

Assessing the Impact of Climate Change on Maize Yield Using Machine Learning Algorithms (Case Study: Qazvin Plain)

Mojgan Ahmadi¹, Hadi Ramezani Etedali^{2*}

¹Ph.D. Graduate, Department of Water Science and Engineering, Faculty of Agriculture, Imam Khomeini International University, Qazvin, Iran. <https://orcid.org/0000-0002-6284-9814>

²Associate Professor, Department of Water Science and Engineering, Faculty of Agriculture, Imam Khomeini International University, Qazvin, Iran. <https://orcid.org/0000-0002-4840-0201>

Introduction

Corn is a strategic crop in the Qazvin plain, playing a vital role in food security, farmers' income, and regional agricultural development. Its adaptability to diverse climatic conditions and a wide range of applications in human consumption, livestock feeding, and agro-industrial processing have consolidated its importance in the province. However, increasing climate variability has presented significant challenges for sustaining productivity, underscoring the need for reliable yield forecasting and effective adaptation strategies. This study evaluates the potential impacts of climate change on forage corn yield in Qazvin through an integrative framework that combines climate modeling with machine learning techniques. Unlike conventional approaches relying on a single general circulation model (GCM) or a single statistical algorithm, the proposed method employs multiple GCMs and an ensemble of machine learning algorithms to reduce uncertainties and improve predictive accuracy. Climate projections were merged through a weighted ensemble approach, while crop yield forecasts were generated using combined machine learning models, which enhanced the stability and reliability of results. The findings demonstrate that the integrative framework substantially outperforms single-model approaches in terms of accuracy and robustness. By addressing both climatic and methodological uncertainties, this research provides valuable insights into the potential effects of climate change on forage corn production in the Qazvin plain. Moreover, the study highlights the practical importance of ensemble-based approaches in supporting regional decision-making for sustainable agricultural management. Overall, the proposed methodology contributes to advancing crop yield prediction under changing climate conditions, with significant implications for food security and agricultural resilience at the regional scale.

Materials and Methods

In this study, observational data on corn yield and monthly climatic variables, including minimum and maximum temperature, precipitation, and reference evapotranspiration, were employed for the period 1986–2014. After data cleaning and normalization, the baseline dataset was randomly divided into training (70%) and testing (30%) subsets to prevent model bias and enhance generalizability.

For the Random Forest model, 145 decision trees were generated. The number of trees was selected to achieve a balance between predictive accuracy and computational efficiency. The Artificial Neural Network (ANN) model was designed with a single hidden layer containing 33 neurons. A linear activation function was applied to the neurons, and the maximum number of training iterations was set to 1000. Input variables were identical to those of the Random Forest model, and the ANN was trained using the `nnet` library in the R environment.

In the Support Vector Regression (SVR) model, a radial kernel was utilized. The penalty parameter (cost) was set to 6, and the ϵ -insensitive loss function was assigned a value of 0.5. The input variables included minimum and maximum temperature, precipitation, and reference evapotranspiration. Model training was carried out to minimize prediction error.

Following the training phase, model performance was evaluated using the testing dataset and standard statistical indicators. Finally, the outputs of the three models were combined to construct an ensemble framework, which provided the most accurate yield estimates based on the lowest Root Mean Square Error (RMSE).

Results and Discussion

The results indicate that both minimum and maximum temperatures are projected to increase in future periods compared to the baseline. Specifically, the change in minimum temperature during 2026–2050, relative to the baseline, is projected to be +2.63 °C under SSP2-4.5 and +2.88 °C under SSP5-8.5. Similarly, maximum temperature is expected to increase by +1.60 °C under SSP2-4.5 and +2.24 °C under SSP5-8.5 over the same period.

Precipitation, on the other hand, is projected to decline in the coming decades. The reduction during 2051–2075, relative to the baseline, is estimated at –38.18 mm/year under SSP2-4.5 and –23.14 mm/year under SSP5-8.5.

In contrast, reference evapotranspiration (ET₀) is projected to rise in future periods. The increase during 2076–2100, relative to the baseline, is estimated at +158.31 mm/year under SSP2-4.5 and +275.73 mm/year under SSP5-8.5.

These findings highlight a consistent warming trend accompanied by decreased precipitation and enhanced evapotranspiration in the Qazvin plain, which together may intensify water stress and increase the vulnerability of corn production under future climate scenarios.

The results indicate a declining trend in corn yield under both climate scenarios in future periods. The greatest reduction was observed under SSP5_8.5 during 2076–2100, with about a 20% decrease, while the smallest reduction occurred under SSP2_4.5 in the same period, with nearly a 5% decrease. These findings highlight the significant impact of climate change on corn production sustainability in the Qazvin plain.

Conclusion

The findings of this study demonstrated that the ensemble approach, integrating multiple climate models with machine learning algorithms, significantly improves the accuracy and robustness of corn yield predictions compared to single-model approaches. Future climate scenarios indicate a consistent increase in minimum and maximum temperatures, a decline in precipitation, and a consequent reduction in corn yield, trends that could exacerbate water stress and challenge the sustainability of agricultural production in the Qazvin plain.

Accordingly, the development and implementation of adaptive strategies are crucial for mitigating the potential impacts of climate change. Key measures include the sustainable management of water resources, the adoption of climate-resilient corn varieties, the application of advanced agricultural technologies, and the integration of predictive and early-warning systems into regional agricultural planning. Implementing these strategies can enhance the resilience of corn production, safeguard food security, and ensure the long-term sustainability of agriculture in the Qazvin plain.

Keywords: Climate change, Corn, Ensemble modeling, Machine Learning.

بررسی تأثیر تغییر اقلیم بر عملکرد ذرت علوفه‌ای با استفاده از الگوریتم‌های یادگیری ماشین در دشت قزوین

مژگان احمدی^۱، هادی رضوانی اعتدالی^{۲*}

۱- دانش‌آموخته دکتری، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

۲- استاد گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

چکیده

تغییر اقلیم یکی از مهم‌ترین چالش‌های تأثیرگذار بر تولیدات کشاورزی است و عملکرد ذرت به عنوان محصولی راهبردی در دشت قزوین نسبت به نوسانات اقلیمی حساسیت بالایی دارد. در این پژوهش اثر تغییرات اقلیمی بر عملکرد ذرت علوفه‌ای دشت قزوین تحت سناریوهای SSP2-4.5 و SSP5-8.5 در دوره‌های آینده ۲۰۷۵-۲۰۵۱، ۲۰۵۰-۲۰۲۶ بررسی گردید. به منظور کاهش عدم قطعیت‌های اقلیمی، خروجی چندین مدل گردش عمومی جو با استفاده از روش ترکیب وزنی خطی ادغام شده‌اند. در مرحله دوم، برای پیش‌بینی عملکرد ذرت، چندین الگوریتم یادگیری ماشین شامل شبکه عصبی، رگرسیون بردار پشتیبان و جنگل تصادفی به صورت ترکیبی (Ensemble) با میانگین وزنی پیش‌بینی‌ها به کار گرفته شده‌اند تا دقت و پایداری نتایج افزایش یابد. داده‌های اقلیمی شامل بارش (به عنوان شاخص تغییرات اقلیم منطقه و منابع آب)، دمای حداقل و حداکثر و تبخیر و تعرق از مدل‌های CNRM-CM6-1، HadGEM3، MIROC6، GFDL-ESM4 طی دوره ۲۰۱۴-۱۹۸۶ به صورت منفرد و گروهی با آمار ایستگاهی مقایسه شد. در بخش اقلیمی، نتایج نشان داد مدل گروهی با دقت بالای $R^2=0.95$ و RMSE پایین، عملکرد بهتری ارائه می‌دهد و خطای کلی را کاهش می‌دهد. پیش‌بینی‌ها بیانگر افزایش دماهای حداقل و حداکثر و تبخیر و تعرق و کاهش بارش در آینده است. شبیه‌سازی عملکرد ذرت با استفاده از مدل‌های یادگیری ماشین گروهی شامل شبکه عصبی، جنگل تصادفی و رگرسیون بردار پشتیبان کاهش عملکرد محصول را در هر دو سناریو نشان داد؛ به طوری که در دوره ۲۰۲۶-۲۰۵۰ به ترتیب حدود ۴/۷۲ و ۸/۷۲ درصد کاهش برآورد شد. نتایج بر ضرورت اتخاذ راهبردهای سازگاری و مدیریت منابع آبی برای کاهش اثرات منفی تغییر اقلیم بر تولید ذرت در دشت قزوین تأکید می‌کند.

کلمات کلیدی: تغییر اقلیم، ذرت، مدل گروهی، یادگیری ماشین.

