM-CM4-8}$	۹۰/۵٪
	$Y_3 = Y_2 + \text{ACCESS-CM2}$	۹۷/۶٪
	$Y_4 = Y_3 + \text{CESM2-WACCM}$	۹۸/۵٪
	$Y_5 = Y_4 + \text{BCC-CSM2-MR}$	۹۹/۳٪
برف‌آباد	$Y_0 = \text{NorESM2-MM}$	۷۸٪
	$Y_1 = Y_0 + \text{CMCC-CM2-SR5}$	۸۳٪
	$Y_2 = Y_1 + \text{INM-CM5-0}$	۹۵٪
	$Y_3 = Y_2 + \text{INM-CM4-8}$	۹۷٪
	$Y_4 = Y_3 + \text{ACCESS-CM2} + \text{CESM2-WACCM}$	۹۸٪
	$Y_5 = Y_4 + \text{BCC-CSM2-MR}$	۹۹/۲٪
بورگ	$Y_0 = \text{NorESM2-MM}$	۷۶٪
	$Y_1 = Y_0 + \text{CMCC-CM2-SR5}$	۸۵٪
	$Y_2 = Y_1 + \text{INM-CM5-0}$	۹۲٪
	$Y_3 = Y_2 + \text{INM-CM4-8}$	۹۴٪
	$Y_4 = Y_3 + \text{CESM2-WACCM}$	۹۸/۲٪
	$Y_5 = Y_4 + \text{ACCESS-CM2} + \text{MPI-ESM1-2-HR}$	۹۹٪

پس از شناسایی ۷ مدل مؤثر CMIP6 رطوبت خاک در پیش‌بینی GWL، با ترکیب پیش‌بینی‌های هر درخت، مدل به طور جمعی نتایج را تعیین کرد. دقت این ۷ مدل در سه منطقه جنگه، برف‌آباد و بورگ به ترتیب ۹۹/۳٪، ۹۹/۲٪ و ۹۹٪ ارزیابی شد. جدول ۴ عملکرد مدل را بر اساس معیارهای مختلف آماری در طول دوره‌های آموزش و تست برای مناطق مختلف دشت اسلام‌آباد نشان می‌دهد.

نتایج جدول ۴ نشان می‌دهد که مدل RF توانسته است با دقت بالایی GWL را شبیه‌سازی کند. معیارهای مختلفی برای ارزیابی عملکرد مدل مورد استفاده قرار گرفته‌اند. مقدار شاخص MAD در دوره تست برای بورگ ۰/۶۶، برف‌آباد ۰/۴۷ و جنگه ۰/۶۵ برآورد شده است. مقادیر کمتر MAD نشان‌دهنده خطای کمتر مدل در پیش‌بینی‌ها است. این میزان در دوره آموزش نسبت به تست بهتر

بوده است. میزان R در دوره تست برای بورگ و جنگه ۰/۹۶ و برف‌آباد ۰/۹۵ و در دوره آموزش برای تمامی مناطق ۰/۹۹ بوده است. مقدار نزدیک به ۱ نشان‌دهنده همبستگی قوی بین مقادیر واقعی و پیش‌بینی‌شده است.

شاخص NS که میزان دقت مدل در پیش‌بینی مقادیر را نشان می‌دهد، در دوره تست برای بورگ و جنگه ۰/۹۰ و برای برف‌آباد ۰/۸۹ و در دوره آموزش برای بورگ و جنگه ۰/۹۸، برف‌آباد ۰/۹۷ محاسبه شده است. مقادیر نزدیک به ۱ بیانگر کیفیت بالای پیش‌بینی‌ها است. مقدار MAE در دوره تست برای بورگ ۰/۴۱- و برف‌آباد و جنگه ۰/۲۵- و در دوره آموزش برای بورگ ۰/۰۳-، برف‌آباد ۰/۰۴- و جنگه ۰/۰۲- بوده است. مقادیر MBE نیز نشان‌دهنده عملکرد مطلوب مدل در هر دو دوره بوده و خطای بایاس مدل بسیار ناچیز است. مقادیر منفی MAE نشان می‌دهد که مدل تمایل به اندکی کم‌برآوردی نسبت به مقادیر واقعی دارد. مقادیر SI در دوره تست بین ۰/۰۶ تا ۰/۰۷ و مقادیر NRMSE در دوره تست ۰/۰۶ تا ۰/۰۸ است، که نشان‌دهنده دقت بالای مدل است. این نتایج نشان می‌دهد که روش پیشنهادی می‌تواند به عنوان یک ابزار مؤثر برای پایش و مدیریت منابع آب زیرزمینی استفاده شود.

جدول ۴. عملکرد مدل RF در دوره آموزش و تست در ریزمقیاس‌نمایی و شبیه‌سازی GWL مناطق مختلف دشت اسلام‌آباد


شاخص	آموزش			شاخص	تست		
	جنگه	برف‌آباد	بورگ		جنگه	برف‌آباد	بورگ
MAD	۰/۲۷	۰/۲۶	۰/۳۸	MAD	۰/۶۵	۰/۴۷	۰/۶۶
R	۰/۹۹	۰/۹۹	۰/۹۹	R	۰/۹۶	۰/۹۵	۰/۹۶
NS	۰/۹۸	۰/۹۷	۰/۹۸	NS	۰/۹۰	۰/۸۹	۰/۹۰
MAE	-۰/۰۲	-۰/۰۰۴	-۰/۰۳	MAE	-۰/۲۵	-۰/۲۵	-۰/۴۱
MBE	۰/۰۲	۰/۰۰۴	۰/۰۳	MBE	۰/۲۵	۰/۲۵	۰/۴۱
SI	۰/۰۳	۰/۰۴	۰/۰۴	SI	۰/۰۶	۰/۰۶	۰/۰۷
NRMSE	۰/۰۳	۰/۰۳	۰/۰۳	NRMSE	۰/۰۸	۰/۰۸	۰/۰۶

پیش‌بینی ماهانه

مشاهداتی

مقادیر مشاهده‌شده برای سه منطقه دشت اسلام‌آباد در دوره ۱۹۹۷ تا ۲۰۱۴ بیانگر تفاوت معنادار در سطح آب زیرزمینی (GWL) این مناطق است (شکل ۳). در منطقه برف‌آباد، GWL بین ۸/۶۸ متر تا ۱۰/۱۷ متر متغیر بوده و نسبت به دو منطقه دیگر مقادیر بالاتری داشته است. میانگین GWL در منطقه بورگ در بازه ۱۵/۲۸ تا ۱۷/۳۳ متر و در منطقه جنگه از ۱۳/۱۱ تا ۱۴/۶۴ متر گزارش شده است. به‌طور کلی، بالاترین سطح دسترسی به آب زیرزمینی (وضعیت مطلوب‌تر) در فصل بهار مشاهده شده که به‌نظر می‌رسد تحت تأثیر تغذیه طبیعی سفره‌ها از بارش‌های زمستانه با تأخیر زمانی، باشد. در مقابل، بیشترین افت GWL در فصل پاییز ثبت شده که می‌تواند ناشی از ترکیب چند عامل باشد؛ از جمله افزایش برداشت در فصل تابستان به‌ویژه در بخش کشاورزی، کاهش نفوذپذیری مؤثر بارش‌ها در فصول گرم و افزایش تبخیر و تعرق ناشی از دمای بالا که مانع از تغذیه مؤثر آبخوان‌ها در این بازه زمانی می‌شود.

