



Simulation of irrigated wheat yield under climate change using an ensemble model of neural network and random forest

Mojgan Ahmadi¹ | Hadi Ramezani Etedali²

1. Department of Water Science and Engineering, Faculty of Agriculture, Imam Khomeini International University, Qazvin, Iran. E-mail: mojgan.ahmadi@edu.ikiu.ac.ir
2. Corresponding Author, Department of Water Science and Engineering, Faculty of Agriculture, Imam Khomeini International University, Qazvin, Iran. E-mail: ramezani@eng.ikiu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 2 July 2025

Received in revised form

5 August 2025

Accepted 30 November 2025

Published online 22 June 2026

Keywords:

Precipitation

Temperature

Scenarios of the sixth report

General circulation models

ABSTRACT

In this study, precipitation, minimum temperature, maximum temperature, and evapotranspiration data from the CNRM-CM6-1, GFDL-ESM4, ACCESS-CM2, and CanESM5 climate models were compared with Qazvin synoptic data for the base period 1986-2014 individually and ensemble. The results showed that evapotranspiration, minimum and maximum temperatures in the group model (combination of the aforementioned climate models using the weighted linear averaging method of the models) are associated with reasonable and appropriate estimates with coefficient of determination values of 0.95 and low RMSE values. The results also showed that running models in groups reduces errors. Using an ensemble model, precipitation data, minimum temperature, maximum temperature, and evapotranspiration were simulated under two scenarios, SSP2_4.5 and SSP5_8.5, for future periods, and the results showed that temperature and evapotranspiration will increase and precipitation will decrease in future periods. The maximum and minimum temperature changes compared to the base period in the period 2026-2050 for the SSP2_4.5 and SSP5_8.5 scenarios will be 1.9, 2.49, 2.98, and 3.31 degrees Celsius, respectively, and the precipitation changes for the SSP2_4.5 and SSP5_8.5 scenarios will be -37.82 and -11.24 mm, respectively. Using climatic parameters, wheat yield was evaluated using random forest, neural network, and ensemble model methods in the baseline period, and the results showed that the ensemble model reduced the error. Therefore, the ensemble model was used to simulate wheat yield in future periods, and the results showed that wheat yield would decrease in future periods. The yield changes in the period 2076-2100 will be -7.22 and -10.81 percent in the SSP2_4.5 and SSP5_8.5 scenarios, respectively.

Cite this article: Ahmadi, M., & Ramezani Etedali, H. (2026). Simulation of irrigated wheat yield under climate change using an ensemble model of neural network and random forest. *Journal of Water and Irrigation Management*, 16 (1), 1-14. DOI: <https://doi.org/10.22059/jwim.2025.397707.1240>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2025.397707.1240>

Publisher: University of Tehran Press.



شبیه‌سازی عملکرد تولید گندم آبی تحت تأثیر تغییر اقلیم با استفاده از مدل گروهی شبکه عصبی و جنگل تصادفی

مژگان احمدی^۱ | هادی رمضانی اعتدالی^۲ ✉

۱. گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه: mojgan.ahmadi@edu.ikiu.ac.ir
 ۲. نویسنده مسئول، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه: ramezani@eng.ikiu.ac.ir

اطلاعات مقاله	چکیده
<p>نوع مقاله: مقاله پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۴/۰۴/۱۱</p> <p>تاریخ بازنگری: ۱۴۰۴/۰۵/۱۴</p> <p>تاریخ پذیرش: ۱۴۰۴/۰۹/۰۹</p> <p>تاریخ انتشار: ۱۴۰۵/۰۴/۰۱</p>	<p>در این پژوهش، داده‌های بارش، دمای حداقل، دمای حداکثر و تبخیر و تعرق مدل‌های اقلیمی CNRM-CM6-1، GFDL-ESM4، ACCESS-CM2 و CanESM5 با داده سینوپتیک قزوین به صورت جداگانه و گروهی در دوره پایه ۲۰۱۴-۱۹۸۶ مقایسه شد. نتایج نشان داد که تبخیر و تعرق، دمای حداقل و حداکثر در مدل گروهی (ترکیب مدل‌های اقلیمی مذکور با استفاده از روش میانگین‌گیری وزن‌دار خطی مدل‌ها) با مقادیر ضریب تبیین ۰/۹۵ و مقادیر کم RMSE با برآورد منطقی و مناسبی همراه است. همچنین نتایج نشان داد که اجرای گروهی مدل‌ها موجب کاهش خطا می‌شود. با استفاده از مدل گروهی داده‌های بارش، دمای حداقل، دمای حداکثر و تبخیر و تعرق تحت دو سناریو SSP2-4.5 و SSP5-8.5 برای دوره‌های آبی شبیه‌سازی شد و نتایج نشان داد که دما و تبخیر و تعرق در دوره‌های آبی افزایش و بارش کاهش خواهد یافت. میزان تغییرات دمای حداکثر و دمای حداقل نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۵۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۱/۹، ۲/۴۹، ۲/۹۸ و ۳/۳۱ درجه سانتی‌گراد و میزان تغییرات بارش برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۳۷/۸۲- و ۱۱/۲۴- میلی‌متر خواهد بود. با استفاده از پارامترهای اقلیمی، عملکرد گندم با روش‌های جنگل تصادفی، شبکه عصبی و مدل گروهی در دوره پایه ارزیابی شد و نتایج نشان داد که مدل گروهی موجب کاهش خطا می‌شود. بنابراین، از مدل گروهی برای شبیه‌سازی عملکرد گندم در دوره‌های آبی استفاده شد و نتایج نشان داد که عملکرد گندم در دوره‌های آبی کاهش می‌یابد. تغییرات عملکرد در دوره ۲۰۷۶-۲۱۰۰، در سناریوی SSP2-4.5 و SSP5-8.5 به ترتیب ۷/۲۲- و ۱۰/۸۱- درصد خواهد بود.</p>
<p>کلیدواژه‌ها: بارش دما سناریوهای گزارش ششم مدل‌های گردش عمومی جو</p>	

استناد: احمدی، مژگان و رمضانی اعتدالی، هادی (۱۴۰۵). شبیه‌سازی عملکرد تولید گندم آبی تحت تأثیر تغییر اقلیم با استفاده از مدل گروهی شبکه عصبی و جنگل تصادفی. نشریه مدیریت آب و آبیاری، ۱۶ (۱)، ۱-۱۴. DOI: <https://doi.org/10.22059/jwim.2025.397707.1240>



۱. مقدمه

به دلیل رشد سریع جمعیت و محدودیت منابع زمینی، حفظ پایداری اکوسیستم‌های کشاورزی توجه زیادی را در سراسر جهان به خود جلب کرده است. تغییرات اقلیمی، به عنوان یکی از مهمترین عوامل تعیین کننده عملکرد محصولات کشاورزی، می‌تواند ۳۰ تا ۵۰ درصد از تغییرپذیری عملکرد جهانی را توضیح دهد (Ray et al., 2015; Rezaei et al., 2018). در کنار گرم شدن آب‌وهوا، شدت، فراوانی و مدت زمان رویدادهای شدید اقلیمی نیز در حال افزایش است که می‌تواند بی‌ثباتی سیستم‌های تولید کشاورزی را تشدید کند (Zheng et al., 2012; Chen et al., 2018). پیش‌بینی تأثیر بالقوه تغییرات اقلیمی آینده و شرایط شدید اقلیمی بر تولید کشاورزی برای تدوین استراتژی‌های سازگاری جهت کاهش خطرات اقلیمی بسیار مهم است (Chen et al., 2018).