مقدمه

امنیت غذایی یکی از اجزای اساسی توسعه پایدار است و ثابت شده است که طیف وسیعی از عوامل تهدیدکننده از جمله رشد جمعیت و تغییرات اقلیمی بر امنیت غذایی تأثیر می‌گذارند. افزایش دما و وقوع مکرر پدیده‌های حدی آب‌وهوایی، چالش‌های فزاینده‌ای را برای عملکرد آینده محصولات کشاورزی به دنبال خواهد داشت (Arunrat et al., 2020). از آنجایی که عوامل اقلیمی به طور قابل توجهی بر بهره‌وری کشاورزی تأثیر می‌گذارند، هرگونه تغییر در متغیرهای اقلیمی مانند دما و بارش ممکن است اهداف امنیت غذایی کشورها را به خطر بیندازد. روش‌های مختلف پیش‌بینی تأیید می‌کنند که تغییرات اقلیمی جهانی بر عملکرد غلات اصلی غذایی مانند ذرت، گندم و برنج تأثیر منفی خواهد گذاشت (Abbaszadeh et al., 2022; Gavahi et al., 2021). پرداختن به چالش امنیت غذایی جهانی مستلزم در نظر گرفتن در دسترس بودن و کیفیت منابع زمین و آب، و همچنین شرایط اجتماعی-اقتصادی و عناصر نهادی است (Fischer et al., 2021). انتظار می‌رود این شرایط با تغییرات اقلیمی و افزایش جمعیت، به ویژه در مناطق کم‌درآمد و از نظر جغرافیایی آسیب‌پذیر جهان مانند دلتاهای بزرگ آسیا بدتر شود (Schneider and Asch., 2020).

اگرچه بسیاری از تحقیقات روندی منفی برای عملکرد محصولات کشاورزی در آینده گزارش کرده‌اند، اما این نتایج تحت تأثیر عدم قطعیت‌های موجود در پیش‌بینی‌های اقلیمی قرار دارند (Asseng et al., 2015; Lesk et al., 2021; Ortiz-Bobea et al., 2021). هیئت بین دولتی تغییرات اقلیمی (IPCC¹) در جدیدترین گزارش خود، مجموعه‌ای جدید از سناریوها را که به‌عنوان مسیرهای اجتماعی-اقتصادی مشترک (SSPs²) شناخته می‌شوند، تشریح می‌کند (Arias et al., 2021). این سناریوها برای بررسی چگونگی تأثیر تصمیمات اجتماعی بر انتشار گازهای گلخانه‌ای و در نتیجه، چگونگی دستیابی به اهداف اقلیمی توافق‌نامه پاریس (مصوب سال ۲۰۱۵) مورد استفاده قرار می‌گیرند. ششمین گزارش ارزیابی IPCC تأیید می‌کند که انتظار می‌رود عملکرد محصولات کشاورزی در سراسر جهان در بیشتر زمین‌های کشت شده کاهش یابد. ذرت یکی از مهم‌ترین غلات زراعی است که نقش اساسی در تأمین غذا و منبع درآمد در کشورهای در حال توسعه دارد (Jägermeyr et al., 2021).

به‌منظور غلبه بر مشکلات مربوط به شرایط تغییرات اقلیم بر محصولات کشاورزی، راه‌حل‌های مختلفی در مطالعات مختلف ارائه شده است. تحقیقات انجام شده نشان داد که تغییرات آب و هوایی بر نیاز آبی محصول و همچنین عملکرد پیش‌بینی شده محصول در آینده بر اساس داده‌های پیش‌بینی آب و هوا تأثیر می‌گذارد (Javadinejad et al., 2021; Chakraborty et al., 2022). مطالعه انجام شده در مورد تأثیر وقایع آب و هوایی شدید، شامل امواج گرما، خشکسالی‌ها و رخدادهای حدی بارش و دما، بر مناطق مختلف اروپا نشان داد که قابل اعتمادترین پیش‌بینی‌کننده‌های آب و هوایی تولید کشاورزی، بارندگی و دمای هوا و آستانه‌های مربوطه آن‌ها هستند (Beillouin et al., 2018). بارش و دمای هوا رایج‌ترین پارامترهای اقلیمی مورد استفاده در بسیاری از مطالعات هستند. با این حال، مطالعات مختلف نشان داده‌اند که علاوه بر بارش و دما، پارامترهای مانند تابش خورشیدی، رطوبت هوا، رطوبت خاک و سرعت باد نیز می‌توانند در پیش‌بینی عملکرد محصولات مؤثر باشند و در مدل‌های متنوع یادگیری ماشین (ML³) به کار رفته‌اند. از جمله مدل‌ها می‌توان به شبکه عصبی مصنوعی (ANN⁴)، شبکه عصبی نیمه پارامتری (SPNN⁵) (Crane-Droesch., 2018)، شبکه عصبی کانولوشنی (CNN⁶) (Kang et al., 2020; Sun et al., 2019)، K-نزدیک‌ترین همسایه (KNN⁷) (Reddy et al., 2021)، شبکه عصبی بازگشتی (RNN⁸)، حافظه طولانی بلندمدت (LSTM⁹) (Wang et al., 2020) و جنگل تصادفی (RF¹⁰) (Kumar et al., 2020) اشاره کرد.

یادگیری ماشین امکان یادگیری مستقل را فراهم می‌کند و از طریق آموزش تکراری، از طریق تجربه بهبود می‌یابد (Pandith et al., 2020). این روش در حوزه کشاورزی برای افزایش کیفیت و بهره‌وری محصولات کشاورزی به کار گرفته شده است. ثابت شده است که یادگیری ماشین عملکرد قدرتمندی در داده‌کاوی و تجزیه و تحلیل‌های کشاورزی، مانند طبقه‌بندی انواع محصولات و پیش‌بینی عملکرد دارد (Witten et al., 2005; Cai et al., 2019; Han et al., 2020). عملکرد محصول را می‌توان با استفاده از مجموعه‌ای متنوع از داده‌ها پیش‌بینی کرد؛ از جمله پارامترهای اقلیمی، ویژگی‌های خاک و عملکرد گذشته محصول (Priya et al., 2018)، و همچنین

¹ The Intergovernmental Panel on Climate Change

² Shared Socioeconomic Pathways

³ Machine Learning

⁴ Artificial Neural Network

⁵ Semi-Parametric Neural Network

⁶ Convolutional Neural Networks

⁷ K-Nearest neighbor

⁸ Recurrent Neural Network

⁹ Long short-term memory

¹⁰ Random Forest

داده‌های ماهواره‌ای شامل اطلاعات نوری، فلورسانس کلروفیل القا شده توسط خورشید و حرارتی (Zhang et al., 2019) و حتی شاخص‌هایی نظیر غلظت نیتрат در زهاب (Shahhosseini et al., 2019). در مطالعه‌ای مدلی برای ادغام داده‌های میدانی، داده‌های سنجش از دور و داده‌های هواشناسی با استفاده از چهار روش یادگیری ماشین برای پیش‌بینی تولید جو در ایران ایجاد کردند و دریافتند که الگوریتم رگرسیون فرآیند گاوسی بهترین نتایج را دارد (Sharifi et al., 2021). با این حال، موپانگوا و همکاران (Mupangwa et al., 2020) در مطالعه‌ای نشان دادند که عملکرد الگوریتم‌های مختلف یادگیری ماشین در پیش‌بینی عملکرد ذرت تحت کشاورزی حفاظتی در شرق و جنوب آفریقا متفاوت است؛ به‌طوری که الگوریتم تحلیل تفکیک خطی از دقت بالاتری برخوردار بوده و ماشین بردار پشتیبان عملکرد ضعیف‌تری نسبت به سایر الگوریتم‌ها داشته است. برخی از محققان در سال‌های اخیر رویکردهای مختلف یادگیری ماشین را برای پیش‌بینی عملکرد محصول با استفاده از متغیرهای اقلیمی پیاده‌سازی کرده‌اند. ویناداری و همکاران (et al., 2014) نوعی تکنیک درخت تصمیم‌گیری را برای یافتن پارامتر غالب آب و هوایی برای عملکرد محصول به‌کار بردند و دقت مطلوب پیش‌بینی‌ها، قدرت بالقوه الگوریتم را در پیش‌بینی عملکرد محصول نشان داد. در سال ۲۰۱۸، شبکه عصبی عمیق برای پیش‌بینی عملکرد محصول بر اساس داده‌های اقلیمی مورد استفاده قرار گرفت و نتایج نشان داد که تغییرات آب و هوایی تأثیرات منفی قابل توجهی بر عملکرد ذرت دارد (Crane-Droesch., 2018). هافمن و همکاران (Hoffman et al., 2018) رابطه بین عملکرد محصول و داده‌های اقلیمی سازگار با مقیاس را برای دوره ۱۹۶۲-۲۰۱۴ با استفاده از جنگل تصادفی برای کشورهای جنوب صحرای آفریقا بررسی کردند. وگل و همکاران (Vogel et al., 2019) با استفاده از داده‌های عملکرد منطقه‌ای و اعمال یک الگوریتم یادگیری ماشین، تأثیرات شرایط آب و هوایی نامساعد بر ناهنجاری‌های عملکرد ذرت، سویا، برنج و گندم بهاره را در مقیاس جهانی بررسی کرد. چمورا و همکاران (Chemura et al., 2020) از تقویت گرادیان شدید، یک رویکرد یادگیری ماشین برای مدل‌سازی مناسب بودن آب و هوای فعلی برای ذرت، سورگوم، کاساوا و بادام زمینی در غنا با استفاده از داده‌های عملکرد و متغیرهای مهم زراعی استفاده کردند. فن و همکاران (Fan et al., 2020) با استفاده از یک شاخص Z تجمیعی که از بارش به عنوان ورودی در جنگل تصادفی برای پیش‌بینی عملکرد برنج و ذرت در استان سیچوان چین استفاده می‌کند، ابزاری جایگزین برای کاربران سطح استان ارائه دادند. مطالعات متعددی در زمینه تغییر اقلیم (Eslami Senoukesh et al., 2024; Ramezani Etedali and Koochi., 2025; Datorani et al., 2025) انجام شده است.

