



Sustainable Soil Moisture Prediction in the Eslamabad Plain: A Machine Learning Approach to Climate Model Selection and Downscaling

Kobra Soltani^{ID 1} | Jafar Masoompour Samakosh^{ID 2} | Seyed Ehsan Fatemi^{ID 3} |
Maryam Hafezparast Mavadat^{ID 4}

1. Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran.
2. Corresponding Author, Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran. E-mail: j.masoompour@razi.ac.ir
3. Department of Water Engineering, Campus of Agriculture and Natural Resources, Razi University, Kermanshah, Iran.
4. Department of Water Engineering, Campus of Agriculture and Natural Resources, Razi University, Kermanshah, Iran.

Article Info

Article type:
Research Article

Article history:

Received: 28 Jan 2025

Received in revised form:
22 Feb 2025

Accepted: 24 Feb 2025

Available online: 22 Jun 2025

Keywords:

Eslamabad weather station,
CMIP6,
MERRA2,
Random forest,
Soil moisture.

ABSTRACT

Climate change and soil moisture reduction are significant challenges in water resource management, food security, and environmental sustainability. This study investigates the changes in the average monthly soil moisture values at the geographical location of the Eslamabad Synoptic Station in Kermanshah province utilizing MERRA2 data, historical (1991–2014), future scenarios data (SSP1-2.6, SSP2-4.5, and SSP5-8.5) from all CMIP6 models (r1i1p1f1 run) across three future periods: near (2026–2050), mid (2051–2075), and far (2076–2100). The Random Forest (RF) machine learning algorithm was utilized for downscaling and identifying the most effective soil moisture models from CMIP6 (achieving a total accuracy of 98%) by employing a Recursive Feature Elimination method in combination with k-fold validation. Out of 12 available models, 5 achieved an accuracy of 98% in predicting soil moisture. The MRI-ESM2-0 model was identified as the top model, with an accuracy of 87%. The other top 4 models collectively increased the final accuracy to 98%. RF evaluation confirmed its precise performance with metrics such as the Nash-Sutcliffe (0.98 for training and 0.78 for testing) and low error values (MAD = 0.01, MAE and MBE equal to zero). The results indicated a significant decrease in soil moisture during the future periods. A short reduction of 0.02 to 0.04 mm is projected for August and winter. In the mid and far future, a decrease of 0.03 to 0.05 mm under SSP5-8.5 is projected for most months. The annual trend indicates a decrease with rates of -0.0002 mm per year shortly under SSP2-4.5 and SSP5-8.5. At the same time, the SSP1-2.6 scenario predicts a trend of -0.0007 mm per year for the mid future. The results of this study are of particular environmental sustainability significance, as future soil moisture reduction could lead to increased water stress, decreased agricultural productivity, and pose a threat to regional food security.

Cite this article: 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. <https://doi.org/10.22126/GES.2025.11696.2832>



© The Author (s).

DOI: <https://doi.org/10.22126/GES.2025.11696.2832>

Publisher: Razi University

پیش‌بینی پایدار رطوبت خاک در دشت اسلام‌آباد: رویکرد یادگیری ماشین برای انتخاب مدل‌های اقلیمی و ریزمقیاس‌نمایی

کبری سلطانی^۱ | جعفر معصوم‌پور سماکوش^۲ | سید احسان فاطمی^۳ | مریم حافظ پرست مودت^۴

۱. گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران.
۲. نویسنده مسئول، گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران. رایانامه: j.masoompour@razi.ac.ir
۳. گروه مهندسی آب، پردیس کشاورزی و منابع طبیعی، دانشگاه رازی، کرمانشاه، ایران.
۴. گروه مهندسی آب، پردیس کشاورزی و منابع طبیعی، دانشگاه رازی، کرمانشاه، ایران.

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخچه مقاله: تاریخ دریافت: ۱۴۰۳/۱۱/۰۹ تاریخ بازنگری: ۱۴۰۳/۱۲/۰۴ تاریخ پذیرش: ۱۴۰۳/۱۲/۰۶ دسترسی آنلاین: ۱۴۰۴/۰۴/۰۱ کلیدواژه‌ها: اسلام‌آباد، جنگل تصادفی، رطوبت خاک، CMIP6، MERRA2	تغییرات اقلیمی و کاهش رطوبت خاک از جمله چالش‌های جدی در مدیریت منابع آب، امنیت غذایی و پایداری محیط‌زیست به شمار می‌روند. این پژوهش به بررسی تغییرات میانگین مقادیر ماهانه رطوبت خاک در موقعیت جغرافیایی ایستگاه سینوپتیک اسلام‌آباد در استان کرمانشاه با استفاده از داده‌های MERRA2، تاریخی (۱۹۹۱-۲۰۱۴) و سناریوهای آینده (SSP1-2.6، SSP2-4.5 و SSP5-8.5) تمام مدل‌های CMIP6 موجود (اجرای r1i1p1f1) در سه دوره آینده نزدیک (۲۰۲۶-۲۰۵۰)، میانی (۲۰۵۱-۲۰۷۵) و دور (۲۰۷۶-۲۱۰۰) پرداخته است. الگوریتم یادگیری ماشین جنگل تصادفی (RF) برای ریزمقیاس‌نمایی و شناسایی مؤثرترین مدل‌های رطوبت خاک CMIP6 (با مجموع ۹۸٪ دقت) با استفاده از ویژگی حذف بازگشتی در ترکیب با روش اعتبارسنجی متقابل k-fold استفاده شد. ۵ مدل از ۱۲ مدل موجود، به دقت ۹۸٪ در پیش‌بینی رطوبت خاک دست یافتند. مدل MRI-ESM2-0 با دقت ۸۷٪ به‌عنوان برترین مدل شناسایی شد. ۴ مدل برتر دیگر در مجموع دقت نهایی را به ۹۸٪ رساندند. ارزیابی RF عملکرد دقیقی آن را با معیارهایی نظیر ضریب نش (۰/۹۸) برای آموزش و ۰/۷۸ (برای تست) و خطای پایین (MAE، MAD = ۰/۰۱) و MBE برابر با صفر) تأیید کرد. نتایج نشان‌دهنده کاهش قابل توجه مقادیر رطوبت خاک در دوره‌های آینده است. در آینده نزدیک، کاهش ۰/۰۲ تا ۰/۰۴ میلی‌متری در اوت و ماه‌های فصل زمستان پیش‌بینی می‌شود. در آینده میانی و دور کاهش ۰/۰۳ تا ۰/۰۵ میلی‌متری تحت SSP5-8.5 برای بیشتر ماه‌ها پیش‌بینی می‌شود. روند میانگین سالانه کاهشی با شیب ۰/۰۰۲- در سال تحت SSP2-4.5 و SSP5-8.5 را برای آینده نزدیک شناسایی کرد. در حالیکه SSP1-2.6 روندی با مقدار ۰/۰۰۷- میلی‌متر در سال را برای آینده میانی پیش‌بینی می‌کند. نتایج این پژوهش از منظر پایداری محیطی اهمیت ویژه‌ای دارند، زیرا کاهش رطوبت خاک در آینده می‌تواند موجب افزایش تنش آبی، کاهش بهره‌وری کشاورزی و تهدید امنیت غذایی منطقه شود.
استناد: سلطانی، کبری؛ معصوم‌پور سماکوش، جعفر؛ فاطمی، سید احسان؛ حافظ پرست مودت، مریم (۱۴۰۴). پیش‌بینی پایدار رطوبت خاک در دشت اسلام‌آباد: رویکرد یادگیری ماشین برای انتخاب مدل‌های اقلیمی و ریزمقیاس‌نمایی. <i>جغرافیا و پایداری محیط</i>، ۱۵ (۲)، ۴۳-۶۱ https://doi.org/10.22126/GES.2025.11696.2832	

مقدمه

پیش‌بینی رطوبت خاک برای بهره‌وری کشاورزی، تاب‌آوری به خشکی، خشکسالی و مدیریت آب، به‌ویژه در مناطق وابسته به کشاورزی امری حیاتی است (Pinnington et al., 2018; Paul & Singh, 2020; Wu et al., 2024). کاهش رطوبت خاک، علاوه بر تأثیر بر تولید محصولات کشاورزی، می‌تواند به فرسایش خاک و کاهش کربن آلی آن منجر شود که این عوامل در تخریب اکوسیستم‌های طبیعی نقش دارند (Borah & Parmar, 2024). تعامل بین بارش و رطوبت خاک قوی‌تر از دما است و اهمیت بارندگی کافی برای حفظ میزان رطوبت خاک را برجسته می‌کند (Peng et al., 2023). اما با اینکه رطوبت خاک برای درک فرایندهای محیطی حیاتی است، اندازه‌گیری آن به دلیل تغییرات مکانی و زمانی چالش‌برانگیز است و به تکنیک‌های پیشرفته نظارت برای افزایش قابلیت‌های پیش‌بینی در هیدرولوژی و کشاورزی نیاز دارد (نورکی و همکاران، ۱۴۰۲).