اسلام آباد - مشاهداتی



شکل ۳. میانگین ماهانه GWL دوره مشاهداتی، آینده نزدیک، میانی و دور در ایستگاه اسلام آباد

سناریو SSP1-2.6

سناریوی SSP1-2.6 با کاهش جزئی انتشار گازهای گلخانه‌ای در نظر گرفته می‌شود. در این شرایط در منطقه برف‌آباد در آینده نزدیک افزایش متوسط GWL، به‌ویژه در ماه اکتبر با مقدار ۲/۴ متر، کاهش در ماه‌های بهار مانند مه و ژوئن با مقدار حدودی ۱/۹ متر در آینده میانی و سطح آب نسبتاً پایدارتر نسبت به دوره مشاهداتی در آینده دور همراه است که نشان‌دهنده بهبود ذخایر آبی است و با سطح آب نسبتاً پایدارتر نسبت به دوره مشاهداتی همراه است (شکل ۴-ب). در منطقه بورگ، برای آینده نزدیک افزایش سطح آب در تمامی ماه‌ها، با بیشترین افزایش در سپتامبر و اکتبر (۲/۱ تا ۲/۴ متر)، کاهش قابل توجه ۳/۵ تا ۴ متری در ماه‌های بهار و تابستان در آینده میانی و شرایط نسبتاً پایدار در آینده دور در مقایسه با دوره مشاهداتی پیش‌بینی می‌شود (شکل ۴-ج). در منطقه جنگه، افزایش GWL در تمام ماه‌ها، به‌ویژه در تابستان و پاییز (۲ تا ۲/۵ متر) در آینده نزدیک، کاهش در ماه‌های بهار (حدود ۱/۵ متر) در آینده میانی و افزایش ۱ تا ۲ متری در ماه‌های تابستان، پاییز و اوایل زمستان در آینده دور، بیشترین تغییرات را شامل می‌شوند (شکل ۴-الف).

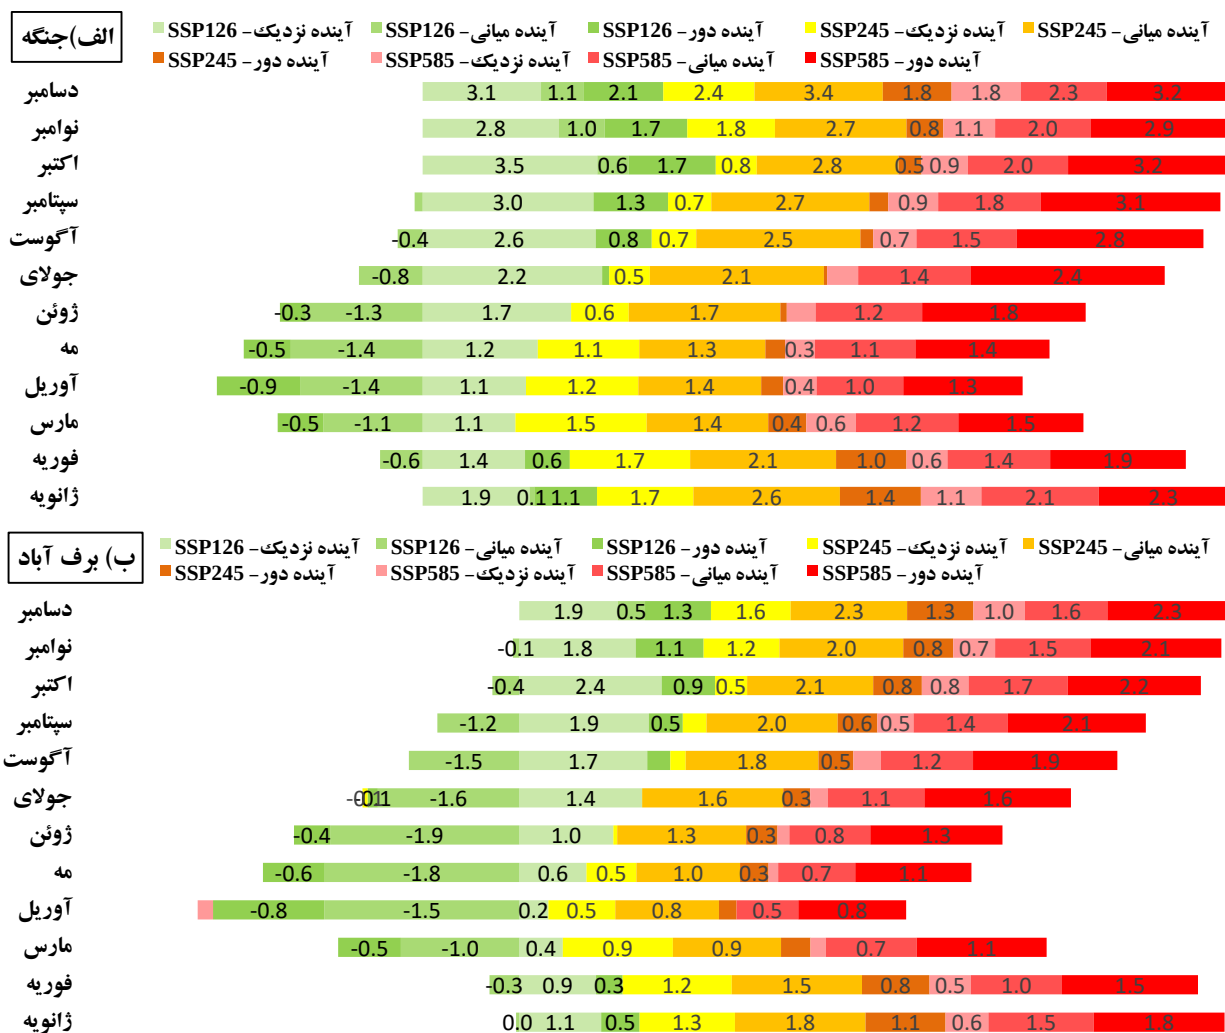
سناریو SSP2-4.5


این سناریو که نشان‌دهنده انتشار متوسط گازهای گلخانه‌ای است، افزایش ۱ تا ۱/۵ متری سطح آب در اواخر پاییز و زمستان برای آینده نزدیک را در منطقه برف‌آباد برآورد می‌کند (شکل ۴-ب). افزایش ۱ تا ۲ متری در تمام ماه‌های آینده میانی و افزایش ۱ تا ۱/۵ متری در پاییز برای آینده دور بالاترین نوسانات این منطقه تحت شرایط SSP2-4.5 است. در منطقه بورگ، افزایش در ماه‌های زمستان و همچنین دسامبر (۱/۵ و ۲ متر) در آینده نزدیک، افزایشی بین ۲ تا ۳ متر در اکثر ماه‌های سال در آینده میانی و روند صعودی جزئی آینده دور، اصلی‌ترین تغییرات هستند (شکل ۴-ج). در میانگین پیرومترهای منطقه جنگه، افزایش ۱/۵ تا ۲/۵ متری در زمستان و پاییز در آینده نزدیک، افزایش قابل توجه و نسبتاً شدید ۱/۵ تا ۲ متری در بهار و زمستان و ۲/۵ تا ۳/۵ متری در تابستان و پاییز در آینده میانی ملاحظه می‌شود. همچنین، به استثنای افت ۱/۵ تا ۲ متری در دسامبر و ژانویه در آینده دور، ثبات نسبی در آینده دور پیش‌بینی می‌شود (شکل ۴-الف). بنابراین شرایط مناسبی نیز تحت این سناریو برای دشت اسلام‌آباد برآورد می‌شود.

