

شبیه سازی عملکرد گندم تحت تأثیر تغییر اقلیم با استفاده از مدل گروهی شبکه عصبی و جنگل

تصادفی

چکیده

تغییرات اقلیمی، فراوانی و شدت رویدادهای شدید مانند خشکسالی، موج گرما و سیل را افزایش می‌دهد و چالش مهمی را برای کشاورزی و امنیت غذایی ایجاد می‌کند. درک تأثیر آینده آب و هوا بر عملکرد محصولات کشاورزی برای برنامه‌ریزی بلندمدت کشاورزی بسیار مهم است. با این حال، این حوزه به دلیل چالش‌های مختلف، از جمله محدودیت‌های داده‌ها، کمتر مورد بررسی قرار گرفته است. در این پژوهش، داده‌های بارش، دمای حداقل، دمای حداکثر و تبخیر و تعرق مدل‌های اقلیمی CNRM-CM6-1، ACCESS-CM2، GFDL-ESM4 و CanESM5 با داده سینوپتیک قزوین به صورت جداگانه و گروهی در دوره پایه ۱۹۸۶-۲۰۱۴ مقایسه شد. نتایج نشان داد که تبخیر و تعرق، دمای حداقل و حداکثر در مدل گروهی 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 آتی شبیه سازی 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 شبیه سازی عملکرد گندم در دوره‌های آتی استفاده شد و نتایج نشان داد که عملکرد گندم در دوره‌های آتی کاهش می‌یابد.

کلمات کلیدی: بارش، دما، سناریوهای گزارش ششم، مدل‌های گردش عمومی جو.

مقدمه

به دلیل رشد سریع جمعیت و محدودیت منابع زمینی، پایداری اکوسیستم‌های کشاورزی توجه بیشتری 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 آب و هوا، 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) شبیه‌سازی‌هایی از آب و هوای 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., ۲۰۱۸).

2022). مرحله ششم پروژه مقایسه متقابل مدل‌های اقلیمی (CMIP6²) مسیرهای اجتماعی-اقتصادی مشترک (SSP³) جدیدی را معرفی کرده است که فرضیات مرجع اجتماعی-اقتصادی متفاوتی را توصیف می‌کنند. مطالعات قبلی نشان داده است که مدل‌های CMIP6 نتایج قابل قبول‌تری نسبت به مدل‌های CMIP5⁴ 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 آگاهی‌بخشی به شیوه‌های کشاورزی و توسعه استراتژی‌هایی برای کاهش اثرات تغییرات اقلیمی بر تولید گندم مهم است.

پیش‌بینی‌های دقیق عملکرد گندم برای حفظ شیوه‌های کشاورزی و کاهش اثرات منفی تغییرات اقلیمی بسیار مهم است. برخلاف مطالعات قبلی که عمدتاً 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 اخیراً شاهد افزایش سریعی بوده است که عمدتاً 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 دائماً در حال تولید هستند. دهه‌های گذشته نیز شاهد پیشرفت‌های اساسی در تجزیه و تحلیل داده‌ها بوده است. مطالعات اولیه عمدتاً 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، XGBoost⁵ و یادگیری عمیق در حال تغییر است (Crane-Droesch, 2018; Ciscar et al., 2018; Hu et al., 2023). مدل‌های یادگیری ماشینی قادر به حل روابط پیچیده و غیرخطی بین محصولات کشاورزی و اقلیم هستند.

الگوریتم‌های یادگیری ماشین اغلب برای حدس زدن میزان تولید محصولات غذایی استفاده می‌شوند. آنها می‌توانند با داده‌هایی که ابعاد زیادی دارند کار کنند، روابطی را پیدا کنند که مستقیم نیستند و روندهای پیچیده را ببینند (Van Klompenburg et al., 2020). الگوریتم‌های یادگیری ماشین با آموزش آنها از طریق آموزش مشاهده‌ای مکانی-زمانی روی مجموعه داده‌های بسیار بزرگ،

پیوندهایی بین عوامل وابسته و مستقل پیدا می‌کنند. تکنیک‌های یادگیری ماشین 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 مشکلات این مدل‌ها است که باعث می‌شود حتی زمانی که در برخورد با مشکلات مربوط به آب و هوا در کشاورزی عملکرد خوبی دارند، کمتر مفید باشند. 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 فراماشین، 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 Nargeseh et al., 2024; Moradi and Naghizadeh., 2023) در ارتباط با تغییر اقلیم و عملکرد گندم انجام شده است. در این پژوهش به بررسی اثر تغییر اقلیم بر عملکرد گندم در قزوین با استفاده از ترکیب مدل‌های گردش عمومی CNRM-CM6-1، ACCESS-CM2 و CanESM5 و سناریوهای SSP2_4.5 و SSP5_8.5 در دوره‌های پایه و آبی و بکارگیری تکنیک‌های هوش مصنوعی پرداخته شده است.