رطوبت خاک برای تولید رواناب و انتقال مواد شیمیایی ضروری است، به‌ویژه در مناطق کوهستانی که دینامیک آن تحت تأثیر خصوصیات خاک است (Ye et al., 2023). رطوبت بالای خاک می‌تواند منجر به اوج زودتر جریان در حوادث بارندگی شود و بر پویایی سیل و مدیریت منابع آب تأثیر بگذارد (Horton et al., 2024; Ye et al., 2023). تغییرات رطوبت خاک می‌تواند به طور مستقیم بر رویدادهای خشکسالی کشاورزی نیز تأثیر بگذارد. کاهش رطوبت خاک می‌تواند منجر به کاهش تنوع زیستی، تخریب خاک و کاهش ظرفیت جذب کربن شود که همگی به ناپایداری شرایط و بحران‌های زیست‌محیطی مرتبط هستند (Zhou et al., 2023). این متغیر جریان آب و انرژی را تنظیم می‌کند و بر تغذیه آب زیرزمینی و رواناب سطحی تأثیر می‌گذارد (WMO, 2023; Sahoo & Sahoo, 2024). درک الگوهای فضایی و زمانی رطوبت خاک به‌منظور شناسایی پتانسیل‌های محیطی، بهبود فرایندهای تصمیم‌گیری در خدمات کشاورزی، برنامه‌ریزی آبیاری و مدیریت محصولات ضروری است (Horton et al., 2024; موسوی و همکاران، ۱۳۹۸).

مطالعات، کاهش جهانی رطوبت خاک، به‌ویژه در نیمکره جنوبی را ناشی از رخدادهای شدید آب‌وهوایی و عوامل محیطی نشان می‌دهد (Peng et al., 2023); بنابراین انتظار می‌رود تغییرات آب‌وهوا بر رطوبت خاک در مناطق کشاورزی تأثیر بگذارد؛ با تغییراتی در سطوح مختلف که بسته به مدل‌ها و سناریوهای اقلیمی متفاوت هستند (صالحی طبس و همکاران، ۱۳۹۸); چراکه اکثر داده‌های رطوبت خاک (مجموعه داده‌ها از آژانس فضایی اروپایی ابتکار تغییر آب‌وهوا^۱ ESA CCI)، رطوبت خاک بر اساس شبیه‌سازی‌های مدل زمین - سطح^۲ (LSMs) (CMIP6, GLEAM, GLDAS) و تحلیل مجدد (CRA-Land, MERRA2, ECMWF ERA5) نشان‌دهنده روند خشک‌شدن فراگیر در رطوبت خاک سطحی جهانی از سال ۱۹۸۰ تا ۲۰۲۰، به‌ویژه در مناطقی مانند آمریکای شمالی، اروپا و آفریقای شمالی است (Guan et al., 2023). اما گیاردینا و همکاران معتقدند که مدل‌های CMIP6 به‌طور کلی کاهش سالانه رطوبت خاک در جهان، به‌ویژه در آمزون را کمتر برآورد می‌کنند (Giardina et al., 2024).

در دشت نیشابور مدل INMCM3 تحت سناریوهای A2 و B1، بیشترین قطعیت و مدل GISS-ER تحت سناریو A2 و مدل CGCM3T47 تحت سناریو B1 کمترین قطعیت را در برآورد رطوبت سالانه اعماق خاک نشان داده‌اند (یعقوب زاده و همکاران، ۱۳۹۶). یک مطالعه با ارزیابی ۲۲ مدل CMIP6 نشان داد در حالی که مجموعه این مدل‌ها توزیع فضایی و روند زمانی رطوبت خاک را به خوبی ثبت می‌کنند، اما اختلافاتی در دقت هر کدام به ویژه در مناطق سردتر و بایر ناشی از تغییرات در روش‌های پارامترسازی مدل و متغیرهای جوی وجود دارد (Liu et al., 2024). اما در این میان فنون یادگیری ماشین مانند جنگل تصادفی اثربخشی قابل توجهی در پیش‌بینی آب‌وهوا نشان داده و دقت ۹۴٪ در برآورد تغییرات آب‌وهوایی را به دست آورده است (Ding, 2024). RF به عنوان موثرترین مدل برای اصلاح نادرستی در مدل‌های اقلیمی برای مناطق مختلف جهان شناسایی شده است و RMSE دما را از ۲/۹ به ۰/۴۴ کاهش داده است (Holthuijsen, 2024).


این الگوریتم دقت قابل توجهی در پیش‌بینی رطوبت خاک با استفاده از داده‌های بازتاب سنجی سیستم ناوبری ماهواره‌ای جهانی^۱ (GNSS-R) همراه با مشاهدات زمینی به مقادیر R2 حدود ۰/۸۲ و RMSE کمتر از ۰/۴۸ میلی‌متر در مزرعه مورد مطالعه‌ای در نیوزیلند نشان داده است (Wilson et al., 2024). RF همچنین برای تخمین منحنی نگهداری آب خاک در تهران و همدان با RMSE، ۲۲ تا ۴۶ درصد بیشتر از رگرسیون خطی، عملکرد مناسب‌تری نشان داده است (کیانی و بیات، ۱۴۰۳). جنگل تصادفی در مقایسه با دیگر الگوریتم‌های یادگیری ماشین مانند رگرسیون خطی چندگانه و برنامه‌ریزی بیان ژن در برآورد تبخیر-تعرق (گنجه‌ای و ناظمی، ۱۴۰۳)، مدل درخت طبقه‌بندی و رگرسیون، ماشین بردار پشتیبان و درخت رگرسیون تقویت شده در پهنه‌بندی مناطق مستعد گردوغبار (افشاری و ولی، ۱۴۰۲)، درخت تصمیم و شبکه عصبی مصنوعی در پیش‌بینی نوسانات سطح ایستابی (پورصالحی و همکاران، ۱۴۰۰)، ماشین بردار پشتیبان در پهنه‌بندی احتمال وقوع سیل (طهماسبی و همکاران، ۱۴۰۰)، شبکه عصبی مصنوعی، الگوریتم درخت تصمیم و رگرسیون لجستیک در مدل‌سازی خطر وقوع زمین‌لغزش (نظریانی و فلاح، ۱۴۰۲؛ سدید و مالکی، ۱۴۰۱) عملکرد بهتری نشان داده است. بطور کلی در چند سال گذشته یادگیری ماشین با نتایج موفقیت آمیزی در مطالعات مختلف برای ریزمقیاس‌نمایی متغیرهای آب‌وهوایی (Jin et al., 2023) و پیش‌بینی استفاده شده‌اند و تصور بر این است که در مطالعات آینده نیز نقش قابل توجهی داشته باشند (Bochenek & Ustrnul, 2022; Fatemi & Parvini, 2022; Rampal et al., 2024). بنابراین ریزمقیاس‌نمایی و پیش‌بینی دقیق رطوبت خاک از مدل‌های اقلیمی که توسط RF تسهیل می‌شود، می‌تواند در برنامه‌ریزی شیوه‌های کشاورزی، خشکسالی و مدیریت زیست محیطی در مناطق مختلف جهان موثر واقع شود.

باوجود پیشرفت‌های صورت گرفته در پیش‌بینی رطوبت خاک، مطالعات موجود اغلب به ادغام مجموعه‌داده‌های جامع از مدل‌های برتر CMIP6 و MERRA2 برای مکان‌های خاص توجه نمی‌کنند. این تحقیق با استفاده از داده‌های رطوبت خاک MERRA2 و معرفی بهترین مدل‌های اقلیمی رطوبت خاک CMIP6 با دقت برآورد ۹۸٪ با استفاده از الگوریتم جنگل تصادفی، به این مهم دست خواهد یافت. با به‌کارگیری این الگوریتم یادگیری ماشین، پژوهش حاضر به دنبال افزایش دقت پیش‌بینی‌های رطوبت خاک نه تنها در ایستگاه اسلام‌آباد بلکه پیشنهاد استفاده از آن برای مناطق دیگر در ایران و حتی جهان است. چرا که در صورت رسیدن به نتیجه مورد نظر، این تحقیق روشی قابل اعتمادتر برای برنامه‌ریزی در زمینه‌های مرتبط همچون کشاورزی و مدیریت خشکسالی و منابع آب ارائه می‌دهد. ترکیب نوآورانه تکنیک یادگیری ماشین پیشرفته RF با داده‌های مدل‌های اقلیمی CMIP6، گامی مهم در درک و پیش‌بینی دینامیک رطوبت خاک در پاسخ به تغییرات اقلیمی به شمار می‌آید. چرا که اندازه‌گیری و پیش‌بینی دقیق رطوبت خاک برای مدیریت پایدار منابع آب و مبارزه با بیابان‌زایی ضروری است.