سناریو SSP5-8.5

سناریو SSP5-8.5 که بیانگر افزایش شدید انتشار گازهای گلخانه‌ای و تأثیرات حداکثری تغییرات اقلیمی است نیز، شرایط مناسبی را برای GWL در دشت اسلام‌آباد به نمایش می‌گذارد. در منطقه پیرومترهای برف‌آباد تحت این سناریو بهبود وضعیت GWL پیش‌بینی می‌شود. افزایش ۱ متر، ۱/۵ تا ۲ متر و تا حدود ۲/۵ متر را برای پاییز به ترتیب در آینده نزدیک، میانی و دور در شرایط SSP5-8.5 بهترین شرایط برآورد شده را برای این منطقه نشان می‌دهد (شکل ۴-ب). در بورگ نیز این افزایش ملاحظه می‌شود. بطوریکه افزایش

۱ تا ۲ متر در زمستان و پاییز در آینده میانی و حتی ۲ تا ۲/۵ متر در آینده دور پیش‌بینی می‌شود (شکل ۴-ج). میانگین پیرومترهای منطقه جنگه نیز افزایش ۱ تا ۲ متر، ۲/۵ تا ۳ متر و ۳ تا ۳/۵ متر را برای فصل پاییز به عنوان نماینده فصل با بیشترین افزایش، تحت سناریوی SSP5-8.5 در آینده‌های نزدیک، میانی و دور نمایش می‌دهد (شکل ۴-الف).





شکل ۴. تفاسیل میانگین ماهانه GWL آینده نزدیک (۲۰۲۶-۲۰۵۰)، میانی (۲۰۵۱-۲۰۷۵) و دور (۲۰۷۶-۲۱۰۰) نسبت به دوره مشاهداتی (۱۹۹۷-۲۰۱۴)

روند تغییرات سطح آب زیرزمینی

مشاهداتی

در دوره ۱۹۹۷ تا ۲۰۱۴، روند تغییرات آب زیرزمینی نشان‌دهنده کاهش شدید و پیوسته GWL در جنگه بوده است. مقدار U (که شاخص مقایسه‌ای آزمون من-کندال است و مقدار انحراف از میانگین را نمایش می‌دهد) برابر ۰/۸۸- است که نشان‌دهنده یک روند نزولی قوی می‌باشد. همچنین، مقدار شیب روند برابر ۰/۵۹- متر در سال نشان می‌دهد که هر سال GWL به طور متوسط حدود ۰/۵۹ متر پایین‌تر رفته است. مقدار p-value کمتر از ۰/۰۰۱ است، که این روند را از نظر آماری کاملاً معنی‌دار می‌کند (شکل ۵-الف). بر اساس داده‌های مشاهده‌ای میانگین پیرومترهای منطقه برف‌آباد، GWL در منطقه برف‌آباد کاهش قابل توجهی داشته است. مقدار U برابر با ۱- و مقدار p-value کمتر از ۰/۰۰۱ است که نشان‌دهنده یک روند نزولی بسیار قوی و معنادار در سطح ۰/۰۵ است. مقدار شیب روند نیز برابر با ۱- است که شدت کاهش در هر سال را نشان می‌دهد (شکل ۵-ب).

داده‌های مشاهده‌ای نشان‌دهنده کاهش شدید و معنادار GWL در منطقه بورگ است. مقدار U برابر با ۰/۸۹- و مقدار p-value کمتر از ۰/۰۰۱ است که نشان‌دهنده روند نزولی بسیار قوی و معنادار در سطح ۰/۰۵ است. همچنین مقدار شیب روند برابر با ۰/۷۱۵- است که نشان‌دهنده نرخ بالای افت GWL طی این دوره است (شکل ۵-ج). روند نزولی در مناطق مختلف دشت اسلام‌آباد در دوره مشاهداتی حاکی از برداشت بی‌رویه آب، کاهش بارندگی، افزایش دمای هوا و کاهش نفوذ آب به منابع زیرزمینی است. این عوامل منجر به افزایش تنش آبی و کاهش دسترسی به منابع پایدار آب در این مناطق شده‌اند، که می‌تواند پیامدهای جدی برای کشاورزی و تأمین آب شرب داشته باشد.

سناریوی SSP1-2.6

این سناریو نمایانگر شرایطی است که در آن اقدامات جدی برای کاهش انتشار گازهای گلخانه‌ای اتخاذ شده و تغییرات اقلیمی در مسیر کنترل‌شده‌ای قرار دارد. تحلیل روند GWL در این سناریو نشان می‌دهد که واکنش منابع آب زیرزمینی به این تغییرات در دوره‌های آینده نزدیک (۲۰۲۶-۲۰۵۰)، میانی (۲۰۵۱-۲۰۷۵) و دور (۲۰۷۶-۲۱۰۰) متفاوت خواهد بود.

آینده نزدیک: در این دوره، GWL در تمام مناطق دشت اسلام‌آباد روندی کاهشی دارد، اما شدت آن نسبت به دوره مشاهداتی کمتر است. مقدار U برای جنگه (۰/۴۱-)، برف‌آباد (۰/۴۸-) و بورگ (۰/۵۹۳-) نشان‌دهنده یک روند نزولی معنادار در سطح ۰/۰۵ است. مقدار p-value نیز برای این مناطق به ترتیب ۰/۰۰۴، ۰/۰۰۱ و ۰/۰۰۱ است که تأییدکننده این کاهش معنادار است.

با این حال، مقدار شیب روند که برای جنگه ۰/۰۷- متر در سال، برف‌آباد صفر و بورگ ۰/۲۱- متر در سال گزارش شده، بیانگر کاهش کمتر شدت افت سطح آب نسبت به دوره مشاهداتی است (شکل ۵). این کاهش ملایم‌تر می‌تواند ناشی از تأثیر سیاست‌های اقلیمی بر افزایش بارندگی و کاهش تبخیر باشد، اما همچنان برداشت آب از منابع زیرزمینی بیش از تغذیه آن است.

آینده میانی: در این دوره، روند GWL در مناطق مختلف دشت اسلام‌آباد متفاوت است. در جنگه، روند کاهش GWL نه‌تنها ادامه دارد، بلکه نسبت به آینده نزدیک تشدید شده است. مقدار U برابر با ۰/۴۹- و مقدار p-value (۰/۰۰۱) نشان‌دهنده کاهش معنادار GWL است. شیب روند نیز ۰/۱۴- متر در سال محاسبه شده که از افزایش شدت افت سطح آب حکایت دارد. در برف‌آباد، مقدار U (۰/۲۲-) و مقدار p-value (۰/۱۲۹) نشان‌دهنده یک روند نزولی است. اما از لحاظ آماری معنادار نیست. این موضوع حاکی از تثبیت نسبی سطح آب در این منطقه است. در مقابل، در بورگ مقدار U (صفر) و p-value (۱) نشان می‌دهد که در این دوره روند خاصی مشاهده نمی‌شود و GWL در این منطقه به‌طور کلی تثبیت شده است (شکل ۵).