با وجود انجام مطالعات متعددی در زمینه پیش‌بینی عملکرد محصولات کشاورزی با استفاده از مدل‌های یادگیری ماشین در ایران، اغلب این مطالعات تنها به یک یا چند مدل اقلیمی به‌صورت جداگانه یا یک الگوریتم پیش‌بینی محدود شده‌اند و از ترکیب (ensemble) مدل‌های CMIP6 برای ذرت در دشت قزوین استفاده نشده است. علاوه بر این، اطلاعات محلی در خصوص تاریخ کاشت و برداشت، سطح زیرکشت و عملکرد ذرت در این منطقه به‌طور محدود گزارش شده است. بنابراین، مطالعه حاضر با به‌کارگیری رویکرد تلفیقی مدل‌های CMIP6 و الگوریتم‌های یادگیری ماشین گروهی، نه تنها دقت پیش‌بینی عملکرد ذرت را افزایش می‌دهد، بلکه شکاف علمی موجود در پژوهش‌های اقلیمی و کشاورزی منطقه‌ای ایران را نیز پر می‌کند. انتخاب دشت قزوین به عنوان منطقه مطالعه به دلیل نقش مهم ذرت در تأمین امنیت غذایی و اقتصادی استان و سهم قابل توجه آن در تولید ملی انجام شده است (Ministry of Agriculture Jihad of Iran, 2024).

ذرت یکی از مهم‌ترین محصولات زراعی دشت قزوین به‌شمار می‌رود و نقش بسزایی در تأمین امنیت غذایی و اقتصادی منطقه دارد. بر اساس آمار رسمی وزارت کشاورزی، سطح زیرکشت ذرت علوفه‌ای در استان قزوین در سال زراعی ۱۴۰۲-۱۴۰۱، ۲۲۳۲۳ هکتار


و عملکرد ذرت ۴/۸ تن در هکتار بوده است (Ministry of Agriculture Jihad of Iran, 2024). این محصول به دلیل سازگاری با شرایط اقلیمی متنوع، بازدهی نسبتاً بالا و کاربردهای گسترده در خوراک انسانی، دام و صنایع تبدیلی، جایگاه ویژه‌ای در کشاورزی استان یافته است. توجه به مدیریت بهینه منابع آبی و پیش‌بینی دقیق عملکرد ذرت، برای حفظ بهره‌وری و کاهش ریسک‌های اقلیمی در این دشت اهمیت ویژه‌ای دارد. هدف این پژوهش ارزیابی اثرات تغییر اقلیم بر عملکرد ذرت در دشت قزوین تحت سناریوهای SSP2-4.5 و SSP5-8.5 در دوره‌های پایه و آتی با استفاده از ترکیب چندین مدل گردش عمومی جو 1-CM6-CNRM، GFDL-ESM4، MIROC6 و HadGEM3 و به‌کارگیری روش‌های یادگیری ماشین است.

نوآوری اصلی این پژوهش در استفاده از یک رویکرد تلفیقی دو مرحله‌ای برای کاهش عدم قطعیت و افزایش دقت پیش‌بینی‌ها است. در مرحله نخست، به‌منظور کاهش عدم قطعیت‌های اقلیمی، خروجی چندین مدل گردش عمومی جو با استفاده از روش ترکیب وزنی خطی ادغام شده‌اند. در مرحله دوم، برای پیش‌بینی عملکرد ذرت، چندین الگوریتم یادگیری ماشین شامل شبکه عصبی، رگرسیون بردار پشتیبان و جنگل تصادفی به‌صورت ترکیبی (Ensemble) با میانگین وزنی پیش‌بینی‌ها به کار گرفته شده‌اند تا دقت و پایداری نتایج افزایش یابد. بدین ترتیب، این مطالعه با تلفیق همزمان مدل‌های اقلیمی چندگانه و الگوریتم‌های یادگیری ماشین گروهی، نسبت به پژوهش‌های پیشین که عمدتاً بر یک مدل اقلیمی یا یک روش آماری یا یادگیری ماشین تکیه داشته‌اند، چارچوبی دقیق‌تر و کاربردی‌تر برای ارزیابی اثرات تغییر اقلیم بر عملکرد محصول در مقیاس منطقه‌ای دشت قزوین ارائه می‌دهد.

مواد و روش‌ها

منطقه مورد مطالعه

استان قزوین در شمال غربی ایران واقع شده است (شکل ۱). کشاورزی نقش مهمی در اقتصاد استان قزوین دارد. دشت قزوین با مساحت تقریبی ۴۵۰ هزار هکتار، جایگاهی برجسته در میان دشت‌های کشور از نظر تولید محصولات کشاورزی دارد. این دشت در فلات مرکزی ایران واقع شده و دارای آب و هوای نیمه‌خشک، تابستان‌های گرم و زمستان‌های نسبتاً سرد است. در دشت قزوین یک ایستگاه هواشناسی سینوپتیک با آمار بلندمدت (ایستگاه قزوین) فعال است که داده‌های ماهانه آن در این پژوهش مورد استفاده قرار گرفت. این ایستگاه در طول جغرافیایی ۵۰/۰۳ درجه شرقی و عرض جغرافیایی ۳۶/۱۵ درجه شمالی واقع شده و ارتفاع آن ۱۲۷۹/۲ متر از سطح دریا است. میانگین سالانه دمای حداکثر و حداقل در دوره پایه ۲۰۱۴-۱۹۸۶ به ترتیب حدود ۱۷ و ۵ درجه سانتیگراد و میانگین بارش سالانه برابر با ۲۴۸ میلی‌متر گزارش شده است. با توجه به اینکه ذرت علوفه‌ای یکی از محصولات اصلی و پرکشت دشت قزوین است، این محصول به‌عنوان گونه هدف انتخاب شد. همچنین، متوسط تاریخ کاشت و برداشت ذرت در منطقه به ترتیب اوایل خرداد و اواخر شهریور ماه است (Qazvin Provincial Agricultural Jihad Organization, 2023). با توجه به ناچیز بودن بارش در دوره رشد ذرت (خرداد تا شهریور)، نقش بارش در این مطالعه عمدتاً غیرمستقیم و در مقیاس اقلیمی منطقه در نظر گرفته شده است.



شکل ۱. موقعیت منطقه مورد مطالعه
Fig 1. The location of the study area

مدل‌های گردش عمومی جو

پروژه مقایسه مدل جفت شده (CMIP¹) که در سال ۱۹۹۵ آغاز شد، اکنون در مرحله ششم خود قرار دارد. از جمله مزایای CMIP² نسبت به مدل CMIP³ افزایش تعداد لایه‌های عمودی است که باعث شبیه‌سازی دقیق‌تر در استراتوسفر می‌شود. مدل‌های گردش عمومی جو (GCM⁴) که تحت ششمین گزارش ارزیابی هیئت بین الدول تغییر اقلیم (CMIP6) توسعه یافته‌اند، نسخه‌های بهبود یافته از CMIP 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 رشد اقتصادی سریع با وابستگی شدید به سوخت‌های فسیلی را نشان می‌دهد که منجر به بالاترین سطح انتشار گازهای گلخانه‌ای و بیشترین افزایش دما و تغییرات در الگوهای بارش می‌شود.