مواد و روش

منطقه مورد مطالعه

شهرستان اسلام‌آباد، یکی از شهرستان‌های استان کرمانشاه در غرب ایران است. این شهرستان از سمت شرق و شمال به شهرستان کرمانشاه، از غرب به شهرستان دالاهو و گیلان‌غرب و از جنوب به شهرستان سیروان در استان ایلام محدود می‌شود. این دشت در ارتفاع حدود ۱۳۰۰ متر از سطح دریا واقع شده است (اسمعیلی و مجرد، ۱۴۰۳). طبق اطلاعات به‌دست‌آمده از ایستگاه هواشناسی اسلام‌آباد، میانگین بارش سالانه ۴۶۳ میلی‌متر و میانگین دما ۱۳/۸ درجه سانتی‌گراد ثبت شده است. این منطقه بر اساس روش اصلاح شده دما، دارای اقلیم نیمه‌مرطوب سرد، مرطوب سرد و ارتفاعات می‌باشد. همچنین، بر اساس منحنی آمبروترمیک ایستگاه اسلام‌آباد، تقریباً پنج ماه از سال، خشکی بر اقلیم این منطقه حاکم است (نعمتی پیکانی و همکاران، ۱۴۰۰). ایستگاه سینوپتیک اسلام‌آباد در طول جغرافیایی ۴۶/۴۶ و عرض جغرافیایی ۳۴/۱۱ واقع شده است (شکل ۱).



شکل ۱. منطقه مورد مطالعه

داده‌ها

این مطالعه یک تحلیل جامع از داده‌های ماهانه رطوبت خاک است که به دلیل عدم دسترسی به داده‌های رطوبت خاک ایستگاه اسلام‌آباد از تحلیل‌های بازنگری دوره مدرن برای تحقیقات و کاربردها، نسخه ۱۲ (MERRA2) در موقعیت جغرافیایی نزدیک به این ایستگاه با تفکیک مکانی ۰/۶۲۵ * ۰/۵ برای دوره ۲۰۱۴-۱۹۹۱ و داده‌های سناریوهای تاریخی و آینده از مدل‌های مختلف در چارچوب پروژه مقایسه مدل‌های جفت‌شده فاز ۶ (CMIP6) که از اتحادیه داده‌های سیستم زمین (ESGF) برای موقعیت ایستگاه سینوپتیک اسلام‌آباد اخذ شده‌اند، ارائه می‌دهد. ESGF از طریق زیر مجموعه‌های مختلف خود دسترسی به مجموعه وسیعی از داده‌های مدل‌های اقلیمی را فراهم آورده که امکان بازیابی داده‌های مدل‌های اقلیمی را برای گزارش‌های ارزیابی IPCC به کاربران می‌دهد.

این تحقیق تمام مدل‌های موجود CMIP6 برای رطوبت خاک موجود در طول و عرض جغرافیایی ۴۶/۴۶ و ۳۴/۱۱ (با ویژگی اجرای r1i1p1f1 از گروه خروجی Lmon ID) با استفاده از کتابخانه intake-ESM و API بهره برده است. دسترسی به داده‌های ذخیره‌شده در DKRZ ESGF از طریق فایل‌های JSON CMIP6 و پسوند داده Zarr حاصل شده است. SSPها (Shared Socioeconomic Pathways) بر اساس پنج سناریو که مسیرهای مختلف اجتماعی-اقتصادی را نشان می‌دهند، از توسعه پایدار (SSP1) تا رشد مبتنی بر سوخت‌های فسیلی (SSP5) طراحی شده‌اند و به عنوان مبنایی اساسی محسوب می‌شوند (Riahi et al., 2017). در این مطالعه، ۱۲ مدل برای داده‌های رطوبت خاک تحت سناریوهای SSP1-2.6، SSP2-4.5 و SSP5-8.5 انتخاب شدند (جدول ۱) و داده‌ها به سه دوره آینده نزدیک (۲۰۲۶-۲۰۵۰)، آینده میانه (۲۰۵۱-۲۰۷۵) و آینده دور (۲۰۷۶-۲۱۰۰) تقسیم، و با استفاده از الگوریتم یادگیری ماشین RF ریزمقیاس‌نمایی شدند.

از الگوریتم یادگیری ماشین جنگل تصادفی و روش حذف ویژگی بازگشتی برای انتخاب مؤثرترین ویژگی‌ها (مدل‌ها) برای هر متغیر استفاده شد. این روش به صورت بازگشتی ویژگی‌های کم‌اهمیت را حذف کرده و مجموعه‌ای بهینه از ویژگی‌ها را انتخاب می‌کند. در روش استاندارد حذف ویژگی بازگشتی، ویژگی‌های کم‌اهمیت به صورت تدریجی حذف می‌شوند، اما اگر

این کار را فقط بر اساس یک بخش از مجموعه داده انجام دهیم، ممکن است مدل به داده‌های خاصی وابسته شده و ویژگی‌های مهم را به اشتباه حذف کند. در اینجا، روش اعتبارسنجی متقابل k-fold با تقسیم داده‌ها به چندین بخش و انجام فرایند حذف ویژگی در هر بخش به طور جداگانه، از این مشکل جلوگیری می‌کند. این روش به مدل اجازه می‌دهد تا در هر Fold یا بخش از داده‌ها اهمیت ویژگی‌ها را ارزیابی کرده و ویژگی‌هایی که در تمام بخش‌ها اهمیت کمی دارند را حذف کند. در نتیجه، ویژگی‌های نهایی انتخاب‌شده پایدارتر و قابل اعتمادتر خواهند بود و احتمال حذف اشتباه ویژگی‌های مهم کاهش می‌یابد، درحالی‌که مدل همچنان دقت بالایی حفظ می‌کند.

مدل‌های انتخاب‌شده‌ای که در مجموع تا ۹۸٪ دقت شبیه‌سازی متغیرها را بر اساس ضریب کارایی نش-ساتکلیف (NSE) نشان دهند برای مشارکت در مجموعه چندمدلی برای پیش‌بینی رطوبت خاک استفاده می‌شوند. معیار ۹۸٪ به منظور حذف مدل‌های با عملکرد پایین و اولویت‌بندی مدل‌های با دقت بالاتر در برآورد متغیر رطوبت خاک طراحی شده است. علاوه بر این، مدلی که بهترین عملکرد را برای این متغیر نشان دهد، انتخاب خواهد شد. شاخص‌های ارزیابی نیز برای مقایسه نتایج در دوره مشترک ۲۰۱۴-۱۹۹۱ میان داده‌های تاریخی CMIP6 ریزمقیاس‌نمایی شده با MERRA2 مورد استفاده قرار گرفتند.

جدول ۱. مدل‌های استفاده شده در تحقیق

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

جنگل تصادفی^۱

جنگل تصادفی (RF) یکی از قدرتمندترین و پرکاربردترین الگوریتم‌های یادگیری ماشین، به‌ویژه در زمینه طبقه‌بندی و رگرسیون است. این الگوریتم بر اساس مفهوم یادگیری گروهی^۲ کار می‌کند و از ترکیب چندین درخت تصمیم برای بهبود دقت و پایداری مدل استفاده می‌کند. این ویژگی باعث می‌شود که اغلب دقت بالاتری نسبت به یک درخت تصمیم منفرد داشته باشد (Wang et al., 2023; Darabi Cheghabaleki et al., 2024). جنگل تصادفی نسبت به نویز و تغییرات در داده‌ها مقاوم است و از بروز مشکل بیش‌برازش‌سازی^۳ جلوگیری می‌کند و به‌خوبی می‌تواند به داده‌های جدید تعمیم داده شود. استفاده از پردازش موازی، باعث می‌شود آموزش و پیش‌بینی با این روش بسیار سریع انجام شود. این الگوریتم می‌تواند با انواع مختلف داده‌ها، از جمله داده‌های عددی و گسسته، کار کند (Salman et al., 2024; Ding, 2024). هر جنگل تصادفی شامل تعداد زیادی درخت تصمیم است که هر کدام ساختار و قوانین خاص خود را دارند. فرایند ساخت درختان در جنگل تصادفی به‌صورت تصادفی انجام می‌شود، یعنی هر بار که الگوریتم اجرا می‌شود، درختان متفاوتی تولید خواهند شد. ساختار درختان تصمیم می‌تواند بسیار پیچیده باشد و شامل شاخه‌های متعدد و سطوح مختلف باشد (Dhanoa et al., 2024). در این

1. Random Forest
2. Ensemble Learning
3. Overfitting

تحقیق تعداد درخت‌ها ۱۰۰ و معیار GINI در انتخاب ویژگی‌ها (پیش‌فرض الگوریتم) استفاده شده است. گره‌ها تا آخرین برگ یعنی تا زمانی که برگ‌ها خالص شده‌اند گسترش پیدا کرده‌اند و محدودیتی برای عمق درخت قرار داده نشده است.