مواد و روش‌ها

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 ۴۵۰۰۰۰ هکتار از نظر محصولات کشاورزی در بین دشت‌های ایران اهمیت دارد. این دشت در فلات مرکزی ایران واقع شده و دارای آب و هوای نیمه خشک، 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. دمای هوای سالانه از حداکثر ۴۲ درجه سانتیگراد تا حداقل ۲۴- درجه سانتیگراد و میانگین بارش سالانه در سطح استان از ۲۱۰ میلیمتر تا بیش از ۵۵۰ میلیمتر متغیر است. با توجه به اینکه گندم یکی از محصولات مهم دشت قزوین بشمار می‌رود این محصول برای ارزیابی انتخاب شد.




Figure.1. The location of the study area

مدل‌های گردش عمومی جو

پروژه مقایسه مدل جفت شده (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 شبیه‌سازی دقیق‌تر در استراتوسفر می‌شود. مدل‌های گردش عمومی جو (GCM⁶) که بر اساس 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 فرآیندهای میکروفیزیکی ابر، بهبود یافته‌اند. بنابراین، گروه GCM گزارش ششم برای پیش‌بینی آب و هوا نسبت به گروه‌های قبلی CMIP قابل اعتمادتر است. سناریو 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 نشان دهنده 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 به روش هارگریوز سامانی محاسبه شد. مجموعه داده‌ی GDDP-CMIP6 از خروجی مدل‌های گردش عمومی پروژه‌ی CMIP6 که در راستای گزارش ششم⁷ IPCC تهیه شده‌اند (Eyring et al., 2016) به دست 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 آماری⁸ BCSD به صورت 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 CNRM-CM6-1، ACCESS-CM2، GFDL-ESM4 و CanESM5 با وضوح مکانی ۰/۲۵ درجه و تحت دو سناریو SSP2_4.5 و SSP5_8.5 برای دوره پایه ۲۰۱۴-۱۹۸۶ و دوره‌های آتی ۲۰۲۵-۲۰۲۶، ۲۰۷۵-۲۰۵۰ و ۲۱۰۰-۲۰۷۵ استفاده شده است.

شبکه عصبی

شبکه‌های عصبی مصنوعی (ANNs) ابزارهای قدرتمندی در یادگیری ماشین هستند که از ساختار مغز انسان الگوبرداری شده‌اند. می‌توان از شبکه‌های عصبی مصنوعی برای تشخیص الگوهای پیچیده، یادگیری از مجموعه داده‌های در حال تغییر و پیش‌بینی‌های مداوم در زمان واقعی استفاده کرد. شبکه‌های عصبی مدل‌های ریاضی هستند که از الگوریتم‌های پیچیده برای تعیین قدرت هر "نورون" و قدرت ارتباط آن با نورون‌های دیگر استفاده می‌کنند. یک شبکه عصبی از خروجی‌های پیش‌بینی شده و واقعی برای بهبود عملکرد خود استفاده می‌کند. که به این فرآیند "آموزش" می‌گویند. معمولاً یک شبکه عصبی مصنوعی دارای یک لایه ورودی، یک لایه خروجی و همچنین لایه‌های پنهان است. لایه ورودی داده‌هایی را از دنیای بیرون دریافت می‌کند که شبکه عصبی باید آن‌ها را تجزیه و تحلیل کند یا درباره آن بیاموزد. سپس، این داده‌ها از یک یا چند لایه پنهان عبور می‌کنند که ورودی را به داده‌هایی تبدیل می‌کنند که برای لایه خروجی ارزشمند هستند. در نهایت، لایه خروجی را در قالب پاسخ شبکه‌های عصبی مصنوعی به داده‌های ورودی ارائه می‌دهد.

جنگل تصادفی

الگوریتم جنگل تصادفی یک تکنیک قدرتمند یادگیری درختی در یادگیری ماشین که به طور گسترده برای طبقه‌بندی و رگرسیون استفاده می‌شوند. جنگل تصادفی، از درخت‌های تصمیم‌گیری زیادی برای پیش‌بینی استفاده می‌کند. جنگل تصادفی با استفاده از نمونه‌های تصادفی از داده‌ها، چندین درخت تصمیم‌گیری می‌سازد. هر درخت بر روی زیرمجموعه متفاوتی از داده‌ها آموزش داده می‌شود که هر درخت را منحصر به فرد می‌کند. هنگام ایجاد هر درخت، الگوریتم به طور تصادفی زیرمجموعه‌ای از ویژگی‌ها یا متغیرها را برای تقسیم داده‌ها انتخاب می‌کند، نه اینکه از همه ویژگی‌های موجود به طور همزمان استفاده کند. این امر به تنوع