¹ The Coupled Model Intercomparison Project

² The Coupled Model Intercomparison Project Phase 6

³ The Coupled Model Intercomparison Project Phase 5

⁴ General Circulation Model

در این مطالعه، برای بررسی تغییرات اقلیمی آینده ۲۰۷۶-۲۱۰۰، ۲۰۵۱-۲۰۷۵ و ۲۰۲۶-۲۰۵۰ از داده‌های روزانه دمای حداقل، دمای حداکثر، تبخیر و تعرق گیاه مرجع و بارش مدل‌های گردش عمومی جو (GCM) استفاده شد. تبخیر و تعرق مرجع به روش هارگریوز سامانی محاسبه شد (Hargreaves and Samani, 1985).

$$ET_0 = R_a \times 0.408 \times 0.0023 \times (T_{mean} + 17.8) \times (T_{max} - T_{min})^{0.5} \quad (1)$$

که در آن ET_0 تبخیر و تعرق مرجع (mm day^{-1})، R_a تابش فرازمینی ($\text{MJ m}^{-2} \text{d}^{-1}$)، T_{mean} ، T_{max} و T_{min} به ترتیب میانگین، حداکثر و حداقل دمای روزانه ($^{\circ}\text{C}$)، 0.408 ضریب تبدیل $\text{MJ m}^{-2} \text{d}^{-1}$ به mm day^{-1} می‌باشد. مجموعه داده GDDP-CMIP6 از خروجی مدل‌های گردش عمومی پروژه CMIP6 تهیه شده است که در راستای گزارش ششم هیئت بین‌الدولی تغییر اقلیم (IPCC) توسعه یافته‌اند (Eyring et al., 2016). این مجموعه داده سناریوهای انتشار گازهای گلخانه‌ای مبتنی بر مسیرهای اجتماعی-اقتصادی مشترک (SSPs)، شامل SSP2-4.5 و SSP5-8.5 را پوشش می‌دهد (O'Neill et al., 2016; Meinshausen et al., 2020). خروجی مدل‌ها با استفاده از روش آماری BCSD به صورت روزانه ریزمقیاس‌سازی و تصحیح اریبی شده‌اند (Thrasher et al., 2022) و از طریق پلتفرم گوگل ارث انجین (GEE¹) در دسترس قرار دارند. این داده‌ها با وضوح مکانی 0.25° درجه و تفکیک زمانی روزانه، تحت سناریوهای مختلف اقلیمی ارائه شده‌اند. در این مطالعه، داده‌های روزانه دمای حداقل، دمای حداکثر و بارش حاصل از مدل‌های گردش عمومی CMIP6-1، GFDL-ESM4، MIROC6 و HadGEM3 با وضوح مکانی 0.25° درجه و تحت دو سناریوی SSP2-4.5 و SSP5-8.5، برای دوره پایه و دوره‌های آتی ۲۰۲۶-۲۰۵۰، ۲۰۵۱-۲۰۷۵ و ۲۰۷۶-۲۱۰۰ مورد استفاده قرار گرفتند. در این پژوهش، چهار مدل گردش عمومی جو مذکور از مجموعه CMIP6 انتخاب شدند. معیار انتخاب این مدل‌ها شامل دسترسی به خروجی سناریوهای SSP2-4.5 و SSP5-8.5، ارائه متغیرهای اقلیمی مورد نیاز مطالعه با تفکیک زمانی مناسب، و عملکرد قابل قبول در شبیه‌سازی دما و بارش در مناطق نیمه خشک و خاورمیانه بر اساس مطالعات پیشین بوده است. علاوه بر این، این مدل‌ها به طور گسترده در مطالعات تغییر اقلیم مرتبط با کشاورزی مورد استفاده قرار گرفته‌اند و از نظر ساختار فیزیکی و پارامترسازی تفاوت‌هایی با یکدیگر دارند. استفاده همزمان از چندین مدل گردش عمومی جو با ویژگی‌های ساختاری متفاوت امکان کاهش عدم قطعیت‌های ناشی از اتکا به یک مدل منفرد را فراهم کرده و موجب افزایش قابلیت اعتماد برآوردهای اقلیمی در مقیاس منطقه‌ای دشت قزوین می‌شود. دوره ۲۰۱۴-۱۹۸۶ به عنوان دوره پایه اقلیمی انتخاب شد که با دوره تاریخی مدل‌های CMIP6 هم‌زمان بوده و مبنای ارزیابی عملکرد مدل‌ها و مقایسه با سناریوهای آینده قرار گرفت. به منظور انطباق داده‌های اقلیمی با دوره فیزیولوژیکی گیاه، تمامی متغیرها صرفاً در دوره رشد ذرت علوفه‌ای (خرداد تا شهریور) استخراج و تجمیع شدند. به منظور تمرکز بر اثر تغییرات اقلیمی، تنها متغیرهای اقلیمی غالب در دوره رشد ذرت علوفه‌ای به عنوان ورودی مدل‌ها استفاده شد و سایر عوامل خاکی و مدیریتی به صورت ثابت در نظر گرفته شدند.

شبکه عصبی

شبکه‌های عصبی مصنوعی (ANNs) مدل‌های محاسباتی الهام گرفته از مغز انسان هستند که از واحدهای پردازشی ساده به نام نورون مصنوعی تشکیل می‌شوند. این شبکه‌ها معمولاً دارای یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی هستند که با تنظیم

¹ Google Earth Engine

وزن ارتباط بین نوروها از طریق فرآیند آموزش قادر به یادگیری الگوهای پیچیده می‌شوند (Haykin, 2009). شبکه‌های عصبی می‌توانند به عنوان تقریب‌زننده‌های توابع عمل کرده و در حوزه‌هایی مانند پردازش تصویر، گفتار و داده‌های زمان‌واقعی کاربردهای فراوانی داشته باشند (Goodfellow, Bengio, & Courville, 2016). در یک مرور جامع، نشان داده شده است که یادگیری عمیق و شبکه‌های عصبی مدرن توانایی بالایی در شناسایی الگوها و پیش‌بینی دارند (Schmidhuber, 2015). به طور کلی، شبکه عصبی مصنوعی ابزاری قدرتمند در یادگیری ماشین است که همچنان در حال گسترش و تکامل می‌باشد.

رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان (SVR^1) یکی از الگوریتم‌های پرکاربرد یادگیری ماشین است که بر پایه نظریه ماشین بردار پشتیبان بنا شده است. هدف اصلی SVR یافتن یک تابع است که بتواند داده‌ها را با خطایی کمتر از یک آستانه مشخص تقریب بزند (Smola & Schölkopf, 2004). برخلاف رگرسیون خطی سنتی که سعی در کمینه‌سازی مجموع خطاها دارد، رگرسیون بردار پشتیبان تنها به داده‌هایی توجه می‌کند که در بیرون از یک ناحیه خطای مجاز (ϵ -insensitive tube) قرار دارند و این ویژگی باعث افزایش مقاومت آن در برابر داده‌های پرت می‌شود (Vapnik, 1995). این روش در بسیاری از کاربردها مانند پیش‌بینی سری‌های زمانی، پردازش سیگنال و مسائل مالی عملکرد بسیار موفقی نشان داده است (Drucker et al., 1996).

جنگل تصادفی

جنگل تصادفی (RF^2) یک روش یادگیری ماشین است که با ترکیب چندین درخت تصمیم به بهبود دقت و کاهش بیش‌برازش کمک می‌کند (Breiman, 2001). در این الگوریتم، هر درخت تصمیم با استفاده از یک نمونه‌گیری تصادفی از داده‌ها و انتخاب تصادفی زیرمجموعه‌ای از ویژگی‌ها ساخته می‌شود و در نهایت، تصمیم نهایی مدل از طریق رأی‌گیری (برای مسائل طبقه‌بندی) یا میانگین‌گیری (برای مسائل رگرسیون) بین درخت‌ها اتخاذ می‌گردد (Louppe, 2014). این روش به دلیل پایداری، توانایی مدیریت داده‌های با ابعاد بالا و مقاومت در برابر داده‌های پرت به طور گسترده در حوزه‌های مختلف مانند طبقه‌بندی پزشکی، پیش‌بینی مالی و داده‌کاوی زیستی به کار گرفته می‌شود (Cutler et al., 2007).

مدل‌سازی عملکرد ذرت

در این پژوهش از داده‌های مشاهده‌ای عملکرد ذرت و متغیرهای اقلیمی ماهانه شامل دمای حداقل و حداکثر، بارش و تبخیر و تعرق مرجع در دوره زمانی ۱۹۸۶ تا ۲۰۱۴ استفاده شد. داده‌های عملکرد مشاهده‌ای ذرت علوفه‌ای مورد استفاده در این پژوهش از آمار رسمی سازمان جهاد کشاورزی استان قزوین استخراج شد. داده‌های دوره پایه پس از انجام مراحل پاک‌سازی و نرمال‌سازی، به صورت تصادفی به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم گردید تا از بروز بایاس در مدل جلوگیری شده و قابلیت تعمیم‌پذیری آن افزایش یابد.