روش اعتبارسنجی متقابل^۱

روش k-fold یکی از روش‌های رایج اعتبارسنجی متقابل در یادگیری ماشین است که به طور گسترده‌ای برای ارزیابی عملکرد مدل‌ها استفاده می‌شود. این روش به‌ویژه در مواردی که حجم داده‌های آموزشی محدود است یا می‌خواهیم از بیش‌برازسازی مدل جلوگیری کنیم، بسیار مفید است (Darabi Cheghabaleki et al., 2024; Jung, 2018). با تقسیم داده‌ها به چندین بخش و آموزش مدل روی بخش‌های مختلف، می‌توانیم برآورد بهتری از عملکرد مدل روی داده‌های جدید و در نتیجه ارزیابی دقیق‌تر داشته باشیم. با استفاده از k-fold، مدل روی بخش‌های مختلفی از داده‌ها آموزش می‌بیند و در نتیجه کمتر به ویژگی‌های خاص یک بخش از داده‌ها وابسته می‌شود. این ویژگی سبب کاهش بیش‌برازسازی می‌شود (Zhang et al., 2022; Leinonen et al., 2024). در این روش داده‌های آموزشی به k قسمت برابر (fold) تقسیم می‌شوند یکی از k قسمت به‌عنوان داده‌های تست انتخاب می‌شود. k-1 قسمت باقی‌مانده به‌عنوان داده‌های آموزش استفاده می‌شوند. مدل روی داده‌های آموزشی آموزش می‌بیند و سپس عملکرد مدل روی داده‌های تست ارزیابی می‌شود. در نهایت، میانگین عملکرد مدل روی همه k قسمت به‌عنوان برآورد نهایی عملکرد مدل در نظر گرفته می‌شود (Darabi Cheghabaleki et al., 2024; Jung, 2018). با استفاده از k-fold می‌توان تعداد درختان مناسب در RF را تعیین کرد و برای انتخاب بهترین پارامترهای دیگر الگوریتم RF مانند عمق درختان و تعداد ویژگی‌های انتخاب شده در هر گره استفاده کرد.

معیارهای ارزیابی دقت مدل

شاخص‌های آماری برای ارزیابی تفاوت بین داده‌های بازتحلیل MERRA2 و CMIP6 در بازه زمانی ۱۹۹۱ تا ۲۰۱۴ به کار گرفته شد. این ارزیابی بر اساس معیارهای مختلفی از جمله شاخص پراکندگی^۲ (SI)، خطای میانگین سوگیری^۳ (MBE)، خطای مربع ریشه نرمال شده^۴ (NRMSE)، خطای مطلق میانگین^۵ (MAE)، انحراف مطلق میانگین^۶ (MAD)، کارایی نش - ساتکلیف^۷ (NSE) و ضریب همبستگی^۸ (CC) که روابط مرتبط با آنها در ادامه ارائه شده است (رابطه‌های ۱ تا ۷)، انجام شد (Moeeni et al., 2017; Verma et al., 2021).

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

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

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

$$MAE = \frac{\sum Y_i - Y}{n} \quad \text{رابطه (۴)}$$


$$MAD = \frac{\sum_{i=1}^n |Y_i - Y|}{n} \quad \text{رابطه (۵)}$$

1. k-fold cross validation
2. Scatter Index (SI)
3. Mean Bias Error (MBE)
4. Normalized Root Mean Square Error (NRMSE)
5. Mean Absolute Error (MAE)
6. Mean Absolute Deviation (MAD)
7. Nash-Sutcliffe Efficiency (NSE)
8. Correlation Coefficient (CC)

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \right] \quad \text{رابطه (۶)}$$

$$CC = \frac{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})(X_{sim,i} - \bar{X}_{sim})}{\sqrt{\sum_{i=1}^N (X_{obs,i} - \bar{X}_{obs})^2 \sum_{i=1}^N (X_{sim,i} - \bar{X}_{sim})^2}} \quad \text{رابطه (۷)}$$


در این روابط، Y_i به داده‌های مشاهده‌شده اشاره دارد؛ Y داده‌های مدل است، $\bar{Y}_i$ میانگین داده‌های مشاهده‌شده و n تعداد کل داده‌ها را نشان می‌دهد. برای درک بهتر روند کلی کار در این مطالعه، فلوچارت مربوط به الگوریتم در شکل ۲ ارائه شده است. این نمودار به وضوح مراحل مختلف تحقیق را نمایش می‌دهد.



شکل ۲. نمودار مراحل تحقیق

نتایج

در این پژوهش، متغیر میانگین رطوبت خاک ماهانه در اسلام‌آباد غرب مورد بررسی قرار گرفته است. با بهره‌گیری از یک API در زبان برنامه‌نویسی پایتون، تمامی مدل‌های CMIP6 که برای این متغیر در طول و عرض جغرافیایی ۴۶/۴۶ و ۳۴/۱۱ موجود بودند (یعنی ۱۲ مدل) اخذ شد. سپس از الگوریتم یادگیری ماشین جنگل تصادفی و روش حذف ویژگی بازگشتی برای انتخاب موثرترین ویژگی‌ها (مدل‌ها) برای هر متغیر استفاده شد. پیش‌بینی‌کننده جنگل تصادفی با استفاده از ۷۰ درصد داده‌های تاریخی مدل‌های آب‌وهوایی و داده‌های MERRA2 آموزش داده شد و ۳۰ درصد باقی‌مانده به منظور تست به کار رفت. نتیجه ارائه شده در شکل ۳ نشان می‌دهد که برخی از مدل‌های CMIP6 در منطقه مورد مطالعه نسبت به سایر مدل‌ها عملکرد بهتری از خود نشان می‌دهند. همان‌طور که مشاهده می‌شود، از میان ۱۲ مدل موجود، میانگین دقت آزمون بعد از ۵ ویژگی (مدل) با حدود ۰/۸۸، برای رطوبت خاک ثابت شده است. بنابراین، در برآورد و شبیه‌سازی متغیر رطوبت خاک، بیش از این تعداد، مدل‌های دیگر تأثیر قابل توجهی ندارند.



شکل ۳. ارزیابی دقت مدل‌های ورودی برای رطوبت خاک

با اجرای جنگل تصادفی مهم‌ترین مدل را برای رطوبت خاک شناسایی شد و تأثیر آن را به صورت درصد به دست آمد و سایر مدل‌ها تا تکمیل ۹۸٪ دقت نیز برحسب درصد معرفی می‌شوند. مدل‌های برتر برای هر متغیر در جدول ۲ نشان داده شده است. جدول ۲ نشان می‌دهد که مدل‌های MRI-ESM2-0 موثرترین مدل برای پیش‌بینی میانگین رطوبت خاک با تأثیر ۸۷٪ است. تمرکز بر روی این مدل می‌تواند حداقل ۸۷٪ دقت را در طول دوره تست به دست آورد. ترکیب مدل‌های پیش‌بینی برای رسیدن به ۹۸٪ دقت تشکیل می‌دهند.