پروژه مقایسه متقابل مدل‌های جفت‌شده (CMIP)^۱ شبه‌سازی‌هایی از آب‌وهوای تاریخی، فعلی و آینده را توسعه می‌دهد که به طور گسترده برای ارزیابی تأثیر تغییرات اقلیمی بر تولید محصولات کشاورزی مورد استفاده قرار گرفته است (Arunrat et al., 2022). مرحله ششم پروژه مقایسه متقابل مدل‌های اقلیمی (CMIP6)^۲ مسیرهای اجتماعی-اقتصادی مشترک (SSP)^۳ جدیدی را معرفی کرده است که فرضیات مرجع اجتماعی-اقتصادی متفاوتی را توصیف می‌کند. مطالعات قبلی نشان داده است که مدل‌های CMIP6 نتایج قابل قبول تری نسبت به مدل‌های CMIP5^۴ برای پیش‌بینی دما و بارش ارائه می‌دهند (Du et al., 2022). برای گنجاندن تخمین‌های اقلیمی CMIP6 بر عملکرد و کیفیت گندم، به کار بیش‌تری در آینده نیاز است. تجزیه و تحلیل جامع رابطه بین تغییرات اقلیمی آینده و عملکرد گندم برای آگاهی بخشی به کشاورزان و سیاست‌گذاران در راستای اتخاذ شیوه‌های کشاورزی سازگار با اقلیم و توسعه استراتژی‌هایی برای کاهش اثرات تغییرات اقلیمی بر تولید گندم ضروری است.

پیش‌بینی‌های دقیق عملکرد گندم برای بهینه‌سازی و تطبیق شیوه‌های کشاورزی با شرایط اقلیمی آینده و کاهش اثرات منفی تغییرات اقلیمی بسیار مهم است. برخلاف مطالعات قبلی که اغلب از روش‌های آماری سنتی استفاده می‌کنند، Ruan et al. (2023) از الگوریتم‌های قدرتمند یادگیری ماشین برای پیش‌بینی عملکرد گندم تحت سناریوهای مختلف تغییرات اقلیمی استفاده کردند. گندم یک منبع حیاتی غلات است که غذای تقریباً ۴۰ درصد از جمعیت جهان را تأمین می‌کند (Giraldo et al., 2019; Ashfaq et al., 2024). اکثر کشاورزان، به ویژه آن‌هایی که در کشورهای در حال توسعه هستند، منحصراً به دانش محدود و تجربه قبلی خود وابسته هستند. این دانش محدود، رقابت جهانی و برآورده کردن تقاضاهای رو به رشد را برای آن‌ها چالش برانگیز می‌کند (Sinwar et al., 2020).

مدل‌های آماری مدت‌هاست که برای استنباط روابط بین محصولات کشاورزی و اقلیم به کار گرفته می‌شوند و قدمت آن‌ها به بیش از یک قرن پیش برمی‌گردد (Blair, 1919). کاربردهای آن‌ها به تازگی شاهد افزایش سریعی بوده است که بیش‌تر ناشی از نگرانی‌های فزاینده در مورد تغییرات اقلیمی و نیاز هم‌زمان به ارزیابی تأثیرات اقلیمی بر کشاورزی است. این محبوبیت هم‌چنین به دلیل دسترسی روزافزون به تجزیه و تحلیل داده‌ها و ابزارهای آماری افزایش یافته است. از یک سو، سوابق تاریخی اقلیمی و کشاورزی از طریق اینترنت قابل دسترسی‌تر شده‌اند. از سوی دیگر، داده‌های جدید با استفاده سریع از شبکه‌های حس‌گر و فناوری‌های تجاری همواره در حال تولید هستند. در دهه‌های گذشته، پیشرفت‌های چشم‌گیری در زمینه تجزیه و تحلیل داده‌ها صورت گرفته است. مطالعات اولیه بیش‌تر بر رگرسیون خطی برای مرتبط کردن عملکرد محصولات کشاورزی با اقلیم متکی بودند. اکنون، روند به سمت یادگیری ماشینی یا هوش مصنوعی، مانند ماشین‌های بردار پشتیبان، شبکه‌های عصبی، جنگل‌های تصادفی، XGBoost^۵ و یادگیری عمیق در حال تغییر است (Crane-Droesch, 2018; Ciscar et al., 2018; Hu et al., 2018).

(*al.*, 2023). مدل‌های یادگیری ماشینی قادر به حل روابط پیچیده و غیرخطی بین محصولات کشاورزی و اقلیم هستند.

از الگوریتم‌های یادگیری ماشینی اغلب برای پیش‌بینی میزان تولید محصولات غذایی استفاده می‌شود. این الگوریتم‌ها قادرند با داده‌های دارای ابعاد بالا کار کنند، روابط غیرخطی را شناسایی کنند و الگوهای پیچیده را استخراج نمایند (Van Klompenburg *et al.*, 2020). پیوندهای میان عوامل وابسته و مستقل، از طریق آموزش مشاهده‌ای مکانی-زمانی و با بهره‌گیری از مجموعه داده‌های بزرگ، توسط این الگوریتم‌ها شناسایی می‌شوند. تکنیک‌های یادگیری ماشینی به روش‌های مختلفی برای شناسایی محصولات کشاورزی و پیش‌بینی عملکرد آن‌ها استفاده شده‌اند.

مدل‌هایی مانند شبکه‌های عصبی مصنوعی، رگرسیون خطی چندگانه (Fashoto *et al.*, 2021)، رگرسیون جنگل تصادفی (Pang *et al.*, 2022; Tariq *et al.*, 2023) و XGboost (Sahbeni *et al.*, 2023) برای تخمین عملکرد استفاده می‌شوند. این مدل‌ها مواردی مانند دما، رطوبت، سرعت باد، بارندگی و گازهای جوی را در نظر می‌گیرند. بیش‌برازش یکی از چالش‌های اصلی این مدل‌ها است که می‌تواند کاربرد آن‌ها را محدود کند، حتی زمانی که در مواجهه با مسائل مرتبط با شرایط آب‌وهوایی عملکرد مناسبی دارند. استفاده از روش‌های گروهی با چندین مدل، پیش‌بینی عملکرد را دقیق‌تر می‌کند و در عین حال بیش‌برازش را کاهش می‌دهد (Fei *et al.*, 2023; Li *et al.*, 2023). روش‌های گروهی، مانند یادگیری فرامشین، ممکن است با ترکیب نتایج بسیاری از مدل‌ها، دقت پیش‌بینی‌های رشد گندم را بهبود بخشند.

مطالعات متعددی (Iqbal *et al.* 2024; Zhang *et al.*, 2023; Bento *et al.*, 2021; Ahmadi *et al.*, 2024; Yanagi *et al.*, 2024; Karatayev *et al.*, 2022; Borzo *et al.*, 2023; Shiyokhi Soghanloo *et al.*, 2021; Lotfi *et al.*, 2021; Aini 2024; Nargeseh *et al.*, 2024; Moradi and Naghizadeh., 2023) در ارتباط با تغییر اقلیم و عملکرد گندم انجام شده است. در این پژوهش، با هدف بررسی اثر تغییر اقلیم بر عملکرد گندم در دشت قزوین، از ترکیب مدل‌های گردش عمومی CNRM-CM6-1، ACCESS-CM2 و CanESM5 و سناریوهای اقلیمی SSP2-4.5 و SSP5-8.5 در دوره‌های پایه و آینده استفاده شده است. وجه تمایز این مطالعه در بهره‌گیری هم‌زمان از چند مدل اقلیمی به همراه تکنیک‌های پیشرفته هوش مصنوعی برای پیش‌بینی عملکرد گندم در سطح منطقه‌ای است؛ رویکردی که در مطالعات پیشین کم‌تر مورد توجه قرار گرفته است.