در مدل جنگل تصادفی، ۱۴۵ درخت تصمیم ایجاد شد. تعداد درخت‌ها به گونه‌ای انتخاب شد که تعادلی میان دقت پیش‌بینی و هزینه محاسباتی برقرار شود. مدل شبکه عصبی مصنوعی با یک لایه پنهان و ۳۳ نورون طراحی شد. برای نوروها از تابع فعال‌ساز

¹ Support Vector Regression

² Random Forest

خطی استفاده گردید و حداکثر تعداد تکرارهای آموزش برابر با ۱۰۰۰ تعیین شد. متغیرهای ورودی مشابه مدل جنگل تصادفی بودند و مدل با استفاده از کتابخانه nnet در محیط نرم‌افزاری R آموزش داده شد. در مدل رگرسیون بردار پشتیبان، از هسته شعاعی استفاده شد. پارامتر جریمه (cost) برابر با ۶ و مقدار ϵ (خطای مجاز) برابر با ۰/۵ تنظیم شد. متغیرهای ورودی مدل‌ها شامل و دمای حداقل و حداکثر، بارش و تبخیر و تعرق بودند و آموزش مدل با هدف به حداقل رساندن خطای انجام گرفت. پس از آموزش مدل‌ها، عملکرد هر یک با استفاده از داده‌های آزمون و آماره‌های ارزیابی بررسی شد. در نهایت، خروجی‌های هر سه مدل با هم ترکیب شدند تا یک مدل تلفیقی ارائه گردد که بهترین برآورد عملکرد محصول را بر اساس کمترین مقدار RMSE فراهم می‌آورد. به منظور تعیین ساختار بهینه مدل‌ها، تعداد نوروها در لایه پنهان شبکه عصبی و تعداد درخت‌ها در الگوریتم جنگل تصادفی از طریق فرآیند تنظیم ابرپارامترها تعیین شد. این فرآیند با استفاده از جستجوی شبکه‌ای و مقایسه عملکرد مدل‌ها بر اساس معیار RMSE در داده‌های اعتبارسنجی انجام گرفت تا از بیش‌برازش جلوگیری شده و پایداری نتایج افزایش یابد. به منظور افزایش پایداری نتایج و جلوگیری از بیش‌برازش، تنظیم ابرپارامترهای مدل‌ها با استفاده از روش اعتبارسنجی متقابل k-بخشی انجام شد و عملکرد نهایی مدل‌ها بر اساس کمینه‌سازی RMSE انتخاب گردید.

آماره‌های ارزیابی

برای ارزیابی نتایج به دست آمده از آماره‌های ارزیابی جذر میانگین مربعات خطا ($RMSE^1$)، میانگین مطلق خطا (MAE^2)، خطای میانگین جهت‌دار (MBE^3) و ضریب تبیین (R^2)⁴ استفاده شد. محاسبه شاخص‌های مذکور با استفاده از روابط ۲ تا ۵ امکان‌پذیر می‌باشد:

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

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (3)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (4)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad (5)$$

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

¹ Root Mean Squared Error

² Mean Absolute Error

³ Mean Bias Error

⁴ Coefficient of determination

میزان آریبی روش است، در یک تخمین نسبتاً دقیق بایستی نزدیک به صفر باشد. شاخص MAE (میانگین مطلق خطا)، میانگین قدر مطلق اختلاف مقدار اندازه‌گیری شده مدل با مقدار واقعی کمیت می‌باشد. هرچه مقدار آن کمتر باشد دقت مدل بالاتر است.

ضریب همبستگی بین منفی یک و مثبت یک قرار می‌گیرد. در نتیجه R^2 که توان دوم آن است بین صفر و یک قرار خواهد داشت. اگر این همبستگی زیاد باشد (نزدیک به 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

داده‌های ماهانه دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های اقلیمی MIROC6, GFDL-ESM4, CNRM-CM6-1 و HadGEM3 با داده سینوپتیک قزوین در دوره پایه ۱۹۸۶-۲۰۱۴ به صورت جداگانه و گروهی مقایسه شد (جدول ۱). در این مطالعه، به منظور بهبود برآورد داده‌های دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش حاصل از چهار مدل گردش عمومی (GCM)، از روش میانگین‌گیری وزن‌دار جوخطی 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.


جدول ۱. ارزیابی دمای حداقل، دمای حداکثر، بارش و تبخیر و تعرق (۱۹۸۶-۲۰۱۴)


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

Variable	General Circulation Model	Coefficient of Determination	Root Mean Square Error	Mean Directional Error	Mean Absolute Error
Parameter	GCM	R^2	RMSE	MBE	MAE
Minimum temperature (°C)	CNRM-CM6-1	0.93	2.67	1.5	2.22
	GFDL-ESM4	0.94	2.45	1.5	3.67
	HadGEM3	0.93	2.66	1.6	2.22
	MIROC6	0.95	2.66	1.3	1.86
	Ensemble model	0.96	2.19	1.4	1.84
Maximum temperature (°C)	CNRM-CM6-1	0.94	2.69	0.1	2.05
	GFDL-ESM4	0.93	2.7	0.1	2.09
	HadGEM3	0.93	2.88	0.3	2.19
	MIROC6	0.93	2.74	-0.1	2.1
	Ensemble model	0.95	2.24	0.1	1.7
Precipitation (mm)	CNRM-CM6-1	0.23	29.49	-5.4	18.18
	GFDL-ESM4	0.1	32.91	-5.4	22.43
	HadGEM3	0.14	32.37	-5.9	19.36
	MIROC6	0.16	31.6	-5	19.56
	Ensemble model	0.26	28.12	-5.3	16.79
Evapotranspiration (mm)	CNRM-CM6-1	0.95	14.4	-1.2	11.26
	GFDL-ESM4	0.95	14.48	-0.9	11.55
	HadGEM3	0.95	14.16	-0.6	11.22

MIROC6	0.95	15.16	-2.2	11.66
Ensemble model	0.96	12.74	-1.1	10.1

نتایج جدول ۱ نشان می‌دهد که دمای حداقل و حداکثر در مدل گروهی با مقادیر ضریب تبیین ۰/۹۵ در سطح معنی داری ۹۵٪ (P-value=0.00) و مقادیر کم RMSE با برآورد معقول و مناسبی همراه است. همچنین نتایج ضریب تبیین دما نشان می‌دهد که ترکیب مدل‌های گردش عمومی جو با داده‌های ایستگاه سینوپتیک از همبستگی بالایی برخوردار هستند. 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 خطای میانگین جهت‌دار نشان می‌دهد که مدل گروهی در دمای حداقل و حداکثر بیش‌برآورد و در بارش و تبخیر و تعرق کم برآورد داشته است. نتایج میانگین مطلق خطا نشان می‌دهد که اجرای مدل گروهی موجب کاهش خطا در پارامترهای دمای حداقل و حداکثر، بارش و تبخیر و تعرق شده است. مقدار پایین ضریب تبیین برای بارش نشان‌دهنده چالش ذاتی مدل‌های گردش عمومی جو در شبیه‌سازی الگوهای بارش، به‌ویژه در مناطق نیمه‌خشک مانند دشت قزوین است. برخلاف دما که متغیری پیوسته و نسبتاً پایدار است، بارش دارای ماهیتی ناپیوسته، با تغییرپذیری مکانی-زمانی بالا و وابسته به رخداد‌های حدی است که پیش‌بینی آن را با عدم قطعیت بیشتری همراه می‌سازد. گزارش‌های IPCC و مطالعات مرتبط با مدل‌های CMIP6 نیز نشان می‌دهند که عدم قطعیت در برآورد بارش به‌طور قابل‌توجهی بیشتر از دما است و مقادیر پایین R^2 برای بارش در بسیاری از مناطق خشک و نیمه‌خشک امری رایج محسوب می‌شود (IPCC, 2021; Yang et al., 2022). با این حال، استفاده از روش ترکیب وزنی خروجی چندین مدل اقلیمی در این پژوهش موجب کاهش خطای کلی و افزایش پایداری برآوردها شده و نتایج حاصل همچنان برای تحلیل روندهای اقلیمی آینده قابل اتکا هستند. به‌طور کلی نتایج نشان داد که اجرای گروهی مدل‌ها موجب کاهش خطا می‌شود. نتایج اشرف و همکاران (Ashraf et al., 2014) نشان داد که آماره‌های محاسبه شده توسط اجرای گروهی ۵ مدل گردش عمومی جو برای منطقه شمال شرق ایران نشان‌دهنده کاهش خطای شبیه‌سازی و در نتیجه افزایش دقت پیش‌بینی‌های شده است. نتایج کمانگر و همکاران (Kamangar et al., 2025) نشان داد با اجرای گروهی پنج مدل گردش عمومی جو کاهش معنی‌دار خطای جذر میانگین مربعات در شبیه‌سازی به روش وزنی در دمای حداقل و حداکثر در مقایسه با اجرای منفرد هر مدل مشاهده شده است که با نتایج مطالعه حاضر همخوانی دارد. میانگین سالانه دمای حداقل و حداکثر، بارش و تبخیر و تعرق در شکل ۲ آورده شده است.