جدول ۲. مدل‌های انتخاب شده بر اساس ضریب NSE

مدل	درصد تأثیر مدل‌های برتر
$X_0 = \text{MRI-ESM2-0}$	۸۷٪
$X_1 = X_0 + \text{MPI-ESM1-2-LR}$	۹۲٪
$X_2 = X_1 + \text{NorESM2-MM}$	۹۶٪
$X_3 = X_2 + \text{MIROC6}$	۹۷٪
$X_4 = X_3 + \text{CESM2-WACCM}$	۹۸٪

پس از شناسایی مدل‌های مؤثر با دقت ۹۸٪ در پیش‌بینی میانگین رطوبت خاک، نتایج ارزیابی جنگل تصادفی در ریزمقیاس‌نمایی و شبیه‌سازی با معیارهای ارزیابی مختلف بررسی شد. جدول ۳ عملکرد مدل را در این معیارها را در طول دوره‌های آموزش و آزمون برای ایستگاه سینوپتیک اسلام‌آباد نشان می‌دهد. نتایج نشان می‌دهد که جنگل تصادفی به طور مؤثر رطوبت خاک را با حداقل ضریب نش ۰/۹۸ برای آموزش مدل و ۰/۷۸ برای دوره آزمون ریزمقیاس‌نمایی و شبیه‌سازی کرده است. $MAD = ۰/۰۱$ ، $CC = ۰/۹۹$ ، MAE و MBE برابر با صفر، $SI = ۰/۰۹$ و $NRMSE = ۰/۰۵$ از دیگر نتایج ارزیابی برای این روش کارآمد است.


جدول ۳. عملکرد مدل جنگل تصادفی در طول آموزش و آزمون

معیار	آموزش	معیار	آزمون
MAD	۰/۰۱	MAD	۰/۰۳
CC	۰/۹۹	CC	۰/۸۹
NS	۰/۹۸	NS	۰/۷۸
MAE	۰/۰۰	MAE	۰/۰۱
MBE	-۰/۰۰۰۰۱	MBE	-۰/۰۰۰۱
SI	۰/۰۹	SI	۰/۲۸
NRMSE	۰/۰۵	NRMSE	۰/۱۵

اقلیم آینده

میانگین ماهانه

مقادیر میانگین ماهانه رطوبت خاک ایستگاه اسلام‌آباد در دوره‌های مختلف (مشاهداتی، آینده نزدیک، آینده میانی و آینده دور) تحت سناریوهای مختلف SSP1-2.6، SSP2-4.5 و SSP5-8.5 و تفاضل زیر دوره‌های آینده از مشاهدات MERRA2 در شکل ۴ و ۵ نشان‌دهنده تغییرات قابل توجهی در مقادیر رطوبت خاک است. این تغییرات در ماه‌های مختلف سال و تحت سناریوهای گوناگون، نشان‌دهنده تأثیرات شدید تغییرات اقلیمی است.




شکل ۴. میانگین ماهانه رطوبت خاک در داده‌های MERRA2، آینده نزدیک، میانی و دور در ایستگاه اسلام‌آباد

در دوره مشاهداتی (شکل ۴)، یک الگوی فصلی مشخص برای رطوبت خاک قابل مشاهده است، به طوری که بالاترین مقادیر رطوبت در ماه‌های زمستان و بهار (به ویژه ژانویه تا آوریل) و کمترین مقادیر در ماه‌های تابستان و اوایل پاییز (به ویژه ژولای تا سپتامبر) ثبت شده است. این الگوی فصلی منعکس‌کننده رژیم بارندگی و تبخیر و تعرق در دشت اسلام‌آباد است، جایی که بارش‌های زمستانی و بهاری باعث افزایش رطوبت خاک می‌شوند و در مقابل، افزایش دما و تبخیر و تعرق در تابستان منجر به کاهش رطوبت خاک می‌گردد.

بررسی سناریوهای آینده نشان می‌دهد که تحت هر سه سناریوی SSP1-2.6، SSP2-4.5 و SSP5-8.5، کاهش رطوبت خاک در مقایسه با دوره مشاهداتی پیش‌بینی می‌شود. این کاهش در تمام ماه‌ها (به‌غیر از ژولای، سپتامبر و اکتبر) قابل مشاهده است، اما شدت آن در سناریوهای مختلف و آینده‌های محتمل، متفاوت است. در آینده نزدیک (۲۰۲۶-۲۰۵۰)، بیشترین کاهش در آگوست، ماه‌های فصل زمستان و اواخر پاییز رخ خواهد داد. بطور مثال در اوت، رطوبت خاک حدود ۰/۰۲ تا ۰/۰۴ میلی‌متر (شکل ۵) نسبت به مقدار ۰/۰۸۷ میلی‌متر دوره مشاهداتی (شکل ۴) تحت شرایط سناریوهای مختلف کاهش خواهد یافت. در آینده میانی و دور نیز در اکثر ماه‌ها (به غیر از ژولای، سپتامبر و اکتبر) رطوبت خاک کاهش خواهد

یافت. در این دوره‌ها کاهش بترتیب در حدود ۰/۰۳ تا ۰/۰۵ و ۰/۰۳ تا ۰/۰۴ میلی‌متر در شرایط SSP5-8.5 پیش‌بینی می‌شود (شکل ۵). کاهش رطوبت خاک می‌تواند موجب کاهش حاصل‌خیزی خاک و نیاز به مصرف بیشتر منابع آبی برای حفظ بهره‌وری محصولات کشاورزی شود.



شکل ۵. تفاضل تجمعی میانگین ماهانه رطوبت خاک آینده نزدیک، میانه و دور از مشاهدات MERRA2

علت‌های کاهش رطوبت خاک را می‌توان به افزایش دما، کاهش بارش‌ها و افزایش تبخیر نسبت داده می‌شود. در سناریوهای با گازهای گلخانه‌ای بیشتر مانند SSP2-4.5 و SSP5-8.5، دما افزایش یافته و تبخیر سطحی آب از خاک بیشتر می‌شود که باعث کاهش رطوبت خاک در ماه‌های گرم‌تر می‌گردد. همچنین، کاهش بارش‌ها در ماه‌های خاص مانند زمستان و بهار، به‌ویژه در سناریوهای SSP2-4.5 و SSP5-8.5، باعث کاهش رطوبت خاک خواهد شد. در نهایت، در SSP5-8.5 که شدیدترین اثرات تغییرات اقلیمی را شامل می‌شود، تغییرات دمایی و تبخیر بیشتر باعث کاهش شدیدتر رطوبت خاک در بسیاری از ماه‌ها می‌شود. این روند می‌تواند منجر به افزایش فشار بر منابع آبی و آسیب به اکوسیستم‌های کشاورزی شود، بنابراین راهکارهایی مانند کشاورزی هوشمند اقلیمی و بهینه‌سازی مصرف آب باید مورد توجه قرار گیرند.


روند میانگین سالانه

نمودار ارائه‌شده در شکل ۶، روند سالانه رطوبت خاک را در سه سناریوی مختلف اقلیمی (SSP1-2.6، SSP2-4.5 و SSP5-8.5) و در دوره‌های زمانی آینده نزدیک (۲۰۲۶ تا ۲۰۵۰)، آینده میانی (۲۰۵۱ تا ۲۰۷۵) و آینده دور (۲۰۷۶ تا ۲۱۰۰) بررسی می‌کند. داده‌های مشاهده‌شده (۱۹۹۱ تا ۲۰۱۴) در هر سه پل برای مقایسه با تغییرات آینده در شرایط هر سناریو قابل مشاهده هستند و روند کلی رطوبت خاک را طی این دوره زمانی نمایش می‌دهند. رطوبت خاک در این دوره افزایش ملایمی داشته است. این روند با شیب ۰/۰۰۰۳ همراه است که نشان می‌دهد سالانه به طور میانگین رطوبت خاک ۰/۰۰۰۳ میلی‌متر افزایش یافته است.

در آینده نزدیک و در شرایط SSP1-2.6 رطوبت خاک افزایش ملایمی با شیب ۰/۰۰۰۹ دارد که نشان‌دهنده افزایش سالانه‌ای در حدود ۰/۰۰۰۹ میلی‌متر است که نسبت به دوره مشاهداتی که افزایش داشت، یک تغییر مثبت به شمار می‌رود. روند کاهشی با شیب ۰/۰۰۰۲- تحت SSP2-4.5 و SSP5-8.5 مشاهده می‌شود که بیانگر کاهش سالانه نسبت به داده‌های مشاهداتی است.

در آینده میانی، در شرایط SSP1-2.6 کاهش رطوبت خاک با شیب ۰/۰۰۰۷- پیش‌بینی می‌شود. تحت SSP2-4.5 روند بهبود یافته و شیب به ۰/۰۰۰۲ تغییر می‌کند، که نشان‌دهنده افزایش سالانه اندک رطوبت خاک است. این تغییر مثبت نشان‌دهنده بازگشت به شرایط مشاهداتی و حتی اندکی بهتر است. کاهش رطوبت خاک در شرایط SSP5-8.5 با شیب ۰/۰۰۰۱- همچنان ادامه دارد، اما این کاهش بسیار ملایم است و نزدیک به ثبات نسبی در مقایسه با داده‌های مشاهداتی است.