آینده دور: در این دوره، برخلاف روندهای گذشته، تغییرات مثبتی در GWL برخی مناطق مشاهده می‌شود. در جنگه، مقدار U (۰/۳۶) و مقدار p-value (۰/۰۱۶) نشان‌دهنده یک روند افزایشی معنادار در سطح ۰/۰۵ است. مقدار شیب روند ۰/۱۸+ متر در سال نیز مؤید این بهبود شرایط است؛ که احتمالاً نتیجه اجرای سیاست‌های موفق کاهش انتشار گازهای گلخانه‌ای، افزایش بارندگی و بهبود مدیریت منابع آب است. در برف‌آباد و بورگ مقدار U (به ترتیب ۰/۲۱۷ و ۰/۱۳۸) و مقدار p-value (به ترتیب ۰/۱۴۳ و ۰/۳۵۹) حاکی از یک روند افزایشی است، اما از لحاظ آماری معنادار نیست. هرچند روند افزایش GWL وجود دارد، اما این افزایش از نظر آماری معنادار نیست. مقدار شیب روند (صفر و ۰/۱۱۴+ متر در سال) در این دو منطقه نشان می‌دهد که بهبود نسبی در GWL این منطقه محتمل است (شکل ۵).

سناریوی SSP2-4.5

سناریوی SSP2-4.5 م‌سیری متعادل‌تر از نظر توسعه اقتصادی و زیست‌محیطی ارائه می‌دهد، اما مدیریت منابع آب همچنان یک چالش اساسی در این مسیر باقی می‌ماند. بررسی روند GWL در این سناریو نشان می‌دهد که تغییرات GWL در دوره‌های آینده نزدیک، میانی و دور الگوهای متفاوتی را در مناطق مختلف دشت اسلام‌آباد دنبال می‌کند.

آینده نزدیک: در این دوره، برخلاف سناریوی SSP1-2.6، GWL در تمامی مناطق دشت اسلام‌آباد روندی افزایشی دارد. مقدار U برای جنگه (۰/۳۳۳-)، برف‌آباد (۰/۴-) و بورگ (۰/۳۳۳-) نشان‌دهنده افزایش معنادار GWL در سطح ۰/۰۵ است. مقدار p-value نیز به ترتیب ۰/۰۲۱، ۰/۰۰۵ و ۰/۰۲۱ بوده که تأییدکننده این روند افزایشی است. همچنین، مقدار شیب روند برای این مناطق به ترتیب ۰/۱۲+ متر در سال، صفر و ۰/۱۳+ متر در سال گزارش شده است. این افزایش GWL احتمالاً ناشی از بهبود مدیریت منابع آب و افزایش تغذیه آبخوان‌ها در این دوره است (شکل ۵).

آینده میانی: در این دوره، روند افزایشی GWL در جنگه متوقف شده و مجدداً کاهش آن آغاز می‌شود. مقدار U (۰/۳۲-) و مقدار p-value (۰/۰۲۷) نشان‌دهنده روند نزولی معنادار است. مقدار شیب روند ۰/۰۷- متر در سال نیز بیانگر کاهش سطح آب در این منطقه است. در برف‌آباد و بورگ نیز این الگوی نزولی مشاهده می‌شود، به‌طوری که مقدار U در این مناطق به ترتیب ۰/۳۸- و ۰/۳۶- و مقدار p-value برابر ۰/۰۰۸ و ۰/۰۱۲ است که روند کاهش GWL را تأیید می‌کند. مقدار شیب روند در بورگ (۰/۰۸-) متر در سال نشان می‌دهد که افت GWL در این منطقه نیز وقوع خواهد یافت (شکل ۵). این کاهش ممکن است ناشی از افزایش بهره‌برداری از منابع آب در این دوره باشد.

آینده دور: در بلندمدت، کاهش GWL در تمامی مناطق دشت اسلام‌آباد شدت می‌یابد. مقدار U برای جنگه (۰/۴۸-)، برف‌آباد (۰/۴۹-) و بورگ (۰/۵۷-) نشان‌دهنده یک روند نزولی قوی و معنادار در سطح ۰/۰۵ است. مقدار p-value نیز در تمامی مناطق ۰/۰۰۱ ≤ بوده، که این روند نزولی را تأیید می‌کند. مقدار شیب روند نیز در جنگه ۰/۰۹- متر در سال، برف‌آباد، صفر و بورگ ۰/۱۶- متر در سال پیش‌بینی می‌شود که نشان‌دهنده این است که افت GWL در این دوره شدت بیشتری خواهد داشت (شکل ۵).




همچنین این روند نشان‌دهنده افزایش فشار بر منابع آب زیرزمینی در سناریوی SSP2-4.5 و لزوم مدیریت مؤثرتر مصرف آب در بلندمدت است.

سناریوی SSP5-8.5

سناریوی SSP5-8.5 نمایانگر افزایش شدید دما و تغییرات اقلیمی گسترده است که می‌تواند تأثیرات قابل توجهی بر منابع آب داشته باشد. بررسی روند GWL در مناطق مختلف دشت اسلام‌آباد تحت این سناریو نشان می‌دهد که تغییرات آن در دوره‌های آینده نزدیک، میانی و دور الگوهای متفاوتی را خواهد داشت.

آینده نزدیک: در این دوره، GWL در منطقه جنگه روند افزایشی معناداری دارد. $U = 0/31$ ، $p\text{-value} = 0/034$ و شیب روند $0/058$ متر در سال حاکی از این افزایش است. در برف‌آباد و بورگ نیز افزایش سطح آب پیش‌بینی می‌شود. اما این روند از لحاظ آماری معنادار نیست. U به ترتیب $0/173$ و $0/14$ ، $p\text{-value} = 0/234$ و $0/338$ و مقدار شیب روند در بورگ $0/06$ متر در سال، افزایش اندک را نشان می‌دهد (شکل ۵). این افزایش احتمالی GWL ممکن است ناشی از تغییرات کوتاه‌مدت در الگوی بارش و تغذیه آبخوان‌ها باشد. آینده میانی: در این دوره، روند افزایشی GWL در تمامی مناطق معنادار و تقویت می‌شود. مقدار U در جنگه ($0/493$)، برف‌آباد ($0/493$) و بورگ ($0/34$) نشان‌دهنده یک افزایش معنادار در سطح $0/05$ است. مقدار $p\text{-value}$ برای جنگه ($0/001$)، برف‌آباد ($0/001$) و بورگ ($0/018$) نیز این روند را تأیید می‌کند. مقدار شیب روند برای این مناطق به ترتیب $0/14$ متر در سال، صفر و $0/098$ متر در سال گزارش شده است (شکل ۵). افزایش معنادار GWL در این دوره ممکن است به دلیل تغییرات اقلیمی منجر به افزایش بارش‌های ناگهانی یا بهبود نسبی تغذیه آبخوان‌ها باشد.