شکل ۲. میانگین سالانه دمای حداقل، حداکثر، مجموع بارش و تبخیر و تعرق

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

نتایج شکل ۲ نشان می‌دهد که دمای حداقل و حداکثر در دوره‌های آتی نسبت به دوره پایه افزایش می‌یابد به طوری که میزان تغییرات دمای حداقل در دوره ۲۰۲۶-۲۰۵۰ نسبت به دوره پایه در سناریو SSP2-4.5 و SSP5-8.5 به ترتیب ۲/۶۳ و ۲/۸۸ درجه سانتیگراد و دمای حداکثر در سناریو SSP2-4.5 و SSP5-8.5 در دوره ۲۰۲۶-۲۰۵۰ نسبت به دوره پایه ۱/۶۰ و ۲/۲۴ خواهد بود. بارش در دوره‌های آتی کاهش می‌یابد و میزان تغییرات آن در دوره ۲۰۷۵-۲۰۵۱ نسبت به دوره پایه در سناریو SSP2-4.5 و SSP5-8.5 به ترتیب ۱۲۱/۶۲ و ۱۷۰/۲۹ میلی‌متر و میزان تغییرات آن در دوره ۲۱۰۰-۲۰۷۶ نسبت به دوره پایه در سناریو SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۱۵۸/۳۱ و ۲۷۵/۷۳ میلی‌متر در سال خواهد بود. افشاری نیا و همکاران (Afsharinia et al., 2023) به ارزیابی تغییرات اقلیمی با استفاده از مدل‌های گزارش ششم در دشت کاشان طی دوره ۲۰۲۲-۲۱۰۰ پرداختند. نتایج آنها نشان داد در همه ایستگاه‌های مورد مطالعه بارش در دوره آتی در مقایسه با دوره پایه دارای روند کاهشی خواهد بود و دمای متوسط نیز در دوره آتی نسبت به دوره پایه افزایش خواهد یافت که با نتایج مطالعه حاضر همخوانی دارد. ایرانشاهی و همکاران (Iranshahi et al., 2023) به بررسی اثرات تغییر اقلیم بر وضعیت دما و بارش در ایستگاه‌های الشتر و خرم‌آباد با استفاده از گزارش ششم پرداختند. نتایج آنها نشان داد که این متغیرها در دوره‌های آینده نزدیک (۲۰۲۳-۲۰۶۲) و آینده دور (۲۱۰۰-۲۰۶۳) در مقیاس ماهانه دارای نوسان‌های متعددی خواهند بود، به طوری که در دو ایستگاه الشتر و خرم‌آباد طی دوره‌های آینده نزدیک و آینده دور دمای حداکثر و دمای حداقل نسبت به دوره مشاهداتی در تمام سناریوهای SSP روندی افزایشی خواهند داشت و تغییرات دمای حداقل نسبت به دمای حداکثر بیش‌تر خواهد بود و میانگین بارش سالانه تحت سناریوهای SSP کاهش خواهد داشت که با نتایج مطالعه حاضر همخوانی دارد.

شبیه‌سازی عملکرد ذرت


عملکرد ذرت با استفاده از پارامترهای دمای حداقل، دمای حداکثر، بارش و تبخیر و تعرق (دوره کشت) شبیه‌سازی شد. برای این منظور از روش‌های جنگل تصادفی، رگرسیون بردار پشتیبان و شبکه عصبی و روش گروهی (ترکیب جنگل تصادفی، رگرسیون بردار پشتیبان و شبکه عصبی) استفاده شد. نتایج ارزیابی روش‌ها در جدول ۲ آورده شده است.

جدول ۲. ارزیابی آماری روش‌های جنگل تصادفی، رگرسیون بردار پشتیبان، شبکه عصبی و روش گروهی در شبیه‌سازی عملکرد (۲۰۱۴-۱۹۸۶)

Table 2. Statistical evaluation of random forest, support vector regression, neural network and ensemble methods in performance simulation (1986-2014)


Step	Method	R ²	RMSE (ton/ha)	MAE (ton/ha)	MBE (ton/ha)
Train	neural network	0.8	0.12	0.1	-0.000003
	random forest	0.89	0.11	0.08	-0.008
	support vector regression	0.85	0.11	0.1	0.03
	ensemble model	0.9	0.10	0.07	-0.005
Test	neural network	0.72	0.04	0.15	0.03
	random forest	0.76	0.22	0.17	-0.04
	support vector regression	0.36	0.08	0.2	-0.009
	ensemble model	0.77	0.03	0.14	-0.005

نتایج جدول ۲ نشان می‌دهد که روش رگرسیون بردار پشتیبان و جنگل تصادفی در مرحله آموزش با ضریب تبیین بیش از ۰/۸ و مقادیر اندک RMSE دقت بالایی در شبیه‌سازی عملکرد ذرت در دوره پایه داشتند. در مرحله آزمون روش گروهی با ضریب تبیین ۰/۷۷، RMSE برابر ۰/۰۳ (تن بر هکتار) و MBE ۰/۰۰۵ - (تن بر هکتار) دقت بالاتری نسبت به روش‌های جنگل تصادفی، رگرسیون بردار پشتیبان و شبکه عصبی داشت و بنابراین این روش برای شبیه‌سازی ذرت در دوره‌های آبی انتخاب شد. اختلاف مشاهده‌شده بین مقادیر R² در مرحله آموزش و آزمون در برخی مدل‌ها می‌تواند نشان‌دهنده تمایل نسبی به بیش‌برازش باشد. این پدیده در مدل‌های یادگیری ماشین، به‌ویژه در شرایطی با حجم محدود داده‌های مشاهده‌ای و تعداد متغیرهای ورودی، امری متداول است. با این حال، در این پژوهش به‌منظور کاهش اثر بیش‌برازش، از تفکیک مستقل داده‌ها به مجموعه‌های آموزش و آزمون و همچنین تنظیم ابرپارامترها بر اساس حداقل‌سازی خطای RMSE در داده‌های اعتبارسنجی استفاده شده است. علاوه بر این، به‌کارگیری رویکرد مدل‌های گروهی (ensemble) موجب کاهش واریانس پیش‌بینی و افزایش پایداری نتایج شده است؛ به‌طوری‌که تمرکز تحلیل‌ها بر عملکرد مدل‌ها در مجموعه آزمون قرار داده شده و نتایج نهایی بر اساس این مرحله گزارش شده‌اند. شبیه‌سازی عملکرد ذرت در دوره‌های آبی انجام شد (شکل ۳).



شکل ۳. میانگین سالانه عملکرد ذرت در دوره‌های آبی
Fig 3. Average annual maize yield in future periods

نتایج نشان می‌دهد که عملکرد ذرت در دوره‌های آبی کاهش می‌یابد. در دوره ۲۰۲۶-۲۰۵۰ تغییرات عملکرد ذرت در سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۴/۷۲- و ۸/۷۲- درصد، در دوره ۲۰۷۵-۲۰۵۱ در سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۶/۶۸- و ۱۵/۱۲- درصد و در دوره ۲۰۷۶-۲۱۰۰ در سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۸/۴- و ۲۰/۰۴- درصد خواهد بود. دیلون و همکاران (Dhillon et al., 2024) به بررسی تأثیر تغییر اقلیم بر عملکرد ذرت در ایالت اوهایو پرداختند. آنها از الگوریتم‌های یادگیری ماشین برای مدل‌سازی تأثیر دما و بارندگی ماهانه بر عملکرد ذرت استفاده کردند. نتایج آنها نشان داد عملکرد ذرت در سناریوهای تغییر اقلیم ۱۳/۲ درصد یا ۱۸/۵ درصد کاهش می‌یابد. اگرچه شرایط اقلیمی منطقه مورد مطالعه با ایالت اوهایو متفاوت است و نقش بارش در فصل رشد ذرت در اوهایو بسیار پررنگ‌تر می‌باشد، نتایج هر دو مطالعه از نظر جهت تغییرات عملکرد تحت سناریوهای تغییر اقلیم هم‌راستا هستند و نشان می‌دهند افزایش دما و تبخیر و تعرق می‌تواند حتی در سیستم‌های آبی نیز منجر به کاهش عملکرد شود. اوزبولدو و ایروم (Ozbuldu, and Irvem., 2025) به بررسی اثرات تغییر اقلیم بر عملکرد ذرت تحت سناریوهای SSP2-4.5 و SSP5-8.5 در دوره ۲۰۲۰-۲۰۶۰ و ۲۰۶۰-۲۱۰۰ در ترکیه پرداختند. نتایج آنها نشان داد عملکرد ذرت برای دوره‌های ۲۰۲۰-۲۰۶۰ و ۲۰۶۰-۲۱۰۰ به ترتیب ۱۰ و ۱۴ درصد برای SSP2-4.5 و ۱۶ و ۳۰ درصد برای SSP5-8.5 کاهش می‌یابد که با نتیجه مطالعه حاضر همخوانی دارد. سری زمانی عملکرد ذرت در شکل ۴ و ارزیابی روند عملکرد ذرت در دوره آبی جدول ۳ آورده شده است.