در آینده دور رطوبت خاک تحت SSP1-2.6 روندی تقریباً ثابت با شیب ۰/۰۰۰۱- را نشان می‌دهد که به معنای تغییرات اندک رطوبت خاک نسبت به داده‌های مشاهداتی است. افزایش رطوبت خاک قابل ملاحظه در شرایط SSP2-4.5 با شیب ۰/۰۰۰۶ بیانگر بهبود شرایط و افزایش سالانه قابل توجه‌تر نسبت به داده‌های مشاهداتی است. همچنین شیب ۰/۰۰۰۴ در سناریوی SSP5-8.5 نشان می‌دهد که شرایط بهبود یافته و روند مثبت به سمت افزایش رطوبت خاک وجود دارد.



شکل ۶. میانگین رطوبت نسبی خاک سالانه آینده نزدیک، میانی و دور برای سناریوهای مختلف در مقایسه با مشاهدات MERRA2

بحث

در پژوهش حاضر، استفاده از الگوریتم جنگل تصادفی برای پیش‌بینی رطوبت خاک ایستگاه اسلام‌آباد توانسته است نتایج قابل‌توجهی را به دست آورد و نتایج کارایی و دقت بالای مدل RF در مقایسه رطوبت خاک اسلام‌آباد با مدل‌های CMIP6، مانند کارایی بالای این الگوریتم در پیش‌بینی متغیرهای محیطی در مقیاس‌های جغرافیایی مختلف دیگر (Wilson et al., 2024; Ding, 2024) را نشان داد. مدل MRI-ESM2-0 با دقت ۰.۸۷٪ برای پیش‌بینی رطوبت خاک، موفق به شبیه‌سازی دقیق شرایط رطوبت خاک در منطقه گردیده است درحالی‌که یافته‌های گیاردینا و همکاران (۲۰۲۴) کم برآوردی مدل‌های CMIP6 از رطوبت خاک را مطرح کرده است (Giardina et al., 2024). این امر ممکن است به علت به‌کارگیری مدل‌ها نامتناسب CMIP6 با اقلیم مناطق مورد مطالعه و یا استفاده از روش‌های نامناسب باشد؛ چراکه نتایج اعتبارسنجی این مدل‌ها

پس از اعمال روش RF در این پژوهش، قطعیت و دقت بالایی را نشان داد.

در زمینه تأثیر تغییرات اقلیمی، این پژوهش نشان می‌دهد که رطوبت خاک در آینده نزدیک و دور کاهش پیدا می‌کند این امر در مناطق مختلف دیگر نیز در اثر رخداد گرمایش جهانی رخ داده است (Peng et al., 2023; Guan et al., 2023). این کاهش به‌ویژه در سناریوهای SSP2-4.5 و SSP5-8.5 که نشان‌دهنده سناریوهای شدیدتر تغییرات اقلیمی هستند، مورد تأکید قرار گرفته است. در این پژوهش نیز تحت این سناریوها، کاهش رطوبت خاک در فصل‌های گرم‌تر و حتی زمستان و پاییز نیز مشاهده می‌شود. این یافته‌ها اهمیت اتخاذ سیاست‌های مدیریت پایدار منابع آب و کشاورزی تطبیقی را نشان می‌دهند تا اثرات تغییرات اقلیمی کاهش یابد.

تغییرات آب‌وهوایی بر رطوبت خاک در مناطق مختلف تأثیرگذار است؛ با تغییراتی در سطوح مختلف که بسته به مدل‌ها و سناریوهای اقلیمی متفاوت (صالحی طیس و همکاران، ۱۳۹۸). به‌ویژه کاهش آن در سناریوهای SSP2-4.5 و SSP5-8.5، که با افزایش گازهای گلخانه‌ای همراه است. در سناریو SSP5-8.5 که شدیدترین اثرات تغییرات اقلیمی را به همراه دارد، کاهش شدید رطوبت خاک به وضوح مشهود است (Peng et al., 2023). بنابراین کاهش رطوبت خاک در آینده در سایه تغییرات اقلیمی، علاوه بر تأثیر بر تولید محصولات کشاورزی، می‌تواند پیامدهایی همچون فرسایش خاک و کاهش کربن آلی آن را سبب شود. این عوامل حتی می‌تواند منجر به تخریب اکوسیستم طبیعی (Borah & Parmar, 2024)، کاهش تنوع زیستی و کاهش ظرفیت جذب کربن و در نهایت بحران‌های زیست‌محیطی (Zhou et al., 2023) و اثرات سوء بر تغذیه منابع آب زیرزمینی و سطحی (WMO, 2023; Sahoo & Sahoo, 2024) در این منطقه شود.

یافته‌های این پژوهش بر اهمیت مدیریت پایدار منابع آب و کشاورزی در منطقه اسلام‌آباد غرب تأکید دارد. نتایج نشان می‌دهد که تغییرات اقلیمی و کاهش رطوبت خاک ممکن است پیامدهای گسترده‌ای بر امنیت غذایی، کیفیت خاک، و اکوسیستم‌های طبیعی داشته باشد. در این راستا، اتخاذ رویکردهای سازگار با تغییرات اقلیمی مانند استفاده از گونه‌های مقاوم به خشکی، بهینه‌سازی مصرف آب در کشاورزی، اجرای روش‌هایی برای تغذیه منابع آب زیرزمینی و افزایش آگاهی کشاورزان از تأثیرات تغییرات اقلیمی، می‌تواند به کاهش اثرات منفی این تغییرات کمک کند.

نتیجه‌گیری

این پژوهش به بررسی تغییرات میانگین رطوبت خاک ایستگاه اسلام‌آباد تحت سناریوهای مختلف تغییر اقلیم (SSP1-2.6، SSP2-4.5 و SSP5-8.5) پرداخته است. به دلیل عدم دسترسی به داده‌های رطوبت خاک ایستگاه اسلام‌آباد از داده‌های MERRA2 در موقعیت جغرافیایی نزدیک به این ایستگاه برای آموزش مدل‌ها استفاده شد. از میان مدل‌های CMIP6، مدل MRI-ESM2-0 با تأثیر ۸۷٪ به‌عنوان مؤثرترین مدل شناسایی شد. سایر مدل‌ها (۴ مدل برتر بعدی) در مجموع تنها ۱۱٪ به دقت پیش‌بینی اضافه کردند و دقت کلی را به ۹۸ درصد رساندند. این نتایج نشان‌دهنده اهمیت انتخاب مدل‌های کلیدی در برآورد دقیق متغیرهای اقلیمی است. همچنین، الگوریتم یادگیری ماشین جنگل تصادفی عملکرد قابل‌توجهی در پیش‌بینی رطوبت خاک داشت. ارزیابی‌ها حاکی از ضریب نش ۰/۹۸ در دوره آموزش و ۰/۷۸ در دوره آزمون بود. معیارهای دیگر شامل $MAD = 0/01$ ، MAE و MBE برابر با صفر نشان‌دهنده دقت بالای این مدل هستند.

بررسی دوره‌های آینده (۲۰۲۶-۲۱۰۰) نشان داد که کاهش قابل‌توجهی در رطوبت خاک در اغلب ماه‌ها پیش‌بینی می‌شود. به‌عنوان مثال، در ماه اوت دوره آینده نزدیک، رطوبت خاک با کاهشی بین ۰/۲ تا ۰/۴ میلی‌متر نسبت به مقدار مشاهداتی ۰/۸۷ میلی‌متر همراه خواهد بود. این کاهش در دوره آینده دور تحت SSP5-8.5 به ۰/۳ تا ۰/۴ میلی‌متر خواهد رسید. روند سالانه الگوی کاهش رطوبت خاک را تحت سناریوهای SSP2-4.5 و SSP5-8.5 در آینده نزدیک و در شرایط سناریوی SSP1-2.6 برای آینده میانی نشان می‌دهد. دقت نتایج روش استفاده شده در این پژوهش، زمینه‌ای برای بهره‌وری از آن در اقلیم‌های مختلف برای حفظ و مدیریت خاک است. یافته‌ها همچنین نشان‌دهنده ضرورت برنامه‌ریزی جامع برای حفظ پایداری محیطی و مدیریت کارآمد منابع آبی در شرایط تغییرات اقلیمی در منطقه مطالعه و سیاست‌گذاری‌های ملی در راستای افزایش بهره‌وری آب و ارتقای تکنیک‌های کشاورزی هوشمند را یادآور می‌شود. همچنین دقت روش استفاده شده در

پژوهش حاضر با استفاده از منابع داده‌های مختلف مانند داده‌های سنجش‌ازدور و یا متغیرهای دیگر نیز می‌تواند زمینه‌ای برای تحقیقات آینده را فراهم کند.