۲. روش‌شناسی پژوهش

۲.۱. منطقه مورد مطالعه

استان قزوین در شمال غربی ایران واقع شده است (شکل ۱). کشاورزی نقش مهمی در اقتصاد استان قزوین ایفا می‌کند. منطقه مورد مطالعه (دشت قزوین) با مساحت ۴۵۰ هزار هکتار از نظر محصولات کشاورزی در بین دشت‌های ایران اهمیت دارد. این دشت دارای آب‌وهوای نیمه‌خشک، تابستان‌های گرم و زمستان‌های نسبتاً سرد است. در این دشت، یک ایستگاه هواشناسی سینوپتیک با آمار بلندمدت (قزوین) وجود دارد. با توجه به آمار بلندمدت ایستگاه سینوپتیک قزوین، در این مطالعه از داده‌های این ایستگاه استفاده شد. این ایستگاه در طول جغرافیایی ۵۰/۰۳ درجه شرقی و عرض جغرافیایی ۳۶/۱۵ درجه شمالی واقع شده و ارتفاع آن ۱۲۷۹/۲ متر است. میانگین دمای حداکثر و حداقل هوای سالانه در دوره پایه (۲۰۱۴-۱۹۸۶) به ترتیب حدود ۱۷ و ۵ درجه سانتی‌گراد و میانگین بارش سالانه حدود ۲۴۸ میلی‌متر است. با توجه به این که گندم یکی از محصولات مهم دشت قزوین به‌شمار می‌رود این محصول برای ارزیابی انتخاب شد.

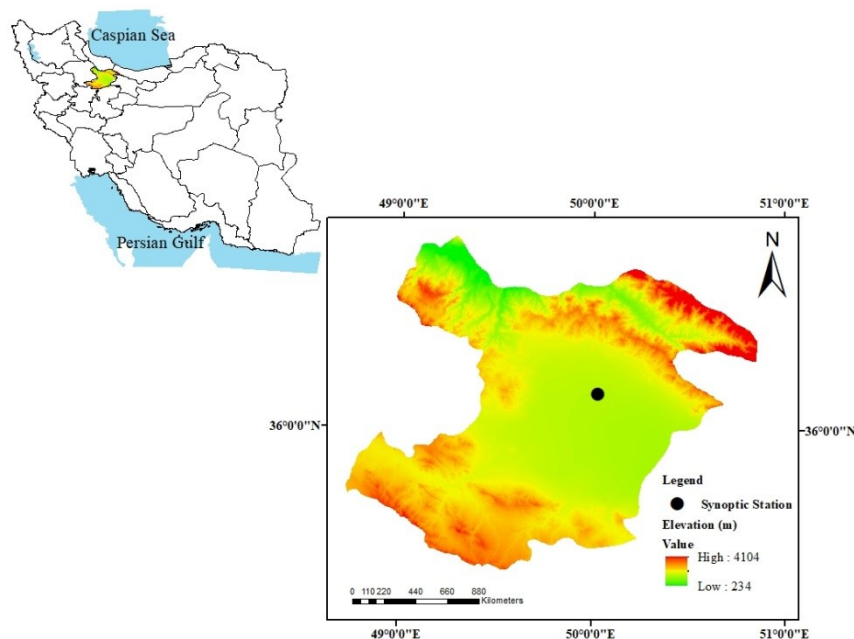


Figure 1. The location of the study area

۲.۲. مدل‌های گردش عمومی جو

پروژه مقایسه مدل جفت‌شده (CMIP) که در سال ۱۹۹۵ آغاز شد، اکنون در مرحله ششم خود قرار دارد. از جمله مزایای CMIP6 نسبت به مدل CMIP5 می‌توان به افزایش تعداد لایه‌های عمودی اشاره کرد که منجر به شبهه‌سازی دقیق‌تر در استراتوسفر می‌شود. مدل‌های گردش عمومی جو (GCM) که براساس ششمین گزارش ارزیابی هیئت بین‌الدول تغییر اقلیم (CMIP6) تهیه شده‌اند، نسخه‌های بهبود یافته از CMIP‌های قبلی هستند که از چندین جهت، از جمله وضوح جغرافیایی بهتر و مدل‌سازی بهبود یافته فرایندهای میکروفیزیکی ابر، بهبود یافته‌اند. بنابراین، گروه GCM گزارش ششم برای پیش‌بینی آب‌وهوا نسبت به گروه‌های قبلی CMIP قابل اعتمادتر است. سناریوی SSP2-4.5 روندهای اجتماعی-اقتصادی میانه و کاهش متوسط انتشار گازهای گلخانه‌ای را نشان می‌دهد که منجر به تغییرات اقلیمی متوسط می‌شود. سناریو SSP5-8.5 نشان‌دهنده رشد اقتصادی سریع با وابستگی شدید به سوخت‌های فسیلی است که منجر به بالاترین سطح انتشار گازهای گلخانه‌ای و بیش‌ترین افزایش دما و تغییرات در الگوهای بارندگی می‌شود.

در این مطالعه، برای بررسی تغییرات اقلیمی آینده از داده‌های روزانه دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های گردش عمومی جو استفاده شد. تبخیر و تعرق به‌روش هارگریوز سامانی محاسبه شد. مجموعه داده GDDP-CMIP6 از خروجی مدل‌های گردش عمومی پروژه CMIP6 که در راستای گزارش ششم IPCC تهیه شده‌اند (Eyring et al., 2016)، به‌دست آمده است. این داده‌ها سناریوهای انتشار گازهای گلخانه‌ای را طبق مسیرهای اجتماعی-اقتصادی مشترک (SSPs) شامل SSP2-4.5 و SSP5-8.5 پوشش می‌دهند (O'Neill et al., 2016; Meinshausen et al., 2020). خروجی مدل‌ها با استفاده از روش آماری ABCSD به‌صورت روزانه ریزمقیاس و تصحیح اریبی شده‌اند (Thrasher et al., 2022) و از طریق Google Earth Engine در دسترس قرار گرفته‌اند. این داده‌ها با وضوح مکانی ۰/۲۵ درجه و وضوح زمانی روزانه، تحت سناریوهای مختلف اقلیمی (SSPها) ارائه شده‌اند. در این مطالعه، از داده‌های روزانه دمای حداقل، دمای حداکثر و بارش مدل‌های گردش عمومی ACCESS-CM2، GFDL-ESM4، CNRM-CM6-1 و CanESM5 تحت دو

سناریوی SSP2_4.5 و SSP5_8.5 برای دوره پایه ۲۰۱۴-۱۹۸۶ و دوره‌های آتی ۲۰۲۵-۲۰۲۶، ۲۰۷۵-۲۰۵۰ و ۲۰۷۵-۲۱۰۰ استفاده شده است.

۳.۲. شبکه عصبی

شبکه‌های عصبی مصنوعی (ANNs) ابزارهای قدرتمندی در یادگیری ماشین هستند که از ساختار مغز انسان الگوبرداری شده‌اند. می‌توان از آن‌ها برای تشخیص الگوهای پیچیده، یادگیری از مجموعه داده‌های پویا و انجام پیش‌بینی‌های بلادرنگ استفاده کرد (Haykin, 2009). شبکه‌های عصبی مدلهایی ریاضی هستند که با بهره‌گیری از الگوریتم‌های پیچیده، وزن نورون‌ها و ارتباطات میان آن‌ها را تنظیم می‌کنند. در فرایند یادگیری، شبکه با مقایسه خروجی پیش‌بینی شده با مقدار واقعی، وزن‌ها را به‌روزرسانی می‌کند؛ فرایندی که به آن «آموزش» گفته می‌شود (Goodfellow et al., 2016). به‌طور معمول، یک شبکه عصبی دارای لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است که داده‌های خام را دریافت کرده، آن‌ها را پردازش نموده و خروجی نهایی را تولید می‌کند.