آینده دور: برخلاف روند افزایشی دوره‌های قبل، در آینده دور GWL در منطقه جنگه و برف‌آباد کاهش می‌یابد، اما این کاهش از نظر آماری معنادار نیست. $U = -0/224$ ، $p\text{-value} = 0/13$ و شیب روند $-0/03$ متر در سال نشان‌دهنده کاهش ضعیف اما غیرمعنادار است. در مقابل، در بورگ روند افزایشی بسیار ضعیفی دیده می‌شود. $U = 0/123$ ، $p\text{-value} = 0/413$ ، شیب روند $0/017$ متر در سال، اما این روند نیز از لحاظ آماری معنادار نیست (شکل ۵). این نتایج نشان می‌دهد که در آینده دور، اگرچه برخی مناطق ممکن است به‌طور نسبی تثبیت یا کاهش اندکی در GWL را تجربه کنند، اما این تغییرات عمدتاً غیرمعنادار خواهند بود و وابسته به میزان بهره‌برداری از منابع آب در طول زمان هستند.



شکل ۵. روند عمق آب زیرزمینی در مناطق مختلف دشت اسلام آباد، دوره مشاهداتی و تحت سناریوهای مختلف SSP در آینده نزدیک، میانی و دور

بحث

در این پژوهش، استفاده از مدل RF برای پیش‌بینی GWL در دشت اسلام‌آباد غرب، نتایج قابل توجهی را به همراه داشت. این نتایج نشان می‌دهند که مدل RF قادر است عملکرد مطلوبی در پیش‌بینی تغییرات GWL به ویژه در شرایط آینده با استفاده از سناریوهای تغییرات اقلیمی مختلف (SSP2-2.6، SSP2-4.5 و SSP5-8.5) نشان دهد. مطالعات دیگر نیز عملکرد این مدل را در مقایسه با مدل‌های دیگر، خصوصاً مدل‌های مبتنی بر داده‌های سنتی و پیش‌بینی‌های عددی، بالاتر برآورد کرده‌اند (Mohammed et al., 2024; Pourmorad et al., 2024).

نتایج این پژوهش نشان می‌دهد که تغییرات اقلیمی نقش قابل توجهی در کاهش GWL در دشت اسلام‌آباد غرب دارد. بر روی روندهای آینده تحت سناریوهای مختلف اقلیمی بیانگر آن است که در صورت افزایش انتشار گازهای گلخانه‌ای و تشدید گرمایش جهانی، افت قابل توجهی در GWL این منطقه رخ خواهد داد. این یافته‌ها همچون مطالعات دیگر نشان می‌دهند که تغییرات اقلیمی و فشارهای انسانی باعث کاهش منابع آب زیرزمینی، خصوصاً در مناطق خشک و نیمه‌خشک می‌شود (اسمعیلی و مجرد، ۱۴۰۳). RF مانند مطالعات دیگر به دلیل توانایی بالا در پردازش داده‌های پیچیده و چندبعدی، از جمله ویژگی‌هایی نظیر انتخاب خودکار ویژگی‌ها، تطبیق‌پذیری با شرایط مختلف اقلیمی و استفاده از ویژگی حذف بازگشتی، موفقیت‌های بزرگی در پیش‌بینی سطح آب زیرزمینی در این تحقیق به دست آورد (Liu et al., 2024; Fang et al., 2024). مقدار R برابر با ۰/۹۷ نشان می‌دهد که مدل RF توانسته است با دقت بسیار بالا روند تغییرات GWL را پیش‌بینی کند. مقدار NSE در این مدل برای مناطق مختلف دشت اسلام‌آباد بین ۰/۸۹ تا ۰/۹۰ در دوره تست و بین ۰/۹۷ تا ۰/۹۸ در دوره آموزش محاسبه شده است، که نشان‌دهنده عملکرد بسیار دقیق مدل است. این نتیجه با تحقیقات پیشین (Gaber & Singla, 2024; Alamsyah et al., 2024; Gupta et al., 2024; Irmanda et al., 2025; نوروزی قوش‌بلاغ و ندیری، ۱۳۹۷؛ کماسی و دالوند، ۱۴۰۴) که مدل RF را به کار برده‌اند و دقت بالای آن را گزارش کردند، همخوانی دارد. علاوه بر این، مدل RF در مقایسه با مدل‌هایی مانند ARIMA و ANN، که بترتیب نیاز به داده‌های گسترده (Pourmorad et al., 2024) و گاهی در انتخاب بهینه متغیرها و یا ساختار مکانی ضعف دارند (Eghrari et al., 2023) عملکرد بهتری از خود نشان داده است (Sakizadeh et al., 2019).

نتایج این پژوهش همچنین نشان داد که مدل NorESM2-MM با تأثیر ۷۳/۳٪ تا ۷۸٪ در مناطق مختلف دشت اسلام‌آباد، دقیق‌ترین مدل برای پیش‌بینی GWL در این منطقه بوده است. این یافته‌ها نشان می‌دهد که ترکیب مدل‌های اقلیمی و روش‌های یادگیری ماشین می‌تواند منجر به بهبود چشمگیر دقت پیش‌بینی‌ها شود، که با مطالعات انجام‌شده توسط Kayhomayoon و همکاران (۲۰۲۱، ۲۰۲۲) و Fang و همکاران (۲۰۲۴) همخوانی دارد.

پیش‌بینی‌های انجام‌شده در این مطالعه، اهمیت توجه به مدیریت منابع آب زیرزمینی در مواجهه با تغییرات اقلیمی را برجسته می‌کند. کاهش GWL حتی در سناریوهای اقلیمی خوشبینانه مانند SSP1-2.6، ضرورت اجرای استراتژی‌های پایدار مدیریت آب را تقویت می‌کند. یافته‌های این تحقیق نشان می‌دهد که استفاده از مدل‌های پیشرفته یادگیری ماشین مانند RF می‌تواند ابزار قدرتمندی برای برنامه‌ریزی منابع آب در مناطق حساس به تغییرات اقلیمی باشد. این نتایج، مشابه با پژوهش‌هایی مانند تحقیق Bogireddy & Murari (۲۰۲۴)، تأکید می‌کند که الگوریتم‌های یادگیری ماشین می‌توانند در تحلیل و پیش‌بینی روندهای آینده منابع آب زیرزمینی نقش مهمی ایفا کنند.

بر اساس نتایج این پژوهش، پیشنهاد می‌شود که سیاست‌گذاران حوزه منابع آب، برنامه‌ریزی‌های سازگاری با تغییرات اقلیمی را با تمرکز بر آینده‌نگری در سطح آب زیرزمینی تقویت کنند. به‌ویژه، استفاده از مدل‌های یادگیری ماشین مانند RF می‌تواند برای ایجاد سامانه‌های هشدار سریع در مناطق پرخطر، ارزیابی سناریوهای مختلف بهره‌برداری و تدوین سیاست‌های کاهش فشار بر آبخوان‌ها در فصول بحرانی به کار گرفته شود. از آنجاییکه با این روش می‌توان اثرات آینده را در زمان حال بررسی نمود لذا زمان کافی برای اندیشیدن تمهیدات لازم جهت مقابله با فرونشست و مدیریت تقاضا در اختیار مدیران صنعت آب وجود خواهد داشت.