شکل ۴. سری زمانی عملکرد ذرت
Fig 4. Maize yield time series

جدول ۳. نتایج آزمون من کندال برای سناریوها

Table 3. Mann-Kendall test results for scenarios				
Scenario	z	P-value	S	τ
SSP5-8.5	-10.228	2.2e-16	-2237	-0.8061
SSP2-4.5	-7.5476	4.434e-14	-1651	-0.5950

نتایج جدول ۳ نشان می‌دهد که بر اساس آزمون Mann-Kendall ($\tau = -0.8061$, $p < 0.0001$) برای سناریو SSP5-8.5 و Mann-Kendall ($\tau = -0.5950$, $p < 0.0001$) برای سناریو SSP2-4.5، روند عملکرد ذرت در هر دو سناریو از سال ۲۰۲۶ تا ۲۱۰۰ نزولی و

معنادار است. این روند نشان دهنده 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. عدم قطعیت در نتایج این پژوهش می‌تواند از منابع مختلفی ناشی شود؛ از جمله عدم قطعیت ذاتی سناریوهای انتشار گازهای گلخانه‌ای، تفاوت ساختاری میان مدل‌های گردش عمومی جو، خطاهای مربوط به داده‌های اقلیمی ورودی و همچنین محدودیت‌های مدل‌های یادگیری ماشین در تعمیم‌پذیری به شرایط آینده. افزون بر این، پیچیدگی فرآیندهای بیوفیزیکی مؤثر بر رشد ذرت و ساده‌سازی آن‌ها در مدل‌ها می‌تواند به افزایش عدم قطعیت منجر شود. با این حال، در این مطالعه تلاش شده است تا با استفاده از رویکرد تلفیقی شامل به‌کارگیری چندین مدل اقلیمی (CMIP6) و ترکیب چند الگوریتم یادگیری ماشین، دامنه عدم قطعیت کاهش یافته و پایداری و قابلیت اعتماد نتایج افزایش یابد. نتایج این مطالعه در راستای تصمیم‌سازی و برنامه‌ریزی سازگاری اقلیمی قابل استفاده هستند و نباید به‌عنوان پیش‌بینی‌های قطعی تلقی شوند.

نتیجه‌گیری

نتایج این پژوهش نشان داد که اجرای گروهی مدل‌های اقلیمی MIROC6, GFDL-ESM4, CNRM-CM6-1 و HadGEM3 با کاهش خطا و بهبود دقت شبیه‌سازی متغیرهای اقلیمی نسبت به مدل‌های منفرد همراه است، به‌گونه‌ای که دمای حداقل و حداکثر با ضرایب تبیین بالا و خطای کم بازتولید شد. شبیه‌سازی متغیرهای اقلیمی تحت سناریوهای SSP2-4.5 و SSP5-8.5 بیانگر کاهش بارش و افزایش دمای حداقل و حداکثر و تبخیر و تعرق در دوره‌های آبی دشت قزوین است که این تغییرات تأثیر منفی قابل توجهی بر عملکرد ذرت دارند. نتایج شبیه‌سازی عملکرد نشان داد که رویکرد گروهی در مقایسه با مدل‌های منفرد یادگیری ماشین، دقت بالاتری داشته و عدم قطعیت را کاهش می‌دهد و بر اساس پیش‌بینی‌ها، عملکرد ذرت در تمامی دوره‌های آینده روندی کاهشی خواهد داشت، به‌ویژه تحت سناریوی بدبینانه SSP5-8.5. این نتایج نشان می‌دهد که بدون اتخاذ راهبردهای سازگاری، تداوم روند تغییرات اقلیمی می‌تواند پایداری تولید ذرت در منطقه را با چالش مواجه سازد؛ از این‌رو اصلاح تقویم زراعی، استفاده از ارقام متحمل به تنش‌های گرمایی و خشکی، بهبود مدیریت آبیاری و بهره‌گیری از مدل‌های پیش‌بینی در تصمیم‌گیری‌های مدیریتی، به‌عنوان مهم‌ترین اقدامات سازگاری برای کاهش اثرات منفی تغییر اقلیم در دشت قزوین پیشنهاد می‌شود.

تقدیر و قدردانی

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

منابع

- Abbaszadeh, P., Gavahi, K., Alipour, A., Deb, P., & Moradkhani, H. (2022). Bayesian multi-modeling of deep neural nets for probabilistic crop yield prediction. *Agricultural and Forest Meteorology*, 314, 108773. <https://doi.org/10.1016/j.agrformet.2021.108773>
- Afsharinia, M., Panahi, F., & Ehteram, M. (2023). Investigation of Climate Change Using CMIP6 Model Outputs (Case Study: Kashan Plain). *Irrigation and Water Engineering*, 14(2), 237-256. <https://doi.org/10.22125/IWE.2023.383176.1704>. [In Persian]
- Arias, P., Bellouin, N., Coppola, E., Jones, R., Krinner, G., Marotzke, J., ... & Zickfeld, K. (2021). Climate Change 2021: the physical science basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change; technical summary. <https://www.ipcc.ch/report/ar6/wg1/>

Arunrat, N., Pumijumnong, N., Sreenonchai, S., Chareonwong, U., & Wang, C. (2020). Assessment of climate change impact on rice yield and water footprint of large-scale and individual farming in Thailand. *Science of the Total Environment*, 726, 137864. <https://doi.org/10.1016/j.scitotenv.2020.137864>

Ashraf, B., Alizadeh, A., Mousavi Bayagi, M., & Bannayan Awal, M. (2014). Verification of temperature and precipitation simulated data by individual and ensemble performance of five AOGCM models for northeast of Iran. *Journal of Water and Soil (Agriculture Sciences and Technology)*, 28 (2), 253-266. <https://doi.org/10.22067/jsw.v0i0.38011>. [In Persian]

Asseng, S., Ewert, F., Martre, P., Rötter, R. P., Lobell, D. B., Cammarano, D., ... & Zhu, Y. (2015). Rising temperatures reduce global wheat production. *Nature Climate Change*, 5(2), 143-147. <https://doi.org/10.1038/nclimate2470>

Beillouin, D., Schauburger, B., Bastos, A., Ciais, P., & Makowski, D. (2020). Impact of extreme weather conditions on European crop production in 2018. *Philosophical Transactions of the Royal Society B*, 375(1810), 20190510. <https://doi.org/10.1098/rstb.2019.0510>

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>

Cai, Y., Guan, K., Lobell, D., Potgieter, A. B., Wang, S., Peng, J., ... & Peng, B. (2019). Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agricultural and Forest Meteorology*, 274, 144-159. <https://doi.org/10.1016/j.agrformet.2019.03.010>

Chakraborty, D., Saha, S., Sethy, B. K., Singh, H. D., Singh, N., Sharma, R., ... & Prasad, P. V. (2022). Usability of the weather forecast for tackling climatic variability and its effect on maize crop yield in the Northeastern Hill Region of India. *Agronomy*, 12(10), 2529. <https://doi.org/10.3390/agronomy12102529>

Chemura, A., Schauburger, B., & Gornott, C. (2020). Impacts of climate change on agro-climatic suitability of major food crops in Ghana. *PLoS One*, 15(6), e0229881. <https://doi.org/10.1371/journal.pone.0229881>

Crane-Droesch, A. (2018). Machine learning methods for crop yield prediction and climate change impact assessment in agriculture. *Environmental Research Letters*, 13(11), 114003. <https://doi.org/10.1088/1748-9326/aae159>

Cutler, D. R., Edwards Jr., T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792. <https://doi.org/10.1890/07-0539.1>

Dastorani, M., Zarei, M., & Qaderi, M. (2025). Climate Change and Vegetation Cover in the Kahneh Watershed, Khorasan Razavi, Using Remote Sensing in the GEE Environment. *Journal of Drought and Climate Change Research*. 3 (11), 47-62. <https://doi.org/10.22077/jdcr.2025.8922.1118>. [In Persian]

Dhillon, R., Takoo, G., Sharma, V., & Nagle, M. (2024). Utilizing a machine learning framework to evaluate the effect of climate change on maize and soybean yield. *Computers and Electronics in Agriculture*, 221, 108982. <https://doi.org/10.1016/j.compag.2024.108982>

Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support vector regression machines. *Advances in neural information processing systems*, 9. https://proceedings.neurips.cc/paper_files/paper/1996/file/d38901788c533e8286cb6400b40b386d-Paper.pdf

Eslami Senoukesh, F., Zarandi-Miandoab, L., Lotfi, R., Abbasi, A., Chaparzadeh, N. (2024). The Effect of Main Components of Climate Change on Photosynthetic Efficiency and Grain Yield of Wheat Genotypes under Rainfed Conditions. *Journal of Drought and Climate Change Research*. 1(4), 1-16. <https://doi.org/10.22077/jdcr.2023.6609.1033>. [In Persian]

Fan, J., Jintrawet, A., & Sangchyoswat, C. (2020). The relationships between extreme precipitation and rice and maize yields using machine learning in Sichuan Province, China. *Current Applied Science and Technology*, 453-469. <https://li01.tci-thaijo.org/index.php/cast/article/view/244405>

Fischer, G., Nachtergaele, F. O., Van Velthuizen, H., Chiozza, F., Francheschini, G., Henry, M., ... & Tramberend, S. (2021). Global agro-ecological zones (GAEZ v4) model documentation. <https://doi.org/10.4060/cb4744en>

Gavahi, K., Abbaszadeh, P., & Moradkhani, H. (2021). DeepYield: A combined convolutional neural network with long short-term memory for crop yield forecasting. *Expert Systems with Applications*, 184, 115511. <https://doi.org/10.1016/j.eswa.2021.115511>

Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT Press. <https://mitpress.mit.edu/9780262035613/deep-learning/>