درختان می‌افزاید. هر درخت تصمیم‌گیری در جنگل، پیش‌بینی را بر اساس داده‌هایی که بر روی آنها آموزش دیده است، انجام می‌دهد. هنگام انجام پیش‌بینی نهایی، جنگل تصادفی نتایج همه درختان را ترکیب می‌کند. برای طبقه‌بندی، پیش‌بینی نهایی با رأی اکثریت تعیین می‌شود. این بدان معناست که دسته‌بندی پیش‌بینی شده توسط اکثر درختان، پیش‌بینی نهایی است. برای رگرسیون، پیش‌بینی نهایی میانگین پیش‌بینی‌های همه درختان است. تصادفی بودن در نمونه‌های داده و انتخاب ویژگی به جلوگیری از بیش‌برازش مدل کمک می‌کند و پیش‌بینی‌ها را دقیق‌تر و قابل اعتمادتر می‌کند.

در این مطالعه از مدل گروهی شبکه عصبی مصنوعی و جنگل تصادفی برای شبیه‌سازی عملکرد گندم استفاده شده است. ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد برای مرحله آزمون به صورت تصادفی در نظر گرفته شد.

آماره‌های ارزیابی

برای ارزیابی نتایج به دست آمده از آماره‌های ارزیابی جذر میانگین مربعات خطا ($RMSE^9$)، خطای اریبی (MBE^{10}) و ضریب تبیین (R^2)¹¹ استفاده شد.

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

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (2)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)^2 (P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad (3)$$

در روابط یادشده O_i : مقادیر داده‌های اندازه‌گیری شده، P_i : مقادیر داده‌های شبیه‌سازی شده، $\bar{O}_i$: میانگین مقادیر داده‌های اندازه‌گیری شده، $\bar{P}_i$: میانگین مقادیر داده‌های شبیه‌سازی شده و n : تعداد داده‌ها است. $RMSE$ میانگین مقادیر انحراف شبیه‌سازی شده را از مقادیر اندازه‌گیری شده نشان می‌دهد. هرچه مقدار $RMSE$ کوچکتر باشد به معنی مطلوب بودن مدل می‌باشد. شاخص MBE بیانگر میزان اریبی روش است، در یک تخمین نسبتاً دقیق بایستی نزدیک به صفر باشد. ضریب همبستگی بین ۱- و ۱ 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، در حالی که اگر همبستگی پایین (نزدیک به صفر) باشد، مدل برازش خوبی از داده‌ها ارائه نداده است.

نتایج و بحث



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

داده‌های دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های اقلیمی ACCESS-CM2, GFDL-ESM4, CNRM-CM6-1 و CanESM5 با در دوره پایه ۱۹۸۶-۲۰۱۴ با داده سینوپتیک قزوین به صورت جداگانه و گروهی مقایسه شد. در این مطالعه، به منظور بهبود برآورد بارش حاصل از چهار مدل گردش عمومی جو (GCM)، از روش میانگین‌گیری وزن‌دار خطی مدل‌ها با هدف کمینه‌سازی ریشه میانگین مربعات خطا (RMSE) نسبت به داده‌های مشاهداتی استفاده شد. در این روش، وزن‌های مربوط به هر مدل اقلیمی به گونه‌ای تنظیم شدند که ترکیب خطی حاصل، کمترین خطا را نسبت به داده‌های مشاهداتی داشته باشد.

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

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

نتایج (جدول ۱) نشان می‌دهد که دمای حداقل و حداکثر در مدل گروهی با مقادیر ضریب تبیین ۰/۹۵ در سطح معنی داری ۰/۹۵ (P-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 با اجرای گروهی ۱۵ مدل AOGCM در انگلستان نشان دهنده کاهش معنی دار عدم قطعیت پیش بینی‌ها 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 آتی افزایش می‌یابد به طوری که میزان تغییرات دمای حداکثر نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۵۰ برای سناریوهای SSP2_4.5 و SSP5_8.5 به ترتیب ۱/۹ و ۲/۴۹ درجه سانتیگراد، در دوره ۲۰۵۰-۲۰۷۵ 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 آتی 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 آتی 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 آتی 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 خرم آباد 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 آتی 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 انتهای قرن 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) تا پایان قرن می‌رسد که با نتایج مطالعه حاضر همخوانی دارد.