پیشنهاد می‌شود که ادارات منابع آب منطقه‌ای، پایش پیوسته و داده‌محور GWL را در دستور کار قرار داده و نتایج پایش‌بینی‌های علمی را در تصمیم‌گیری‌های مدیریتی (مانند زمان‌بندی برداشت، تخصیص منابع، یا اعمال محدودیت فصلی) لحاظ کنند. همچنین، طراحی و اجرای سیاست‌های سازگاری مانند ارتقای راندمان آبیاری، توسعه زیرساخت‌های تغذیه مصنوعی و آموزش بهره‌برداران می‌تواند به کاهش آسیب‌پذیری مناطق نیمه‌خشک نسبت به بحران آب کمک نماید.

نتیجه‌گیری

نتایج این پژوهش نشان داد که روند تغییرات GWL در دشت اسلام‌آباد غرب طی دوره م‌شاهداتی (۱۹۹۷-۲۰۱۴) به‌طور معناداری کاهش یافته است. بیشترین افت GWL در این دوره در منطقه برف‌آباد با مقدار ۱ متر در سال مشاهده شد، درحالی‌که در مناطق جنگه و بورگ این مقدار به‌ترتیب ۰/۵۹ و ۰/۷۱۵ متر در سال برآورد شده است. این کاهش عمدتاً به دلیل افزایش بهره‌برداری از منابع آب زیرزمینی، کاهش بارندگی و افزایش دما رخ داده است. در سناریوی SSP1-2.6، کاهش GWL در آینده نزدیک (۲۰۲۶-۲۰۵۰) معنادار بوده و در منطقه بورگ با شیب ۰/۲۱- متر در سال اتفاق می‌افتد. در آینده میانی (۲۰۵۱-۲۰۷۵)، افت GWL در جنگه با شیب ۰/۱۴- متر در سال ادامه خواهد داشت. در سناریوی SSP2-4.5، کاهش GWL در آینده دور (۲۱۰۰-۲۰۷۶) در تمامی مناطق دشت اسلام‌آباد معنادار بوده و در بورگ با شیب ۰/۱۶- متر در سال بیشترین مقدار را خواهد داشت.

در پایش‌بینی‌های آینده، بیشترین افزایش GWL در منطقه جنگه تحت سناریوی SSP5-8.5، با مقدار ۳ تا ۳/۵ متر در پاییز آینده دور پایش‌بینی می‌شود. در مقابل، بیشترین کاهش GWL تحت شرایط سناریوی SSP1-2.6 در منطقه بورگ، با افتی بین ۳/۵ تا ۴ متر در ماه‌های بهار و تابستان در آینده میانی انتظار می‌رود. همچنین، برای سناریوهای کم‌انتشار مانند SSP1-2.6 و SSP2-4.5، شرایط نسبتاً پایدارتری در آینده دور پایش‌بینی شده است.

دقت RF در پایش‌بینی GWL در تمامی مناطق دشت اسلام‌آباد بسیار بالا بود. مقادیر R برابر با ۰/۹۷ و شاخص NSE بین ۰/۸۹ تا ۰/۹۸ در مناطق مختلف نشان‌دهنده قابلیت بالای این مدل در پایش‌بینی دقیق تغییرات GWL است. همچنین، مدل NorESM2-MM به‌عنوان بهترین مدل اقلیمی برای شبیه‌سازی GWL شناسایی شد و ترکیب آن با سایر مدل‌های CMIP6 دقت پایش‌بینی را تا حدود ۹۹/۵٪ افزایش داد. این نشان می‌دهد که استفاده از ترکیب مدل‌های رطوبت خاک CMIP6 به تنهایی، با RF می‌تواند تأثیر بسزایی در بهبود دقت پایش‌بینی‌ها داشته باشد. در مجموع، این پژوهش نشان داد که تغییرات اقلیمی و فشارهای انسانی بر منابع آب زیرزمینی تأثیر قابل‌توجهی دارند و RF می‌تواند به‌عنوان یک ابزار قدرتمند برای پایش‌بینی و مدیریت پایدار منابع آب زیرزمینی در دشت اسلام‌آباد غرب و مناطق مشابه مورد استفاده قرار گیرد.

تعارض منافع

هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد.

منابع

۱. اسمعیلی، شکوفه و مجرد، فیروز (۱۴۰۳). بررسی پایداری سطح آب زیرزمینی در دشت اسلام‌آباد غرب (استان کرمانشاه) و ارزیابی وضعیت آینده با مدل‌های گردش عمومی جو. هیدروژئومورفولوژی، ۱۱ (۴۱)، ۱۱۵-۱۳۴.
<https://doi.org/10.22034/hyd.2024.62351.1747>
۲. باقرآبادی، رسول (۲۰۲۲). بررسی خشکسالی هواشناسی اسلام‌آباد غرب با استفاده از شاخص‌های خشکسالی. مهندسی آب، ۱۰ (۲)، ۱۳۶-۱۴۸.

۳. باقری خانقاهی، هزارجریبی؛ ابوطالب، کمالی و زمانی، محمدا سماعیل (۱۴۰۴). پیش‌نمایی بارندگی مناطق مختلف آب‌وهوایی ایران با استفاده از مدل اقلیمی LARS WG7. منابع آب و تغییر اقلیم، ۱(۱)، ۳۹-۲۸.
<http://dx.doi.org/10.22091/wrcc.2025.11744.1008>
۴. پناهی، مهدی؛ میثاقی، فرهاد و قنبری، فرید (۱۳۹۶). تعیین روند تغییرات پارامترهای کیفی آبهای زیرزمینی دشت شبستر. علوم محیطی، ۱۵ (۳)، ۱۹-۳۸.
https://envs.sbu.ac.ir/article_97862.html
۵. پور صالحی، فاطمه؛ خاشعی سیوکی، عباس و هاشمی، سیدرضا (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). اکوهیدرولوژی، ۸ (۴)، ۹۶۱-۹۷۴.
<http://dx.doi.org/10.22059/ije.2022.327263.1526>
۶. دالوند، رضوان و کماسی، مهدی (۱۴۰۴). ارزیابی مدل‌های درخت تصمیم غیرپارامتریک برای پیش‌بینی عمق آبستگي پایه‌های پل. منابع آب و تغییر اقلیم، ۱(۱)، ۵۰-۴۰.
<http://dx.doi.org/10.22091/wrcc.2025.11363.1005>
۷. سلطان‌نژاد، کبری؛ معصوم پور سماکوش، جعفر؛ مجرد، فیروز؛ هادی‌پور، سحر و جلیلیان، عبداله (۱۴۰۲). تحلیل روند و تنوع فضایی خشکی در اقلیم آلوده ایران. پژوهش‌های جغرافیای طبیعی، ۵۵ (۲)، ۵۰-۲۵.
<http://dx.doi.org/10.22059/jphgr.2023.361339.1007777>
۸. عباتی، آزاده و ادب، حامد (۱۴۰۱). ارزیابی روش‌های یادگیری ماشین در ریزمقیاس‌نمایی مکانی میانگین سالانه دمای سطح زمین و دمای هوا. محیط زیست طبیعی، ۷۵ (۴)، ۵۵۱-۵۶۹.
<http://dx.doi.org/10.22059/jne.2022.340875.2416>
۹. فاطمی، سید احسان؛ قبادیان، رسول و پاک‌بین، مژگان (۱۳۹۷). پیش‌بینی عمق آب زیرزمینی با استفاده از مدل طیف‌سنجی سری‌های زمانی. دانش آب و خاک، ۲۸ (۱)، ۱۴۵-۱۵۸.
https://water-soil.tabrizu.ac.ir/article_7600.html
۱۰. کریمی‌نژاد، حسام؛ فاطمی، سید احسان و حافظ پرست موت، مریم (۱۴۰۲). طبقه‌بندی جریان فصلی سد جامی‌شان با روش K-means و اثر آن در برنامه‌ریزی پویای تصادفی. فناوری‌های پیشرفته در بهره‌وری آب، ۳ (۲)، ۱۵-۳۲.
<http://dx.doi.org/10.22126/atwe.2023.9111.1052>
۱۱. گرگانی، شهرام؛ بافکار، علی و فاطمی، احسان (۱۳۹۶). پیش‌بینی استعداد لودگی آب‌های زیرزمینی با استفاده از شاخص دراستیک و تحلیل سری‌های زمانی سالانه (مطالعه موردی: دشت ماهیدشت کرمانشاه). سلامت و محیط زیست، ۱۰ (۳)، ۳۲۸-۳۱۷.
<http://ijhe.tums.ac.ir/article-1-5962-fa.html>
۱۲. 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>
۱۳. 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.
<http://dx.doi.org/10.22059/jrwm.2018.68924>
14. Adib, M. N. M., & Harun, S. (2022). Metalearning approach coupled with CMIP6 multi-GCM for future monthly streamflow forecasting. *Journal of Hydrologic Engineering*, 27(6), 05022004.
[https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0002176](https://doi.org/10.1061/(ASCE)HE.1943-5584.0002176)
15. Akurugu, C. A. (2024). Identifying Drivers of Groundwater Level Fluctuations in the Casper Aquifer Near Cheyenne, WY, Using Random Forest Model (Master's thesis, University of Wyoming).
16. Alamsyah, N., Budiman, B., Yoga, T. P., & Alamsyah, R. Y. R. (2024). Comparison linear regression and random forest models for prediction of underground drought levels in forest fires. *Jurnal Techno Nusa Mandiri*, 21(2), 81-86. <https://doi.org/10.33480/techno.v21i2.5237>
17. 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)
18. Amnuaylojaroen, T. (2023). Advancements in downscaling global climate model temperature data in southeast asia: a machine learning approach. *Forecasting*, 6(1), 1-17.