منابع

- اسمعیلی، شکوفه؛ 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)، ۱۳۴-۱۱۵. doi: 10.22034/hyd.2024. 62351.1747
- افشاری، مجید؛ ولی، عباسعلی (۱۴۰۲). کارایی سنجش از دور و خوارزمیک‌های یادگیری ماشین در پهنه‌بندی مناطق مستعد گردوغبار استان اصفهان. *مدیریت بیابان*، ۱۱ (۳)، ۸۸-۷۳. doi: 10.22034/jdmal.2023.2011344.1438
- پورصالحی، فاطمه؛ خاشعی سیوکی، عباس؛ 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). *اکوهیدرولوژی*، ۸ (۴)، ۹۷۴-۹۶۱. doi: 10.22059/ije.2022.327263.1526
- سدیدی، جواد؛ مالکی، رضا (۱۴۰۱). مقایسه الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی و رگرسیون لجستیک در پهنه‌بندی خطر زمین‌لغزش در جاده مهاباد سردشت. *کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی*، ۲ (۴)، ۱۰۰-۸۱. doi: 10.22034/rsgi.2022.15839
- صالحی طبس، مختار؛ یعقوب‌زاده، مصطفی؛ هاشمی، سید رضا (۱۳۹۸). اثر تغییر اقلیم بر رطوبت خاک مزرعه ذرت با استفاده از داده‌های گزارش پنجم و مدل SWAP. *آبیاری و زهکشی ایران*، ۱۳ (۶)، ۱۸۴۳-۱۸۳۲. doi: 20.1001.1.20087942. 1398.13.6.25.1
- طهماسبی، محمدرضا؛ شعبانلو، سعید؛ رجبی، احمد؛ یوسفوند، فریبرز (۱۴۰۰). پهنه‌بندی احتمال وقوع سیل با استفاده از بررسی مقایسه‌ای دو مدل شناخته شده جنگل تصادفی و ماشین بردار پشتیبان در شمال ایران. *مدیریت آب و آبیاری*، ۱۱ (۲)، ۲۲۳-۲۳۵. doi: 10.22059/jwim.2021.317527.856
- کیانی، رضا؛ بیات، حسین (۱۴۰۳). ارزیابی قابلیت دو روش رگرسیون و جنگل تصادفی برای تخمین منحنی نهداری آب خاک با ایجاد توابع انتقالی شبه‌پیوسته. *دانش خاک و گیاه*، ۳۴ (۴)، ۱۵-۳۶. doi: 10.22034/ws.2024.60933.2556
- گنجه‌ای، سیمین؛ ناظمی، امیرحسین (۱۴۰۳). مقایسه عملکرد روش‌های یادگیری ماشین در مدل‌سازی تبخیر-تغرق مرجع روزانه و توزیع مکانی آن (مطالعه موردی: استان زنجان). *علوم و مهندسی آبیاری*، doi: 10.22055/jise.2024.45305.2103
- موسوی، حسین؛ کمانگر، محمد؛ کربلایی، علیرضا (۱۳۹۸). واکاوی مکانی رطوبت خاک پس از بارش‌های بیش‌ازحد نرمال سال آبی ۹۷-۹۸ با مدل‌سازی خطی متغیرهای محیطی و تصاویر ماهواره‌ای. *مهندسی و مدیریت آبخیز*، ۱۳ (۱)، ۱۷۳-۱۶۰. doi: 10.22092/ijwmse.2020.128371.1737
- نظریانی، نسترن؛ فلاح، اصغر (۱۴۰۲). مدل‌سازی خطر وقوع زمین‌لغزش با استفاده از داده‌کاوی در جنگل‌های هیرکانی. *مدیریت حوزه آبخیز*، ۱۴ (۲۷)، ۱۳۴-۱۲۳. doi: 10.61186/jwmr.14.27.123
- نعمتی پیکانی، مصطفی؛ اجتهادی، حمید؛ عصری، یونس؛ اسماعیل‌زاده، امید (۱۴۰۰). مطالعه فلوریستیک گیاهان آوندی منطقه حفاظت‌شده قلاجه در استان کرمانشاه. *تاکسونومی و بیوسیس‌ماتیک*، ۱۳ (۴۱)، ۹۲-۵۹. doi: 10.22108/tbj.2021. 130866.1181
- نورکی، عاطفه؛ گلایی، منا؛ الباجی، محمد؛ ناصری، عبدعلی؛ همایونی، سعید (۱۴۰۲). مدلسازی زمانی - مکانی رطوبت خاک با استفاده از داده‌های سنجش‌ازدور نوری - حرارتی و مدل‌های یادگیری ماشین. *تحقیقات آب‌و‌خاک ایران*، ۵۴ (۴)، ۶۳۷-۶۵۳. doi: 10.22059/ijswr.2023.356707.669469
- یعقوب‌زاده، مصطفی؛ امیرآبادی زاده، مهدی؛ رضائی، یوسف؛ پوررضا بیلندی، محسن (۱۳۹۶). بررسی عدم قطعیت مدل‌های گردش عمومی جو در برآورد رطوبت خاک تحت تأثیر تغییر اقلیم. *تحقیقات آب‌و‌خاک ایران*، ۴۸ (۵)، ۱۱۰۹-۱۱۱۹. doi: 10.22059/ijswr.2017.224039.667603

References

- Afshari, M., & Vali, A. (2023). The efficiency of remote sensing and machine learning algorithms in the zoning of susceptible areas to dust in Isfahan province. *Desert Management*, 11(3), 73-88. doi: 10.22034/jdmal.2023.2011344.1438. (In Persian).

- Bochenek, B., & Ustrnul, Z. (2022). Machine learning in weather prediction and climate analyses—applications and perspectives. *Atmosphere* 13(2), 180. doi: 10.3390/atmos13020180
- Borah, B., & Parmar, P. (2024). Soil Organic Carbon Dynamics: Drivers of Climate Change-Induced Soil Organic Carbon Loss at Various Ecosystems. *International Journal of Environment and Climate Change* 14 (10):74-153. doi: 10.9734/ijecc/2024/v14i104477
- 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. doi: 10.1007/s13201-024-02154-x
- Dhanoa, M.S., Sanderson, R., Lister, S. J., Cardenas, L.M., Ellis, J.L., Lopez, S., & France, J. (2024). Decision tree learning with random forest models using agricultural and ecological field data incorporating multi-factor studies and covariate structure. *CABI Reviews*, 19(1). doi: 10.1079/cabireviews.2024.0030
- Ding, Z. (2024). Climate Prediction with Tree Structure Based on Random Forest. *Transactions on computer science and intelligent systems research*, 5, 204-208. doi: 10.62051/akf9ef10
- Esmaili, S. & Mojarad, 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. doi: 10.22034/hyd.2024.62351.17 (In Persian).
- 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. doi: 10.1007/s00521-022-07140-5
- Ganji, S., & Nazemi, A. H. (2024). Comparing the performance of machine learning methods in modeling daily reference ET and its spatial distribution (case study: Zanzan province). *Irrigation Sciences and Engineering*. doi: 10.22055/jise.2024.45305.2103. (In Persian).
- Giardina, F., Padron, R.S., Stocker, B.D., Schumacher, D.L., & Seneviratne, S.I. (2024). Large biases in soil moisture limitation across CMIP6 models (No. EGU24-17662). *Copernicus Meetings*. doi: 10.5194/egusphere-egu24-17662
- Guan, Y., Gu, X., Slater, L.J., Li, J., Kong, D., & Zhang, X. (2023). Spatio-temporal variations in global surface soil moisture based on multiple datasets: intercomparison and climate drivers. *Journal of Hydrology*, 625, 130095. doi: 10.1016/j.jhydrol.2023.130095
- Holthuijsen, T. (2024). *Development of a Random Forest Climate Model Correction Algorithm*. doi: 10.21203/rs.3.rs-4125598/v1
- Horton, D., Johnson, J.T., Al-Khaldi, M., Baris, I., Park, J., & Bindlish, R. (2024). Soil Moisture During 2015 Spring Flood Events from the SMAP Radar Time-Series Ratio Algorithm. In *2024 United States National Committee of URSI National Radio Science Meeting, USNC-URSI NRS*, 352-352. doi: 10.23919/USNC-URSINRS60317.2024.10465105
- 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. doi: 10.1007/s00477-023-02444-x
- Jung, Y. (2018). Multiple predicting K-fold cross-validation for model selection. *Journal of nonparametric statistics*, 30(1), 197-215. doi: 10.1080/10485252.2017.1404598
- Kiani, R., & Bayat, H. (2024). Evaluation of the Capability of Regression and Random Forest Methods to Estimate Soil Water Retention Curve by Developing Pseudo-continuous Pedotransfer Functions. *Water and Soil Science*, 34 (4), 15-36. doi: 10.22034/ws.2024.60933.2556. (In Persian).
- Leinonen, T., Wong, D., Vasankari, A., Wahab, A., Nadarajah, R., Kaisti, M., & Airola, A. (2024). Empirical investigation of multi-source cross-validation in clinical ECG classification. *Computers in Biology and Medicine*, 183, 109271. doi: 10.1016/j.combiomed.2024.109271
- Liu, Y., Chen, X., Bai, Y., & Zeng, J. (2024). Evaluation of 22 CMIP6 model-derived global soil moisture products of different shared socioeconomic pathways. *Journal of Hydrology*, 636, 131241. doi: 10.1016/j.jhydrol.2024.131241
- 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.