۴.۲. جنگل تصادفی

الگوریتم جنگل تصادفی (Random Forest) یکی از روش‌های قدرتمند و پرکاربرد در یادگیری ماشین مبتنی بر ساختار درختی است که به‌طور گسترده برای مسائل طبقه‌بندی و رگرسیون مورد استفاده قرار می‌گیرد (Breiman, 2001). این الگوریتم با ساخت مجموعه‌ای از درخت‌های تصمیم‌گیری که هر کدام بر روی نمونه‌های تصادفی از داده‌ها آموزش می‌بینند، عملکردی ترکیبی ارائه می‌دهد. در فرایند ساخت هر درخت، نه تنها داده‌ها به‌صورت تصادفی انتخاب می‌شوند، بلکه در هر گره، تنها زیرمجموعه‌ای از ویژگی‌ها برای تقسیم داده‌ها در نظر گرفته می‌شود؛ رویکردی که منجر به تنوع ساختاری در درخت‌ها و در نتیجه افزایش دقت و کاهش بیش‌برازش می‌گردد. در مرحله پیش‌بینی، الگوریتم پاسخ همه درخت‌ها را تجمیع می‌کند؛ برای طبقه‌بندی از رأی‌گیری اکثریت و برای رگرسیون از میانگین‌گیری استفاده می‌شود. تصادفی بودن در انتخاب نمونه‌ها و ویژگی‌ها، مزیتی کلیدی در ایجاد مدل‌هایی با قابلیت تعمیم بهتر فراهم می‌آورد (Hastie et al., 2009).

در این پژوهش، از داده‌های مشاهده‌ای مربوط به عملکرد گندم و متغیرهای اقلیمی شامل دمای حداقل و حداکثر، بارندگی و تبخیر و تعرق در بازه زمانی ۱۹۸۶ تا ۲۰۱۴ استفاده شد. برای آموزش و آزمون مدل‌ها، داده‌های مربوط به دوره پایه پس از پاک‌سازی و نرمال‌سازی، به‌صورت تصادفی به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. این روش با هدف جلوگیری از بروز بایاس در مدل و افزایش تعمیم‌پذیری انجام شده است.

برای مدل‌سازی، از دو الگوریتم یادگیری ماشین شامل جنگل تصادفی و شبکه عصبی مصنوعی استفاده شد. در مدل جنگل تصادفی، تعداد درخت‌ها ۱۵۰ عدد در نظر گرفته شد و اهمیت متغیرها نیز محاسبه گردید. مدل شبکه عصبی با استفاده از یک لایه پنهان شامل ۷۶ نورون توسعه داده شد. تابع فعال‌ساز در این مدل خطی در نظر گرفته شد و تعداد تکرارهای مجاز آموزش تا ۱۰۰۰ بار تعیین گردید. فرایند آموزش مدل‌ها با استفاده از کتابخانه‌های randomForest و nnet در محیط R انجام شد. پس از آموزش، عملکرد مدل‌ها با استفاده از داده‌های آزمون و معیارهای ریشه میانگین مربعات خطا (RMSE)^۹، خطای اربیبی (MBE)^{۱۰} و ضریب تعیین (R^۲)^{۱۱} ارزیابی گردید.

در ادامه، ترکیب وزن‌دار خروجی دو مدل به‌صورت یک مدل تلفیقی پیاده‌سازی شد تا بهترین پیش‌بینی براساس کم‌ترین مقدار RMSE حاصل گردد.

۵.۲. آماره‌های ارزیابی

برای ارزیابی نتایج به‌دست‌آمده از آماره‌های ارزیابی جذر میانگین مربعات خطا (RMSE)، خطای اریبی (MBE) و ضریب تبیین (R^2) استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad \text{رابطه ۱}$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad \text{رابطه ۲}$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad \text{رابطه ۳}$$

در روابط یادشده، O_i : مقادیر داده‌های اندازه‌گیری‌شده، P_i : مقادیر داده‌های شبیه‌سازی‌شده، \bar{O}_i : میانگین مقادیر داده‌های اندازه‌گیری‌شده، \bar{P}_i : میانگین مقادیر داده‌های شبیه‌سازی‌شده و n : تعداد داده‌ها است. RMSE میانگین مقادیر انحراف شبیه‌سازی‌شده را از مقادیر اندازه‌گیری‌شده نشان می‌دهد. هرچه مقدار RMSE کوچک‌تر باشد به معنی مطلوب‌بودن مدل می‌باشد. شاخص MBE بیانگر میزان اریبی روش است، در یک تخمین نسبتاً دقیق می‌باید نزدیک به صفر باشد. ضریب همبستگی بین -1 و 1 قرار می‌گیرد. در نتیجه R^2 که توان دوم آن است بین صفر و یک قرار خواهد داشت. اگر این همبستگی زیاد باشد (نزدیک یک)، مدل داده‌ها را خوب برازش کرده است، درحالی‌که اگر همبستگی پایین (نزدیک به صفر) باشد، مدل برازش خوبی از داده‌ها ارائه نداده است.

۳. یافته‌های پژوهش و بحث

۳.۱. بررسی تغییرات بارش، تبخیر و تعرق، دمای حداقل و حداکثر

داده‌های دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های اقلیمی GFDL-ESM4، CNRM-CM6-1، ACCESS-CM2 و CanESM5 در دوره پایه ۲۰۱۴-۱۹۸۶ با داده سینوپتیک قزوین به‌صورت جداگانه و گروهی (ترکیب مدل‌های اقلیمی مذکور) مقایسه شد. در این مطالعه، به‌منظور برآورد مدل گروهی، از روش میانگین‌گیری وزن‌دار خطی مدل‌ها با هدف کمینه‌سازی ریشه میانگین مربعات خطا (RMSE) نسبت به داده‌های مشاهداتی استفاده شد. در این روش، وزن‌دهی به مدل‌های اقلیمی به‌گونه‌ای انجام شد که ترکیب خطی آن‌ها، بهترین تطابق را با داده‌های مشاهداتی و کمترین خطای ممکن را داشته باشد.

Table 1. Evaluation of minimum temperature, maximum temperature, precipitation and evapotranspiration (1986-2014)

Parameter	GCM	R^2	RMSE	MBE
Minimum temperature (°C)	ACCESS-CM2	0.94	2.39	1.3
	CanESM5	0.94	2.55	1.6
	CNRM-CM6-1	0.93	2.67	1.5
	GFDL-ESM4	0.94	2.45	1.5
	Ensemble model	0.96	2.22	1.4
Maximum temperature (°C)	ACCESS-CM2	0.93	2.82	0.2
	CanESM5	0.94	2.66	0.4
	CNRM-CM6-1	0.94	2.69	0.1
	GFDL-ESM4	0.93	2.7	0.1
	Ensemble model	0.95	2.26	0.2
Precipitation (mm)	ACCESS-CM2	0.15	31.51	-6
	CanESM5	0.12	32.55	-6.4
	CNRM-CM6-1	0.23	29.49	-5.4
	GFDL-ESM4	0.1	32.91	-5.4
	Ensemble model	0.26	28.28	-5.7
Evapotranspiration (mm)	ACCESS-CM2	0.95	15.17	-0.6
	CanESM5	0.95	14.4	0.5
	CNRM-CM6-1	0.95	14.4	-1.2
	GFDL-ESM4	0.95	14.48	-0.9
	Ensemble model	0.96	13.05	-0.5