19. Araghi, A., Martinez, C. J., Adamowski, J., & Olesen, J.E. (2018). Spatiotemporal variations of aridity in Iran using high-resolution gridded data. *International Journal of Climatology*, 38 (6), 2701-2717. <https://doi.org/10.1002/joc.5454>
20. Atabati, A. & Adab, H. (2022). Evaluation of machine learning methods in spatial downscaling of average annual land surface temperature and air temperature. *Journal of Natural Environment*, 75(4), 551-569. <https://doi.org/10.22059/jne.2022.340875.2416> (In Persian).
21. Bagherabadi, Rasoul. (2022). Investigation of meteorological drought Eslamabad-e Gharb using of draught indices. *Water Engineering*, 10 (2), 136_148 (In Persian).
22. Bagheri-Khanghahi, M., Jaribi, A. H., Kamali, M. I., & Zamani, F. (2025). Forecasting Rainfall in Different Climatic Regions of Iran Using the LARS WG7 Climate Model. *Water Resources and Climate Change*, 10.22091/wrcc.2025.11244.1008 (In Persian)
23. Bochenek, B., & Ustrnul, Z. (2022). Machine learning in weather prediction and climate analyses—applications and perspectives. *Atmosphere*, 13(2), 180. <https://doi.org/10.3390/atmos13020180>
24. Bogireddy, S. R., & Murari, H. (2024, September). *Enhancing crop yield prediction through random forest classifier: A comprehensive approach*. In 2024 5th International Conference on Smart Electronics and Communication (ICOSEC) (pp. 1663-1668). IEEE. <http://dx.doi.org/10.1109/ICOSEC61587.2024.10722249>
25. 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>
26. 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>
27. 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. <https://doi.org/10.3390/atmos13060941>.
28. Eghrari, Z., Delavar, M. R., Zare, M., Mousavi, M., Nazari, B., & Ghaffarian, S. (2023). Groundwater level prediction using deep recurrent neural networks and uncertainty assessment. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 493-500. <https://doi.org/10.5194/isprs-annals-X-1-W1-2023-493-2023>
29. Esmaeili, S. & Mojjarrad, F. (2025). Investigating the stability of the groundwater level in the Eslamabad-e Gharb plain (Kermanshah province) and evaluating the future situation with atmospheric general circulation models. *Hydrogeomorphology*, 11(41), 134-115. <https://doi.org/10.22034/hyd.2024.62351.1747> (In Persian)
30. Fang, W., Ren, K., Liu, T., Shang, J., Jia, S., Jiang, X., & Zhang, J. (2024). An evaluation of random forest based input variable selection methods for one month ahead streamflow forecasting. *Scientific Reports*, 14(1), 29766. <https://doi.org/10.1038/s41598-024-81502-y>
31. 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)
32. 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>
33. Gaber, K. Sh., & Singla, M. K. (2025). Predictive analysis of groundwater resources using Random Forest regression. *Journal of Artificial Intelligence and Metaheuristics*, 9(1), 11–19. <https://doi.org/10.54216/JAIM.090102>
34. Gidden, M. J., Riahi, K., Smith, S. J., Fujimori, S., Luderer, G., Kriegler, E., van Vuuren, D. P., van den Berg, M., Feng, L., Klein, D., Calvin, K., Doelman, J. C., Frank, S., Fricko, O., Harmsen, M., Hasegawa, T., Havlik, P., Hilaire, J., Hoesly, R., Horing, J., Popp, A., Stehfest, E., & Takahashi, K. (2019). Global emissions pathways under different socioeconomic scenarios for use in CMIP6: a dataset of harmonized emissions trajectories through the end of the century. *Geoscientific model development*, 12(4), 1443-1475. <https://doi.org/10.5194/gmd-12-1443-2019>