شبیه سازی عملکرد گندم

عملکرد گندم با استفاده از پارامترهای دمای حداقل، دمای حداکثر، بارش و تبخیر و تعرق (دوره کشت) شبیه سازی شد. برای این منظور از روش های جنگل تصادفی، شبکه عصبی و روش گروهی (ترکیب جنگل تصادفی و شبکه عصبی) استفاده شد. نتایج ارزیابی روش ها 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

نتایج جدول ۳ نشان می دهد که روش شبکه عصبی و جنگل تصادفی در مرحله آموزش با ضریب تبیین بیش از ۰/۹ و مقادیر اندک RMSE دقت بالایی در شبیه سازی 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 روش های جنگل تصادفی و شبکه عصبی داشت و بنابراین این روش برای شبیه سازی گندم در دوره های آتی انتخاب شد. در مطالعه ای Iqbal et al. (2024) به بررسی پیش بینی عملکرد گندم با استفاده از مدل های 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 فوق العاده ای در شبیه سازی عملکرد نشان داد و از روش های رگرسیون جنگل تصادفی، شبکه عصبی و درخت تقویتی بهتر بود که با نتایج مطالعه حاضر همخوانی دارد.

پس از کالیبره کردن مدل گروهی با داده های دوره پایه، عملکرد گندم برای دوره های آتی تحت سناریوهای SSP2_4.5 و SSP5_8.5 شبیه سازی 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، ۲۰۵۰-۲۰۷۵ و ۲۰۷۶-۲۱۰۰ به ترتیب برابر ۲/۱۵-، ۴/۶۲- و ۷/۲۲- درصد، در سناریو SSP2_4.5 و در سناریو SSP5_8.5 دوره‌های ۲۰۲۶-۲۰۵۰، ۲۰۵۰-۲۰۷۵ و ۲۰۷۶-۲۱۰۰ به ترتیب برابر ۲/۸۸-، ۷/۹۴- و ۱۰/۸۱- درصد بود. در مطالعه‌ای، Mirshekari et al. (2025) تاثیر 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 پایان قرن، به ویژه در سناریوهای با انتشار بالا، کاهش یابد. در مقابل، 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 به طور 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) به طور متوسط ۱۰ درصد کاهش یابد، در حالی که 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 بر اساس آزمون Mann-Kendall ($\tau = -0.597$, $p < 0.0001$) برای سناریو SSP5-8.5 و Mann-Kendall ($\tau = -0.4948$, $p < 0.0001$) برای سناریو 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.

نتیجه گیری

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 ۱۹۸۶-۲۰۱۴ 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 معنی داری 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 برای دوره‌های آتی شبیه‌سازی 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 شبیه سازی عملکرد گندم در دوره‌های آبی استفاده شد و نتایج نشان داد که عملکرد گندم در دوره‌های آبی کاهش می‌یابد.

تقدیر و تشکر

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

پی نوشت

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

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.

Karimi, S. R., nasrolahi, A. and 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.

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.

Moradi, R. and 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.

lotfi, M., Kamali, G. A., Meshkatee, A. H. and 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.

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.

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.

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.

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., and 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., and 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.

Tebaldi, C., Debeire, K., Eyring, V., Fischer, E., Fyfe, J., Friedlingstein, P., Knutti, R., Lowe, J., O'Neill, B., Sanderson, B., van Vuuren, D., Riahi, K., Meinshausen, M., Nicholls, Z., Tokarska, K. B., Hurtt, G., Kriegler, E., Lamarque, J.-F., Meehl, G., Moss, R., Bauer, S. E., Boucher, O., Brovkin, V., Byun, Y.-H., Dix, M., Gualdi, S., Guo, H., John, J. G., Kharin, S., Kim, Y., Koshiro, T., Ma, L., Olivie, D., Panickal, S., Qiao, F., Rong, X., Rosenbloom, N., Schupfner, M., Séférian, R., Sellar, A., Semmler, T., Shi, X., Song, Z., Steger, C., Stouffer, R., Swart, N., Tachiiri, K., Tang, Q., Tatebe, H., Voldoire, A., Volodin, E., Wyser, K., Xin, X., Yang, S., Yu, Y., and Ziehn, T. (2021). Climate model projections from the Scenario Model Intercomparison Project (ScenarioMIP) of CMIP6, *Earth Syst. Dynam.*, 12, 253–293.

Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., and 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., and Nemani, R. (2022). NASA-NEX-GDDP-CMIP6 Dataset. NASA Earth Exchange.

Semenov, M.A., and 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., and 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., and 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., and 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*, Volume 2, pp. 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.

Simulation of wheat yield under the influence of climate change using neural network and random forest ensemble models

Abstract

Climate change increases the frequency and intensity of extreme events such as droughts, heat waves, and floods, posing a significant challenge to agriculture and food security. Understanding the future impact of climate on crop yields is crucial for long-term agricultural planning. However, this area has been underexplored due to various challenges, including data limitations. 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 ensemble model 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. 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.

Keywords: General Circulation Models, Precipitation, Scenarios of the sixth report, Temperature.