نتایج (جدول ۱) نشان می‌دهد که دمای حداقل و حداکثر در مدل گروهی با مقادیر ضریب تبیین ۰/۹۵ در سطح معنی‌داری ۹۵ درصد ($P\text{-value}=0.00$) و مقادیر کم RMSE با برآورد منطقی و مناسبی همراه است. همچنین نتایج ضریب تبیین دما نشان می‌دهد که ترکیب مدل‌های گردش عمومی جو و داده‌های ایستگاه سینوپتیک همبستگی بالایی دارند. مقدار ضریب تبیین بیش از ۹۰ درصد نشان می‌دهد که بیش از ۹۰ درصد واریانس موجود در داده‌های دمای حداقل و حداکثر ایستگاه سینوپتیک با داده‌های گروهی مدل‌های گردش عمومی جو توصیف می‌شود. نتایج نشان داد که اجرای گروهی مدل‌ها موجب کاهش خطا می‌شود. ارزیابی اثرات تغییر اقلیم بر احتمال تنش گرمایی در طول گلدهی گندم با اجرای گروهی ۱۵ مدل AOGCM در انگلستان نشان‌دهنده کاهش معنی‌دار عدم قطعیت پیش‌بینی‌ها و خطا در مقایسه با استفاده از یک مدل بود (Semenov and Stratonovitch, 2010) که با نتیجه مطالعه حاضر همخوانی دارد. Shahin Rukhsar *et al.* (2020) در شبیه‌سازی داده‌های هواشناسی در ایستگاه سینوپتیک رشت از ترکیب مدل‌های گروهی گردش عمومی جو استفاده کردند. نتایج آن‌ها نشان داد که ترکیب گروهی مدل‌ها با دقت بیشتری پارامترهای اقلیمی را شبیه‌سازی کرد که با نتایج مطالعه حاضر همخوانی دارد. میانگین سالانه دمای حداقل و حداکثر، بارش و تبخیر و تعرق در شکل (۲) آورده شده است.

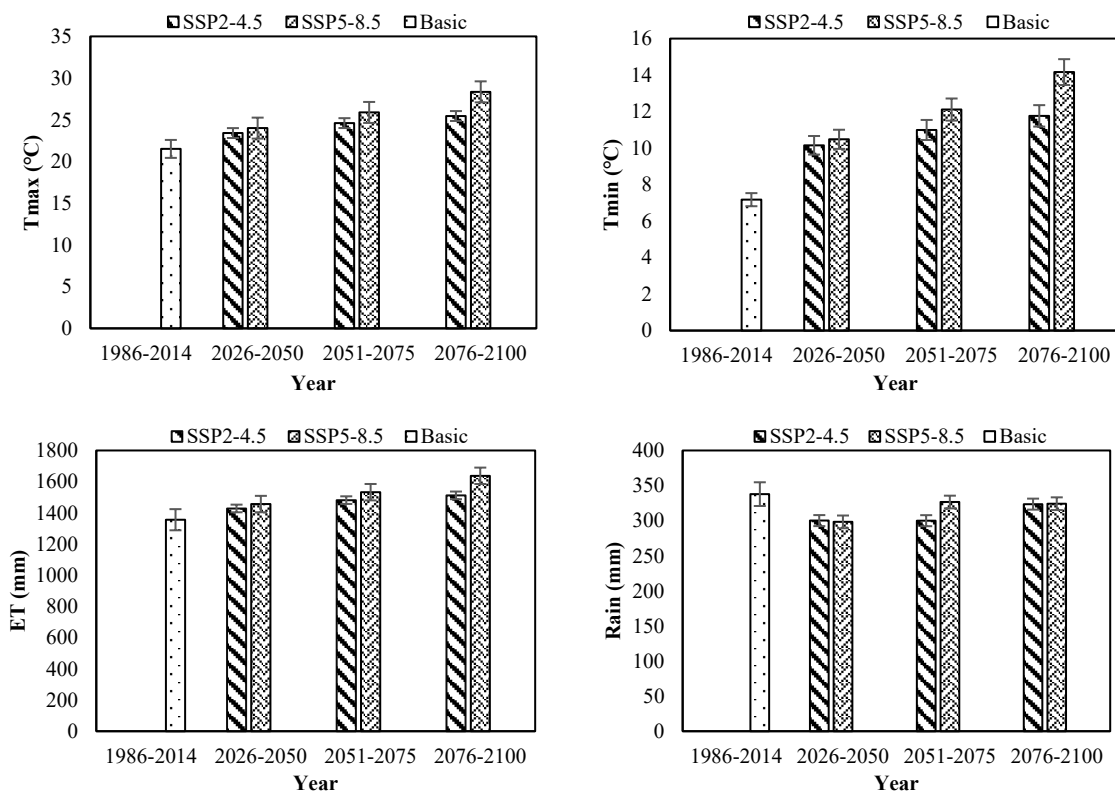


Figure 2. Annual average minimum and maximum temperatures, total precipitation and evapotranspiration

نتایج (شکل ۲) نشان می‌دهد که دمای حداکثر در دوره‌های آبی افزایش می‌یابد به طوری که میزان تغییرات دمای حداکثر نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۲۵ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۱/۹ و ۲/۴۹ درجه سانتی‌گراد، در دوره ۲۰۷۵-۲۰۵۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۳/۰۹ و ۴/۳۷ درجه سانتی‌گراد و

در دوره ۲۰۷۶-۲۱۰۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۳/۹۴ و ۶/۸۴ درجه سانتی‌گراد خواهد بود. دمای حداقل در دوره‌های آبی افزایش می‌یابد و میزان تغییرات آن نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۵۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۲/۹۸ و ۳/۳۱ درجه سانتی‌گراد خواهد بود. بارش در دوره‌های آبی کاهش می‌یابد و تغییرات آن نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۷۵ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۳۷/۸۲- و ۱۱/۲۴- میلی‌متر خواهد بود. تبخیر و تعرق در دوره‌های آبی افزایش می‌یابد و میزان تغییرات آن در دوره ۲۰۷۵-۲۱۰۰ نسبت به دوره پایه برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۱۵۶/۲۳ و ۲۸۱/۶۸ میلی‌متر خواهد بود. در مطالعه‌ای Karimi et al. (2024) به بررسی اثرات تغییر اقلیم بر تبخیر و تعرق مرجع بر اساس سناریوهای گزارش ششم در ایستگاه خرم‌آباد پرداختند. برای محاسبه تبخیر و تعرق از روش هارگریوز استفاده کرده بودند و نتایج آن‌ها نشان داد که متوسط دمای حداقل و حداکثر و تبخیر و تعرق در دوره‌های آبی نسبت به دوره پایه افزایش می‌یابد که با نتایج مطالعه حاضر همخوانی دارد. در مطالعه‌ای Din Pajouh and Allahvardipour (2025) تغییرات تبخیر و تعرق مرجع دشت مغان را مطابق گزارش ششم بررسی کردند. نتایج آن‌ها نشان داد که دمای حداقل و حداکثر تحت بدبینانه‌ترین سناریو (SSP5-8.5) به ترتیب از ۹/۹۵ و ۲۱/۱۲ درجه سانتی‌گراد دوره پایه، به ۱۶/۰۴ و ۲۷/۶۸ درجه سانتی‌گراد در دوره ۲۰۸۱-۲۱۰۰ میلادی خواهد رسید. میانگین تبخیر و تعرق مرجع دشت مغان از ۱۱۱۴ (میلی‌متر بر سال) در دوره پایه، با ۲۰ درصد افزایش به ۱۳۳۴ (میلی‌متر بر سال) در دوره ۲۰۸۱-۲۱۰۰ میلادی می‌رسد که با نتایج مطالعه حاضر همخوانی دارد.

۲.۳. شبه‌سازی عملکرد گندم

عملکرد گندم با استفاده از پارامترهای دمای حداقل، دمای حداکثر، بارش و تبخیر و تعرق (دوره کشت) شبه‌سازی شد. برای این منظور از روش‌های جنگل تصادفی، شبکه عصبی و روش گروهی (ترکیب جنگل تصادفی و شبکه عصبی) استفاده شد. نتایج ارزیابی روش‌ها در جدول (۳) آورده شده است.