35. Gorgani, S., Bafkar, A., & Fatemi, S. E. (2017). Prediction of groundwater pollution potential using the DRASTIC index and annual time series analysis (case study: plain Mahidasht Kermanshah). *Journal of Health and Environment*, 10 (3), 317-328. <http://ijhe.tums.ac.ir/article-1-5962-en.pdf> (In Persian)
36. 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>
37. Irmanda, H. N., Ermatita, E., bin Awang, M. K., & Adrezo, M. (2024). Enhancing Weather Prediction Models through the Application of Random Forest Method and Chi-Square Feature Selection. *International Journal on Informatics Visualization*, 8(3-2), 1506-1514. <http://dx.doi.org/10.62527/ijoiv.8.3.2356>
38. Islam, M. S. (2023). Groundwater: Sources, functions, and quality. In *Hydrogeochemical evaluation and groundwater quality* (pp. 17-36). Cham: Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-44304-6-2>.
39. Jin, H., Jiang, W., Chen, M., Li, M., Bakar, K. S., & Shao, Q. (2023). Downscaling long lead-time daily rainfall ensemble forecasts through deep learning. *Stochastic Environmental Research and Risk Assessment*, 37(8), 3185-3203. <https://doi.org/10.1007/s00477-023-02444-x>
40. Kardan Moghaddam, H., Ghordoyee Milan, S., Kayhomayoon, Z., Rahimzadeh kivi, Z., & Arya Azar, N. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environmental Monitoring and Assessment*, 193(4), 173. <https://doi.org/10.1007/s10661-021-08961-y>
41. Kariminezhad, H., Fatemi, S. E., & Hafezparast Mavadat, M. (2023). Reservoir inflow Classification of Jamishan reservoir by K-means method and its effect on stochastic dynamic programming. *Advanced Technologies in Water Efficiency*, 3(2), 15-32. <https://doi.org/10.22126/atwe.2023.9111.1052> (In Persian)
42. Kayhomayoon, Z., Ghordoyee Milan, S., Arya Azar, N., & Kardan Moghaddam, H. (2021). A new approach for regional groundwater level simulation: clustering, simulation, and optimization. *Natural Resources Research*, 30, 4165-4185. <https://doi.org/10.1007/s11053-021-09913-6>
43. Kayhomayoon, Z., Ghordoyee-Milan, S., Jaafari, A., Arya-Azar, N., Melesse, A. M., & Moghaddam, H. K. (2022). How does a combination of numerical modeling, clustering, artificial intelligence, and evolutionary algorithms perform to predict regional groundwater levels? *Computers and Electronics in Agriculture*, 203, 107482. <https://doi.org/10.1016/j.compag.2022.107482>
44. Komasi, M. & Dalvand, R. (2025). Evaluation of nonparametric decision tree models for predicting scour depth of bridges. *Water Resources and Climate Change*, 1(1), 40-50. [10.22091/wrcc.2025.11363.1005](https://doi.org/10.22091/wrcc.2025.11363.1005) (In Persian)
45. Liu, B., Sun, Y., & Gao, L. (2024). Enhancing Groundwater Recharge Prediction: A Feature Selection-Based Deep Forest Model With Bayesian Optimisation. *Hydrological Processes*, 38(10), e15309. <https://doi.org/10.1002/hyp.15309>
46. Mannik, M., Birkse, J., & Karro, E. (2024, April). Groundwater vulnerability and pollution risk assessment in the Estonian-Latvian transboundary area. In EGU General Assembly Conference Abstracts (p. 16280). <https://doi.org/10.5194/egusphere-egu24-16280>
47. Mendoza Paz, S., Villazón Gómez, M. F., & Willems, P. (2024). Adapting to Climate Change with Machine Learning: The Robustness of Downscaled Precipitation in Local Impact Analysis. *Water*, 16(21), 3070. <https://doi.org/10.3390/w16213070>
48. Miao, Y., & Xu, Y. (2024, June). Random Forest-Based Analysis of Variability in Feature Impacts. In 2024 IEEE 2nd International Conference on Image Processing and Computer Applications (ICIPCA) (pp. 1130-1135). IEEE. <https://doi.org/10.1109/ICIPCA61593.2024.10708791>
49. 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>
50. Mohammed, K. S., Shabanlou, S., Rajabi, A., Yosefvand, F., & Izadbakhsh, M. A. (2023). Prediction of groundwater level fluctuations using artificial intelligence-based models and GMS. *Applied Water Science*, 13(2), 54. <https://doi.org/10.1007/s13201-022-01861-7>

51. 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 Management*, 71(3), 829-845. doi: <https://doi.org/10.22059/jrwm.2018.68924> (In Persian)
52. O'Neill, B. C., Tebaldi, C., van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J.-F., Lowe, J., Meehl, G. A., Moss, R., Riahi, K., and Sanderson, B. M. (2016), The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geosci. Model Dev.*, 9, 3461–3482. <https://doi.org/10.5194/gmd-9-3461-2016>
53. Panahi, M., Misaqi, F. and Ghanbari, F. (2017). Determining of trend variation in quality parameters of Shabestar plain underground water. *Environmental Sciences*, 15(3), 19-38. https://envs.sbu.ac.ir/article_97862.html (In Persian)
54. Pang, B., Yue, J., Zhao, G., & Xu, Z. (2017). Statistical downscaling of temperature with the random forest model. *Advances in Meteorology*, 2017(1), 7265178. <https://doi.org/10.1155/2017/7265178>
55. Pourmorad, S., Kabolizade, M., & Dimuccio, L. A. (2024). Artificial Intelligence Advancements for Accurate Groundwater Level Modelling: An Updated Synthesis and Review. *Applied Sciences*, 14(16), 7358. <https://doi.org/10.3390/app14167358>
56. Poursalehi, F., KhasheiSiuki, 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. <http://dx.doi.org/10.22059/jje.2022.327263.1526> (In Persian)
57. Rampal, N., Hobeichi, S., Gibson, P. B., Baño-Medina, J., Abramowitz, G., Beucler, T., González-Abad, J., Chapman, W., Harder, P., & Gutierrez, J. M. (2024). Enhancing regional climate downscaling through advances in machine learning. *Artificial Intelligence for the Earth Systems*, 3(2), 230066. <https://doi.org/10.1175/AIES-D-23-0066.1>
58. Sakizadeh, M., Mohamed, M. M., & Klammler, H. (2019). Trend analysis and spatial prediction of groundwater levels using time series forecasting and a novel spatio-temporal method. *Water Resources Management*, 33, 1425-1437. <https://doi.org/10.1007/s11269-019-02208-9>
59. Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random forest algorithm overview. *Babylonian Journal of Machine Learning*, 2024, 69-79. <https://doi.org/10.58496/BJML/2024/007>
60. Soltani, K., masoompour samakosh, J., Mojarad, F., Hadi Pour, S. and Jalilian, A. (2023). Analysis of the Trend and Spatial Variation of Aridity in the Future Climate of Iran. *Physical Geography Research*, 55(2), 25-50. <https://doi.org/10.22059/jphgr.2023.361339.1007777> (In Persian)
61. Tang, K., Zhu, H., & Ni, P. (2021). Spatial downscaling of land surface temperature over heterogeneous regions using random forest regression considering spatial features. *Remote Sensing*, 13(18), 3645. <https://doi.org/10.3390/rs13183645>
62. Tang, T., Liu, T., & Gui, G. (2024). Forecasting precipitation and temperature evolution patterns under Climate Change using a Random Forest Approach with Seasonal Bias correction. *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 17, 12609-12621. <https://doi.org/10.1109/JSTARS.2024.3425639>
63. Teimoori, S., Olya, M. H., & Miller, C. J. (2023). Groundwater level monitoring network design with machine learning methods. *Journal of Hydrology*, 625, 130145. <https://doi.org/10.1016/j.jhydrol.2023.130145>
64. 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>
65. 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>
66. Williams, S. A., Megdal, S. B., Zuniga-Teran, A. A., Quanrud, D. M., & Christopherson, G. (2024). Equity Assessment of Groundwater Vulnerability and Risk in Drinking Water Supplies in Arid Regions. *Water* (20734441), 16(23). <https://doi.org/10.3390/w16233520>

67. Yang, R., Zhong, Y., Zhang, X., Maimaitituersun, A., & Ju, X. (2025). A Comparative Study of Downscaling Methods for Groundwater Based on GRACE Data Using RFR and GWR Models in Jiangsu Province, China. *Remote Sensing*, 17(3), 493. <https://doi.org/10.3390/rs17030493>

فیلد استادی
نقشه