- doi: 10.1016/j.jhydrol.2017.02.012
- Mosavi, H., Kamangar, M., & Krbalayy, A. (2021). Spatial Analysis of Soil Moisture after Excessive Normal Precipitation of 1997-98 with Linear Modeling of Environmental Variables and Satellite Images. *Watershed Engineering and Management*, 13(1), 160-173. doi: 10.22092/ijwmse.2020.128371.1737. (In Persian).
- Nazariani, N., & Fallah, A. (2023). Landslide Risk Modeling using Data Mining in Hyrcanian Forests. *Watershed Management Research*, 14(27), 123-134. doi: 10.61186/jwmr.14.27.123. (In Persian).
- Nemati Paykani, M., Ejtehad, H., Asri, Y., & Esmailzadeh, O. (2021). A Floristic Study of Vascular Plants in the Qalajeh Protected Area in Kermanshah Province. *Taxonomy and Biosystematics*, 13(48), 59-92. doi: 10.22108/tbj.2021.130866.1181. (In Persian).
- Nouraki, A., Golabi, M., Albaji, M., Naseri, A., & Homayouni, S. (2023). Spatial-temporal modeling of soil moisture using optical and thermal remote sensing data and machine learning algorithms. *Journal of Soil and Water Research*, 54(4), 637-653. doi: 10.22059/ijswr.2023.356707.669469. (In Persian).
- Paul, S., & Singh, S. (2020). Soil moisture prediction using machine learning techniques. *In Proceedings of the 2020 3rd International Conference on Computational Intelligence and Intelligent Systems*, 1-7. doi: 10.1145/3440840.3440854
- Peng, C., Zeng, J., Chen, K.S., Ma, H., & Bi, H. (2023). Spatiotemporal Patterns and Influencing Factors Of Soil Moisture At A Global Scale. *In IGARSS 2023, International Geoscience and Remote Sensing Symposium*, Pasadena, CA, USA, 2023, pp. 3174-3177. doi: 10.1109/IGARSS52108.2023.10282096
- Pinnington, E., Quaife, T., & Black, E. (2018). Impact of remotely sensed soil moisture and precipitation on soil moisture prediction in a data assimilation system with the JULES land surface model. *Hydrology and Earth System Sciences*, 22(4), 2575-2588. doi: 10.5194/hess-22-2575-2018
- 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). *Ecohydrology*, 8(4), 961-974. doi: 10.22059/ije.2022.327263.1526. (In Persian).
- Rampal, N., Hobeichi, S., Gibson, P. B., Bano-Medina, J., Abramowitz, G., Beucler, T., Gonzalez-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. doi: 10.1175/AIES-D-23-0066.1
- Riahi, K., Van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O., Lutz, W., Popp, A., Crespo Cuaresma, J., KC, S., Leimbach, M., Jiang, L., Kram, T., Rao, S., Emmerling, J., Ebi, K., & Tavoni, M. (2017). The shared socioeconomic pathways and their energy, land use, and greenhouse gas emissions implications: an overview. *Global Environmental Change*, 42, 153-168. doi: 10.1016/j.gloenvcha.2016.05.009
- Sadidi, J., & Maliki, R. (2022). Using machine learning-based models for landslide susceptibility mapping in Mahabad-Sardasht road. *Remote Sensing and GIS Applications in Environmental Sciences*, 2(4), 81-100. doi: 10.22034/rsgi.2022.15839. (In Persian).
- Sahoo, S., & Sahoo, B. (2024). Assessing Spatially Distributed Soil Moisture under Changing Land Uses and Climate. *In Climate Change Impacts on Soil-Plant-Atmosphere Continuum*, Singapore: Springer Nature Singapore, 78, 209-228. doi: 10.1007/978-981-99-7935-6_8.
- Salehi tabas, M., Yaghoobzadeh, M., & Hashemi, S. (2020). The effect of climate change on soil moisture content of Maize farm using data from the fifth report and SWAP model. *Journal of Irrigation & Drainage*, 13(6), 1832-1843. dor: 20.1001.1.20087942.1398.13.6.25.1. (In Persian).
- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69-79. doi: 10.58496/BJML/2024/007
- Tahmasebi, M. R., Shabanlou, S., Rajabi, A., & Yosefvand, F. (2021). Flood probability zonation

- using a comparative study of two well-known random forest and support vector machine models in northern Iran. *Water and Irrigation Management*, 11(2), 223-235. doi: 10.22059/jwim.2021.317527.856. (In Persian).
- Verma, S., Bhatla, R., Ghosh, S., Sinha, P., Kumar Mall, R., & Pant, M. (2021). Spatio-temporal variability of summer monsoon surface air temperature over India and its regions using Regional Climate Model. *International Journal of Climatology*, 41(13), 5820-5842. doi: 10.1002/joc.7155
- Wang, D., Liu, J., Luan, Q., Shao, W., Fu, X., Wang, H., & Gu, Y. (2023). Projection of future precipitation change using CMIP6 multimodel ensemble based on fusion of multiple machine learning algorithms: A case in Hanjiang River Basin, China. *Meteorological Applications*, 30(5), e2144. doi: 10.1002/met.2144
- Wilson, M. D., Datta, R., Savarimuthu, S., Moller, D., & Ruf, C. (2024). Prediction of Soil Moisture From Near-Global Cygnss Gnss-Reflectometry Using a Random Forest Machine Learning Model. In *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*, 4465-4471. doi: 10.1109/IGARSS53475.2024.10642723
- WMO. (2023). State of Global Water Resources 2022. *World Meteorological Organization*, 3, 16-18. doi: 10.18356/9789263113337.
- Wu, X., Xu, H., He, H., Wu, Z., Lu, G., & Liao, T. (2024). Agricultural Drought Monitoring Using an Enhanced Soil Water Deficit Index Derived from Remote Sensing and Model Data Merging. *Remote Sensing*, 16(12), 2156. doi: 10.3390/rs16122156
- Yaghoobzadeh, M., Amir Abadi Zade, M., Ramezani, Y., & Pourreza, B. M. (2018). An uncertainty analysis of general circulation models for estimation of soil moisture affected by climate change. *Journal of soil and water research*, 48(5), 1109-1119. doi: 10.22059/ijswr.2017.224039.667603. (In Persian).
- Ye, S., Liu, L., Li, J., Pan, H., Li, W., & Ran, Q. (2023). From rainfall to runoff: The role of soil moisture in a mountainous catchment. *Journal of Hydrology*, 625, 130060. doi: 10.1016/j.jhydrol.2023.130060
- Zhang, P., Lu, J., & Chen, X. (2022). Machine-learning ensembled CMIP6 projection reveals socio-economic pathways will aggravate global warming and precipitation extreme. *Hydrology and Earth System Sciences Discussions*, 2022, 1-40. doi: 10.5194/hess-2022-235
- Zhou, Z., Wang, Y., Li, R., Qi, L., Zhao, Y., Xu, Y., & Huang, J. (2023). The deterioration and restoration of dried soil layers: New evidence from a precipitation manipulation experiment in an artificial forest. *Journal of Hydrology*, 625, 130087. doi: 10.1016/j.jhydrol.2023.130087