Table 3. Statistical evaluation of random forest, neural network and ensemble methods in performance simulation (1986-2014)

Step	Method	R ²	RMSE (ton/ha)	MBE (ton/ha)
Train	Neural network	0.99	0.001	0.007
	Random forest	0.93	0.2	-0.002
	Ensemble model	0.98	0.13	0.007
Test	Neural network	0.73	0.44	-0.03
	Random forest	0.45	0.33	-0.03
	Ensemble model	0.67	0.3	-0.01

در جدول (۳)، مقادیر پیش‌بینی شده عملکرد گندم توسط مدل‌ها در دوره پایه (۱۹۸۶-۲۰۱۴) با داده‌های مشاهداتی مقایسه شده است. این جدول شامل نتایج ارزیابی مدل‌ها در داده‌های آموزش و آزمون است. نتایج جدول (۳) نشان می‌دهد که روش شبکه عصبی و جنگل تصادفی در مرحله آموزش با ضریب تبیین بیش از ۰/۹ و مقادیر اندک RMSE دقت بالایی در شبه‌سازی عملکرد گندم در دوره پایه داشتند. در مرحله آزمون روش گروهی با ضریب تبیین ۰/۶۷، RMSE برابر ۰/۳ (تن بر هکتار) و MBE ۰/۰۱- (تن بر هکتار) دقت بالاتری نسبت به روش‌های جنگل تصادفی و شبکه عصبی داشت و بنابراین این روش برای شبه‌سازی گندم در دوره‌های آبی انتخاب شد. در مطالعه‌ای Iqbal et al. (2024) به بررسی پیش‌بینی عملکرد گندم با استفاده از مدل‌های یادگیری ماشین تحت سناریوهای تغییر اقلیم در پنجاب پاکستان پرداختند. آن‌ها از سه مدل رگرسیون جنگل تصادفی، شبکه عصبی (پرسپترون چند لایه) و درخت تقویتی برای

توسعه یک مدل گروهی استفاده کردند. نتایج آن‌ها نشان داد که مدل گروهی با $R=0/988$ و $MAE=0/09$ عملکرد فوق‌العاده‌ای در شبیه‌سازی عملکرد نشان داد و از روش‌های رگرسیون جنگل تصادفی، شبکه عصبی و درخت تقویتی بهتر بود که با نتایج مطالعه حاضر همخوانی دارد.

پس از کالیبره کردن مدل گروهی با داده‌های دوره پایه، عملکرد گندم برای دوره‌های آتی تحت سناریوهای SSP2-4.5 و SSP5-8.5 شبیه‌سازی شد. میانگین سالانه عملکرد گندم در دوره پایه و آتی در شکل (۳) آورده شده است.

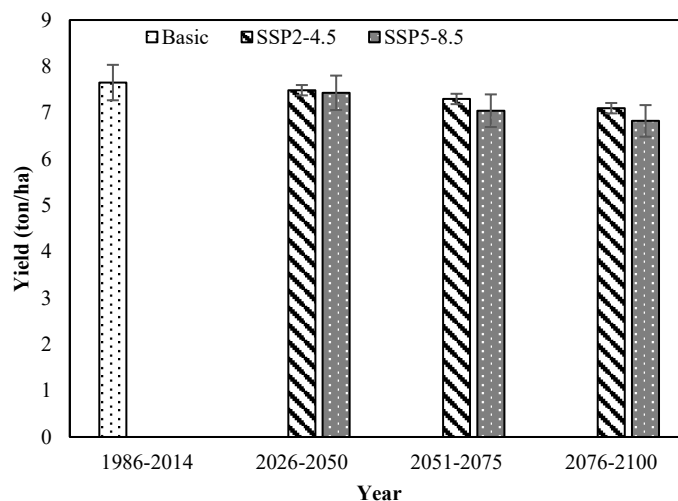


Figure 3. Average annual maize yield in future periods

نتایج شکل (۳) نشان می‌دهد که عملکرد گندم در دوره‌های آتی نسبت به دوره پایه کاهش می‌یابد. تغییرات عملکرد در دوره‌های ۲۰۲۶-۲۰۵۰، ۲۰۷۵-۲۱۰۰ و ۲۰۷۶-۲۱۰۰ به ترتیب برابر ۲/۱۵-، ۴/۶۲- و ۷/۲۲- درصد، در سناریوی SSP2-4.5 و در سناریوی SSP5-8.5 دوره‌های ۲۰۲۶-۲۰۵۰، ۲۰۷۵-۲۱۰۰ و ۲۰۷۶-۲۱۰۰ به ترتیب برابر ۲/۸۸-، ۷/۹۴- و ۱۰/۸۱- درصد بود. در مطالعه‌ای، Mirshekari *et al.* (2025) تأثیر تغییر اقلیم بر عملکرد گندم در مناطق خشک ایران را تحت سناریوهای SSP2-4.5 و SSP5-8.5 بررسی کردند. نتایج آن‌ها نشان داد که افزایش قابل توجه دمای سالانه و کاهش بارندگی تحت هر دو سناریو (SSP2-4.5 و SSP5-8.5) در مقایسه با دوره پایه وجود دارد. در ایرانشهر، پیش‌بینی می‌شود که عملکرد در طول سال‌های ۲۰۲۶-۲۰۵۰ تحت سناریوی SSP2-4.5، ۱۶/۷ درصد افزایش یابد، اما تا سال ۲۱۰۰ میلادی، به‌ویژه در سناریوهای با انتشار بالا، کاهش یابد. در مقابل، منطقه زابل کاهش مداوم عملکرد را نشان می‌دهد و تا پایان قرن به ۲۶/۳۲ درصد می‌رسد. در مطالعه‌ای، Eddamiri *et al.* (2024) عملکرد گندم در مراکش را از سال ۲۰۲۱-۲۰۴۰ با استفاده از مدل‌های اقلیمی متعدد و الگوریتم‌های یادگیری ماشین شبیه‌سازی کردند. از متغیرهای دمای حداقل، دمای حداکثر و روش جنگل تصادفی، XGBoost، LightGBM و Gradient Boosting Regressor، برای توسعه یک مدل یادگیری گروهی برای پیش‌بینی عملکرد گندم در مقیاس استانی در مراکش استفاده شدند. نتایج نشان می‌دهد که رویکرد یادگیری گروهی، خطاهای پیش‌بینی را در مقایسه با مدل‌های منفرد به‌طور قابل توجهی کاهش داده و به ضریب تعیین بالای ۰/۸۲ و خطای جذر میانگین مربعات (RMSE) پایین ۳۰۰/۵۱ کیلوگرم در هکتار دست یافته است. پیش‌بینی می‌شود که عملکرد گندم تا سال ۲۰۴۰ تحت سناریوی مسیره‌های اجتماعی-اقتصادی مشترک متوسط (SSP2-4.5) به‌طور متوسط ۱۰ درصد کاهش یابد، درحالی‌که تحت سناریوی انتشار

بالا (SSP5-8.5)، عملکرد می‌تواند تا ۶۰ درصد در برخی استان‌ها کاهش یابد. سری زمانی عملکرد گندم در شکل (۴) و ارزیابی روند عملکرد گندم در دوره آتی جدول (۴) آورده شده است.