Han, J., Zhang, Z., Cao, J., Luo, Y., Zhang, L., Li, Z., & Zhang, J. (2020). Prediction of winter wheat yield based on multi-source data and machine learning in China. *Remote Sensing*, 12(2), 236.- <https://doi.org/10.3390/rs12020236>

Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Applied engineering in agriculture*, 1(2), 96-99. <http://dx.doi.org/10.13031/2013.26773>

Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Pearson Education India. <http://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>

- Hoffman, A. L., Kemanian, A. R., & Forest, C. E. (2018). Analysis of climate signals in the crop yield record of sub-Saharan Africa. *Global Change Biology*, 24(1), 143-157. <https://doi.org/10.1111/gcb.13901>
<https://doi.org/10.22077/jdcr.2023.6609.1033>
- IPCC. (2021). *Climate Change 2021: The Physical Science Basis*. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. <https://www.ipcc.ch/report/ar6/wg1/>
- Iranshahi, M., Ebrahimi, B., Yousefi, H., & Moridi, A. (2023). Investigating the effects of climate change on temperature and precipitation using a neural network and CMIP6 (Case study: Aleshtar and Khorramabad Stations). *Water and Irrigation Management*, 12(4), 821-845. <https://doi.org/10.22059/jwim.2022.346796.1009>. [In Persian]
- Jägermeyr, J., Müller, C., Ruane, A. C., Elliott, J., Balkovic, J., Castillo, O., ... & Rosenzweig, C. (2021). Climate impacts on global agriculture emerge earlier in new generation of climate and crop models. *Nature Food*, 2(11), 873-885. <https://doi.org/10.1038/s43016-021-00400-y>
- Javadinejad, S., Eslamian, S., & Ostad-Ali-Askari, K. (2021). The analysis of the most important climatic parameters affecting performance of crop variability in a changing climate. *International journal of hydrology science and technology*, 11(1), 1-25. <https://doi.org/10.1504/IJHST.2021.112651>
- Kamangar, M., Ahmadi, M., Rabiei-Dastjerdi, H., & Hazbavi, Z. (2025). Ensemble modeling of extreme seasonal temperature trends in Iran under socio-economic scenarios. *Natural Hazards*, 121(2), 1265-1288. <https://doi.org/10.1007/s11069-024-06830-8>
- Kang, Y., Ozdogan, M., Zhu, X., Ye, Z., Hain, C., & Anderson, M. (2020). Comparative assessment of environmental variables and machine learning algorithms for maize yield prediction in the US Midwest. *Environmental Research Letters*, 15(6), 064005. <https://doi.org/10.1088/1748-9326/ab7df9>
- Lesk, C., Coffel, E., Winter, J., Ray, D., Zscheischler, J., Seneviratne, S. I., & Horton, R. (2021). Stronger temperature–moisture couplings exacerbate the impact of climate warming on global crop yields. *Nature Food*, 2(9), 683-691. <https://doi.org/10.1038/s43016-021-00341-6>
- Louppe, G. (2014). *Understanding random forests: From theory to practice*. Université de Liège (Belgium). <https://doi.org/10.48550/arXiv.1407.7502>
- Ministry of Agriculture Jihad of Iran. (2024). *Agricultural Statistics Yearbook*. Tehran, Iran. <https://agrieng.org/images/dlcenter/jahad/zerace.pdf>
- Mupangwa, W., Chipindu, L., Nyagumbo, I., Mkuhlani, S., & Sisito, G. (2020). Evaluating machine learning algorithms for predicting maize yield under conservation agriculture in Eastern and Southern Africa. *SN Applied Sciences*, 2(5), 952. <https://doi.org/10.1007/s42452-020-2711-6>
- Ortiz-Bobea, A., Ault, T. R., Carrillo, C. M., Chambers, R. G., & Lobell, D. B. (2021). Anthropogenic climate change has slowed global agricultural productivity growth. *Nature Climate Change*, 11(4), 306-312. <https://doi.org/10.1038/s41558-021-01000-1>
- Ozbuldu, M., & Irvem, A. (2025). Evaluation of Climate Change Impacts on Maize and Cotton Yields Under Different Climate Scenarios in Kırıkhan District, Türkiye. *International Journal of Plant Production*, 19(1), 65-81. <https://doi.org/10.1007/s42106-024-00320-4>
- Pandith, V., Kour, H., Singh, S., Manhas, J., & Sharma, V. (2020). Performance evaluation of machine learning techniques for mustard crop yield prediction from soil analysis. *Journal of Scientific Research*, 64(2), 394-398. <https://doi.org/10.37398/JSR.2020.640254>
- Priya, P., Muthaiah, U., & Balamurugan, M. (2018). Predicting yield of the crop using machine learning algorithm. *International Journal of Engineering Sciences & Research Technology*, 7(1), 1-7. <https://doi.org/10.5281/zenodo.1212821>
- Qazvin Provincial Agricultural Jihad Organization. (2023). *Cropping calendar and maize cultivation guidelines in Qazvin Province*. <https://qazvin.maj.ir/>
- Ramezani Etedali, H., & Koohi, S. (2025). Investigation of the Impact of Climate Change on Aridity in Iran with Population Exposure Approach. *Journal of Drought and Climate Change Research*. 3(1), 17-38. <https://doi.org/10.22077/jdcr.2024.8258.1079>
- Reddy, D. J., & Kumar, M. R. (2021, May). Crop yield prediction using a machine learning algorithm. In *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)* (pp. 1466-1470). IEEE. <https://doi.org/10.1109/ICICCS51141.2021.9432236>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>

- Schneider, P., & Asch, F. (2020). Rice production and food security in Asian Mega deltas—A review on characteristics, vulnerabilities and agricultural adaptation options to cope with climate change. *Journal of Agronomy and Crop Science*, 206(4), 491-503. <https://doi.org/10.1111/jac.12415>
- Shahhosseini, M., Martinez-Feria, R. A., Hu, G., & Archontoulis, S. V. (2019). Maize yield and nitrate loss prediction with machine learning algorithms. *Environmental Research Letters*, 14(12), 124026. <https://doi.org/10.1088/1748-9326/ab5268>
- Sharifi, A. (2021). Yield prediction with machine learning algorithms and satellite images. *Journal of the Science of Food and Agriculture*, 101(3), 891-896. <https://doi.org/10.1002/jsfa.10696>
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Sun, J., Di, L., Sun, Z., Shen, Y., & Lai, Z. (2019). County-level soybean yield prediction using a deep CNN-LSTM model. *Sensors*, 19(20), 4363. <https://doi.org/10.3390/s19204363>
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer. <https://doi.org/10.1007/978-1-4757-3264-1>
- Veenadhari, S., Misra, B., & Singh, C. D. (2014). Machine learning approach for forecasting crop yield based on climatic parameters. In *2014 International Conference on Computer Communication and Informatics* (pp. 1-5). IEEE. <https://doi.org/10.1109/ICCCI.2014.6921718>
- Vogel, E., Donat, M. G., Alexander, L. V., Meinshausen, M., Ray, D. K., Karoly, D., ... & Frieler, K. (2019). The effects of climate extremes on global agricultural yields. *Environmental Research Letters*, 14(5), 054010. <https://doi.org/10.1088/1748-9326/ab154b>
- Wang, X., Huang, J., Feng, Q., & Yin, D. (2020). Winter wheat yield prediction at county level and uncertainty analysis in main wheat-producing regions of China with deep learning approaches. *Remote Sensing*, 12(11), 1744. <https://doi.org/10.3390/rs12111744>
- Witten, I. H., Frank, E., Hall, M. A., Pal, C. J., & Data, M. (2005). Practical machine learning tools and techniques. In *Data mining* (Vol. 2, No. 4, pp. 403-413). Amsterdam, The Netherlands: Elsevier. <https://doi.org/10.1186/1475-925X-5-51>
- Yang, L., Tian, J., Fu, Y., Zhu, B., He, X., Gao, M., ... & Zhang, Z. (2022). Will the arid and semi-arid regions of Northwest China become warmer and wetter based on CMIP6 models?. *Hydrology Research*, 53(1), 29-50. <https://doi.org/10.2166/nh.2021.069>
- Zhang, L., Zhang, Z., Luo, Y., Cao, J., & Tao, F. (2019). Combining optical, fluorescence, thermal satellite, and environmental data to predict county-level maize yield in China using machine learning approaches. *Remote Sensing*, 12(1), 21. <https://doi.org/10.3390/rs12010021>
- 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.
- 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., 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.
- Thrasher, B., Depsky, N., Taylor, M. A., & Nemani, R. (2022). NASA-NEX-GDDP-CMIP6 Dataset. NASA Earth Exchange.
- Kumar, Y. J. N., Spandana, V., Vaishnavi, V. S., Neha, K., & Devi, V. G. R. R. (2020). Supervised machine learning approach for crop yield prediction in the agriculture sector. In *2020 5th International Conference on Communication and Electronics Systems (ICCES)* (pp. 736-741). IEEE. <https://doi.org/10.1109/ICCES48766.2020.9137868>