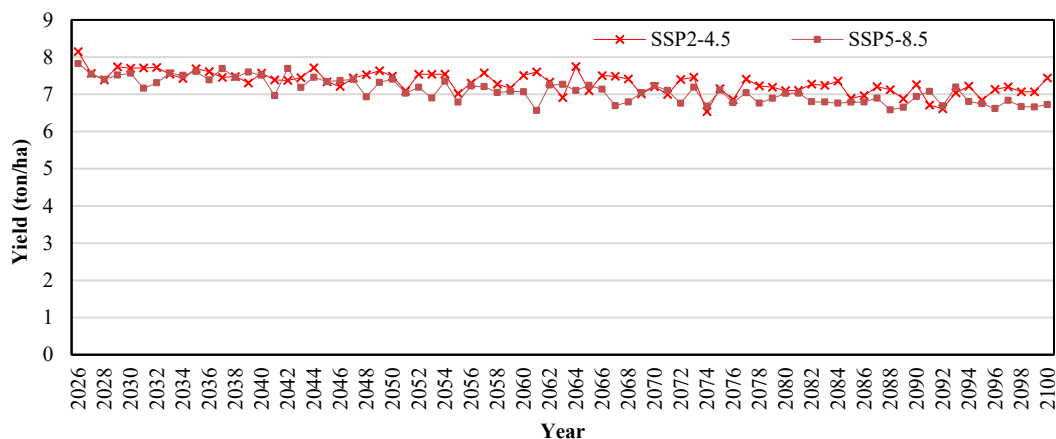


Figure 4. Wheat yield time series

Table 4. Mann-Kendall test results for scenarios

Scenario	z	P-value	S	τ
SSP5-8.5	-7.575	3.59e-14	-1657	-0.597
SSP2-4.5	-6.2759	3.476e10	-1373	-0.4948

نتایج جدول (۴) نشان می‌دهد که براساس آزمون Mann-Kendall ($\tau = -0.597$, $p < 0.0001$) برای سناریوی SSP5-8.5 و ($\tau = -0.4948$, $p < 0.0001$) برای سناریوی SSP2-4.5، روند عملکرد گندم در هر دو سناریو از سال ۲۰۲۶ تا ۲۱۰۰ نزولی و معنادار است. این روند نشان‌دهنده تأثیر منفی افزایش دما و تغییر الگوی بارندگی بر عملکرد آینده است. شیب روند منفی می‌تواند نشانگر نیاز به راهکارهای سازگاری مانند ارقام مقاوم یا بهبود مدیریت آبیاری باشد.

۴. نتیجه‌گیری

تغییرات اقلیمی تاکنون بر عملکرد محصولات کشاورزی تأثیر گذاشته و همچنان تأثیر خواهد گذاشت. درک و پیش‌بینی چگونگی تأثیر تغییرات اقلیمی بر محصولات کشاورزی ضروری است. در این پژوهش، داده‌های بارش، دمای حداقل، دمای حداکثر و تبخیر و تعرق بارش مدل‌های اقلیمی ACCESS-CM2، GFDL-ESM4، CNRM-CM6-1 و CanESM5 با دوره پایه ۲۰۱۴-۱۹۸۶ با داده سینوپتیک قزوین به صورت جداگانه و ترکیبی مقایسه شد. نتایج نشان داد که تبخیر و تعرق، دمای حداقل و حداکثر در مدل گروهی با مقادیر ضریب تبیین ۰/۹۵ در سطح معنی‌داری ۹۵ درصد و مقادیر کم RMSE با برآورد منطقی و مناسبی همراه است. همچنین نتایج نشان داد که اجرای گروهی مدل‌ها موجب کاهش خطا می‌شود. با استفاده از مدل گروهی داده‌های بارش، دمای حداقل، دمای حداکثر و تبخیر و تعرق برای دوره‌های آتی شبه‌سازی شد و نتایج نشان داد که دما و تبخیر و تعرق در دوره‌های آتی افزایش و بارش کاهش خواهد یافت. با استفاده از پارامترهای اقلیمی عملکرد گندم با روش‌های جنگل تصادفی، شبکه عصبی و مدل گروهی در دوره پایه ارزیابی شد و نتایج نشان داد که مدل گروهی موجب کاهش خطا می‌شود. بنابراین از مدل گروهی برای شبه‌سازی عملکرد گندم در دوره‌های آتی استفاده شد و نتایج نشان داد که عملکرد گندم در دوره‌های آتی کاهش می‌یابد.

۵. پی‌نوشت‌ها

1. The Coupled Model Intercomparison Project
2. The Coupled Model Intercomparison Project Phase 6
3. Shared Socioeconomic Pathways
4. The Coupled Model Intercomparison Project Phase 5
5. eXtreme Gradient Boosting
6. General Circulation Model
7. The Intergovernmental Panel on Climate Change
8. Bias Correction and Spatial Disaggregation
9. Root Mean Squared Error
10. Mean Bias Error
11. Coefficient of determination

۶. تشکر و قدردانی

این مقاله از طرح پسادکتری دانشگاه بین‌المللی امام خمینی (ره) با شماره قرارداد ۲۵۹۱۴۴/۱/د استخراج گردیده است.

۷. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۸. منابع

- Din Pajouh, Y., & Allahvardipour, P. (2025). Monitoring and forecasting of evapotranspiration changes in the Moghan Plain according to the sixth IPCC report. *Environment and Water Engineering*, 11 (1), 47-56. (In Persian).
- Karimi, S. R., Nasrolahi, A., & Iranshahi, M. (2024). Investigating the effects of climate change on reference evapotranspiration based on the SSP scenarios. *Iranian Journal of Soil and Water Research*, 54(11), 1759-1777. (In Persian).
- Shahin Rukhsar, P., Alizadeh, A., Ansari, H., & Ghorbani, M. (2020). Study of the group uncertainty of atmospheric general circulation models in meteorological data simulation (Case study of Rasht synoptic station). *Irrigation and Drainage of Iran*, 13 (6), 1897-1909. (In Persian).
- Moradi, R., & Naghizadeh, M. (2023). Growth and Yield Response of Wheat (Mihan variety) to Future Climate Change in Kerman and Ardebil. *Journal Of Agroecology*, 15(1), 1-16. (In Persian).
- lotfi, M., Kamali, G. A., Meshkatee, A. H., & Varshavian, V. (2021). Evaluation of Yield Changes and Length of Dryland Wheat Phenological Stages under RCP Scenario Using DSSAT and AquaCrop Models in Western Iran. *Iranian Journal of Soil and Water Research*, 52(10), 2665-2677. (In Persian).
- Aini Nargeseh, H., Rahimi Moghadam, S., Azizi, K., Qarnjik, A., & Amiri, R. (2024). Adaptation of rainfed winter wheat to climate change in arid and cold regions using optimal planting date and supplementary irrigation. *Agricultural Sciences Research in Arid Regions*, 6 (4), 277-293. (In Persian).
- Borzo, F., Ramezani Edelali, H., & Kaviani, A. (2023). The effect of climate change under climate change conditions on winter wheat yield. *Iranian Irrigation and Drainage*, 17 (5), 995-979. (In Persian).
- Shiyokhi Soghanloo, S., Mousavi Bayegi, M., Torabi, B., & Raeni Sarjaz, M. (2021). Evaluation of the impact of climate change on the yield of irrigated wheat cultivar Mehregan under drought stress conditions (case study: Varamin). *Agricultural Meteorology*, 9 (2), 15-28. (In Persian).
- Iqbal, N., Shahzad, M. U., Sherif, E. S. M., Tariq, M. U., Rashid, J., Le, T. V., & Ghani, A. (2024). Analysis of wheat-yield prediction using machine learning models under climate change scenarios. *Sustainability*, 16(16), 6976.
- Mirshekari, S., Yaghoubi, F., & Hashemi, SA. (2025). Climate Change Impacts on Wheat Yields in Arid Regions of Iran: A Multimodel Approach for Adaptation Strategies. *Int. J. Plant Prod.*

- Eddamiri, S., Bouras, E.H., & Amazirh, A. (2024). Modeling the impact of climate change on wheat yield in Morocco based on stacked ensemble learning. *Model. Earth Syst. Environ.*, 10, 6413-6433.
- 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., & Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geosci. Model Dev.*, 9, 3461-3482.
- Meinshausen, M., Nicholls, Z. R. J., Lewis, J., Gidden, M. J., Vogel, E., Freund, M., Beyerle, U., Gessner, C., Nauels, A., Bauer, N., Canadell, J. G., Daniel, J. S., John, A., Krummel, P. B., Luderer, G., Meinshausen, N., Montzka, S. A., Rayner, P. J., Reimann, S., Smith, S. J., van den Berg, M., Velders, G. J. M., Vollmer, M. K., & Wang, R. H. J. (2020). The shared socio-economic pathway (SSP) greenhouse gas concentrations and their extensions to 2500. *Geosci. Model Dev.*, 13, 3571-3605.
- Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geosci. Model Dev.*, 9, 1937-1958.
- Thrasher, B., Depsky, N., Taylor, M. A., & Nemani, R. (2022). NASA-NEX-GDDP-CMIP6 Dataset. NASA Earth Exchange.
- Semenov, M.A., & Stratonovitch, P. (2010). Use of Multi-Model Ensembles from Global Climate Models for Assessment of Climate Change Impacts. *Climate Research*, 41, 1-14.
- Van Klompenburg, T., Kassahun, A., & Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Comput. Electron. Agric.*, 177, 105709.
- Bento, V. A., Ribeiro, A. F., Russo, A., Gouveia, C. M., Cardoso, R. M., & Soares, P. M. (2021). The impact of climate change in wheat and barley yields in the Iberian Peninsula. *Scientific reports*, 11(1), 15484.
- Ahmadi, M., Etedali, H. R., Salem, A., Al-Mukhtar, M., & Elbeltagi, A. (2024). Simulation of wheat water footprint using AquaCrop model under the climate change, case study in Qazvin plain. *Applied Water Science*, 14(12), 264.
- Karatayev, M., Clarke, M., Salnikov, V., Bekseitova, R., & Nizamova, M. (2022). Monitoring climate change, drought conditions and wheat production in Eurasia: The case study of Kazakhstan. *Heliyon*, 8(1).
- Yanagi, M. (2024). Climate change impacts on wheat production: Reviewing challenges and adaptation strategies. *Advances in Resources Research*, 4(1), 89-107.
- Fashoto, S.G., Mbunge, E., Ogunleye, G., & den Burg, J.V. (2021). Implementation of machine learning for predicting maize crop yields using multiple linear regression and backward elimination. *Precis. Agric.*, 6, 679-697.
- Pang, A., Chang, M.W., & Chen, Y. (2022). Evaluation of random forests (RF) for regional and local-scale wheat yield prediction in southeast Australia. *Sensors*, 22, 717.
- Sahbeni, G., Székely, B., Musyimi, P.K., Timár, G., & Sahajpal, R. (2023). Crop Yield Estimation Using Sentinel-3 SLSTR, Soil Data, and Topographic Features Combined with Machine Learning Modeling: A Case Study of Nepal. *AgriEngineering*, 5, 1766-1788.
- Tariq, A., Yan, J., Gagnon, A.S., Riaz Khan, M., & Mumtaz, F. (2023). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-Spat. Inf. Sci.*, 26, 302-320.
- Fei, S., Hassan, M.A., Xiao, Y., Su, X., Chen, Z., Cheng, Q., Duan, F., Chen, R., Ma, Y. (2023). UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat. *Precis. Agric.*, 24, 187-212. &
- Li, Q.C., Xu, S.W., Zhuang, J.Y., Liu, J.J., Yi, Z.H., & Zhang, Z.X. (2023). Ensemble learning prediction of soybean yields in China based on meteorological data. *J. Integr. Agric.*, 22, 1909-1927.
- Blair, T. A. (1919). A statistical study of weather factors affecting the yield of winter wheat in Ohio. *Monthly Weather Review*, 47(12), 841-847.
- Du, X., Gao, Z., Sun, X., Bian, D., Ren, J., Yan, P., & Cui, Y. (2022). Increasing temperature during early spring increases winter wheat grain yield by advancing phenology and mitigating leaf senescence. *Science of the Total Environment*, 812, 152557.
- Arunrat, N., Sreenonchai, S., Chaowiwat, W., & Wang, C. (2022). Climate change impact on major crop yield and water footprint under CMIP6 climate projections in repeated drought and flood areas in Thailand. *Science of the Total Environment*, 807, 150741.

- Crane-Droesch, A. (2018). Machine learning methods for crop yield prediction and climate change impact assessment in agriculture. *Environmental Research Letters*, 13(11), 114003.
- Ciscar, J. C., Fisher-Vanden, K., & Lobell, D. B. (2018). Synthesis and review: An inter-method comparison of climate change impacts on agriculture. *Environmental Research Letters*, 13(7), 070401.
- Hu, T., Zhang, X., Bohrer, G., Liu, Y., Zhou, Y., Martin, J., ... & Zhao, K. (2023). Crop yield prediction via explainable AI and interpretable machine learning: Dangers of black box models for evaluating climate change impacts on crop yield. *Agricultural and Forest Meteorology*, 336, 109458.
- Ray, D., Gerber, J., MacDonald, G., & West, P. (2015). Climate variation explains a third of global crop yield variability. *Nat. Commun.*, 6, 5989.
- Rezaei, E. E., Siebert, S., Manderscheid, R., Müller, J., Mahrookashani, A., Ehrenpfordt, B., et al. (2018). Quantifying the response of wheat yields to heat stress: the role of the experimental setup. *Field Crop Res.*, 217, 93-103.
- Chen, Y., Zhang, Z., & Tao, F. (2018). Impacts of climate change and climate extremes on major crops productivity in China at a global warming of 1.5 and 2.0°C. *Earth Syst. Dynam.*, 9, 543-562.
- Zheng, B., Chenu, K., Dreccer, M., & Chapman, S. (2012). Breeding for the future: what are the potential impacts of future frost and heat events on sowing and flowering time requirements for Australian bread wheat (*Triticum aestivum*) varieties. *Glob. Chang. Biol.*, 18, 2899-2914.
- Ruan, G., Schmidhalter, U., Yuan, F., Cammarano, D., Liu, X., Tian, Y., Zhu, Y., Cao, W., & Cao, Q. (2023). Exploring the transferability of wheat nitrogen status estimation with multisource data and Evolutionary Algorithm-Deep Learning (EA-DL) framework. *Eur. J. Agron.*, 143, 126727.
- Giraldo, P., Benavente, E., Manzano-Agugliaro, F., Gimenez, E. (2019). Worldwide research trends on wheat and barley: A bibliometric comparative analysis. *Agronomy*, 9, 352.
- Ashfaq, M., Khan, I., Alzahrani, A., Tariq, M.U., Khan, H., & Ghani, A. (2024). Accurate Wheat Yield Prediction Using Machine Learning and Climate-NDVI Data Fusion. *IEEE Access*, 12, 40947-40961.
- Sinwar, D., Dhaka, V.S., Sharma, M.K., & Rani, G. (2020). AI-based yield prediction and smart irrigation. In *Internet of Things and Analytics for Agriculture*; Springer: Singapore, 2, 155-180.
- Iqbal, N., Shahzad, M. U., Sherif, E. S. M., Tariq, M. U., Rashid, J., Le, T. V., & Ghani, A. (2024). Analysis of wheat-yield prediction using machine learning models under climate change scenarios. *Sustainability*, 16(16), 6976.
- Zhang, D., Liu, J., Li, D., Batchelor, W. D., Wu, D., Zhen, X., & Ju, H. (2023). Future climate change impacts on wheat grain yield and protein in the North China Region. *Science of the Total Environment*, 902, 166147.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.