

Application of soft computing in simulating rainfed wheat yield using integration of climatic data and remote sensing indices

ABSTRACT

Wheat, as a strategic crop, plays a critical role in the nation's food security. This research aimed to compare different algorithms to increase the accuracy of modeling rainfed wheat yield using artificial neural networks at the field scale. For this purpose, a combination of two datasets, including remote sensing indicators and climatic data for 61 farms, was used as input to the models. The southern regions of the Lake Urmia Basin were selected as the case study area. An artificial neural network (ANN) model, serving as the base model, and metaheuristic algorithms, including the Reptile Search Algorithm (RSA) and the Firefly Algorithm (FFA), were employed to enhance ANN training accuracy. The input data included the Normalized Difference Vegetation Index (NDVI), the Infrared Percentage Vegetation Index (IPVI), and five climatic parameters: total precipitation, mean maximum temperature, mean minimum temperature, average temperature, and mean relative humidity. The results revealed that the developed hybrid models outperformed the standalone ANN model in simulating rainfed wheat yield. Specifically, the ANN-FFA model achieved a coefficient of determination (R^2) of 0.758 and a root mean square error (RMSE) of 0.189 $\text{ton}\cdot\text{ha}^{-1}$ during the test stage, outperforming the ANN-RSA model, which yielded an R^2 of 0.748 and an RMSE of 0.190 $\text{ton}\cdot\text{ha}^{-1}$. Both algorithms reduced the rainfed wheat yield simulation error index by an average of 0.042 $\text{ton}\cdot\text{ha}^{-1}$. As a result, the ANN-FFA hybrid model improved the accuracy of simulating rainfed wheat yield, which necessitates its use and evaluation in other similar areas for a comprehensive understanding.

Keywords: Artificial Neural Networks, Firefly Algorithm, Food Security, Rainfed products, Reptile Search Algorithm.

EXTENDED ABSTRACT

Introduction

In the recent years, artificial intelligence (AI) techniques have been increasingly employed in agricultural research due to their ability to address complex and nonlinear problems. Among the most well-known and widely used models is the Artificial Neural Network (ANN), which effectively manages intricate nonlinear relationships and interactions between variables. However, in certain cases, ANN model has demonstrated suboptimal performance in predictive tasks, raising concerns regarding their reliability (Kayhomayoon et al., 2022). To address these limitations, metaheuristic algorithms have been extensively utilized recently years to optimize and enhance the accuracy of standalone models such as ANN, Adaptive Neuro-Fuzzy Inference Systems (ANFIS), and Support Vector Regression (SVR) (Milan et al., 2021). The Reptile Search Algorithm (RSA) and the Firefly Algorithm (FFA) are examples of such metaheuristic methods that have proven their effectiveness in optimization tasks. In parallel with robust prediction models, remote sensing technologies have emerged as cost-effective and accurate alternatives to traditional methods for agricultural yield estimation and modeling, especially for rainfed wheat. In recent years, researchers have increasingly integrated remote sensing indices with meteorological parameters to improve yield prediction accuracy for rainfed crops.

Materials and Methods

This study aimed to simulate and predict rainfed wheat yield across 61 farms in the counties of Oshnavieh, Piranshahr, and Naqadeh, situated in the southern part of West Azerbaijan Province, Iran, near Lake Urmia. The data covered 2005–2006 to 2024–2025, corresponding to the rainfed wheat growing season from early October to late July, obtained from the West Azerbaijan Agricultural Jihad Organization. The two main datasets were: regional meteorological data and remote sensing vegetation indices. Among the vegetation indices, the Normalized Difference Vegetation Index (NDVI) and the Infrared Percentage

Vegetation Index (IPVI) were specifically selected to evaluate vegetation cover in the studied area. These datasets served as input variables for the modeling framework. Vegetation indices were extracted using satellite imagery processed in the Google Earth Engine (GEE) platform. For the period from 2006 to 2012, Landsat 5 imagery was used, while Landsat 8 imagery was employed for the period from 2013 to 2024. Initially, the datasets were integrated and modeled with an Artificial Neural Network (ANN). To improve accuracy, two metaheuristic optimization algorithms -the Reptile Search Algorithm (RSA) and the Firefly Algorithm (FFA)- were applied to optimize the models. Ultimately, two hybrid models, ANN-RSA and ANN-FFA were developed for predicting rainfed wheat yield.

Results and Discussion

Based on the study findings, the input variables for the model included total precipitation, mean minimum temperature, and average temperature, along with the remote sensing indices NDVI and IPVI, were selected as the model inputs. The incorporation of the Reptile Search Algorithm (RSA) and the Firefly Algorithm (FFA) significantly enhanced the training accuracy of the Artificial Neural Network (ANN). During training, combining ANN with RSA and FFA increased the coefficient of determination (R^2) by 13.88% and 17.31%, respectively. In the testing phase, further gains were observed, with R^2 increasing by 17.24% and 18.80%, respectively. Notably, the Firefly Algorithm, despite its relatively simpler structure compared to RSA, yielded superior predictive performance, achieving a root mean square error (RMSE) of 0.189 ton.ha⁻¹ and an R^2 value of 0.758. Overall, the ANN-FFA model outperformed other configurations, demonstrating that combining meteorological data with remote sensing indices enhances yield prediction accuracy. This highlights the potential of hybrid machine learning models to support data-driven decisions in precision agriculture, especially under rainfed conditions.

Conclusions

Timely and accurate crop yield prediction is essential for policymakers to effectively mitigate climate-related impacts and maximize agricultural products. One of the key outcomes of this study was the development of a robust predictive model that integrates meteorological parameters and remote sensing indices within an intelligent hybrid machine learning framework for forecasting rainfed wheat yield. The proposed model demonstrated promising predictive capabilities, highlighting the potential of combining artificial intelligence with environmental data for agricultural forecasting. A major advantage of such hybrid models is their independence from the need for detailed physical information about the study area often costly, time-consuming, or practically infeasible to acquire in many regions. As a result, this approach offers a cost-effective and scalable solution for yield estimation, particularly in resource-limited settings. Utilizing readily available meteorological and satellite data reduces the need for extensive field surveys and enhances the feasibility of regional yield predictions, especially in resource-limited areas.

Author contributions

In the present research, A.A.: Writing original draft, Formal analysis, Conceptualization, Data curation, Methodology, Validation, Software, Modeling. V. R.: Writing – review & editing. J.B.: Writing – review & editing. F.A.: Writing – review & editing. M.R.: Writing – review & editing.

Data Availability Statement

Data is available on reasonable request from the authors.

Acknowledgements

The authors would like to thank Urmia University and West Azerbaijan province Jihad Keshavarzi for their kindly supports. Also, the authors would like to thank all participants of the present study.

Ethical considerations

The study was approved by the Ethics Committee of the Urmia University. The authors avoided data fabrication, falsification, plagiarism, and misconduct. The present manuscript has not simultaneously been sent to another journal.

Conflict of interest

The author declares no conflict of interest.

ویدار استانی
کشد

کاربرد محاسبات نرم در شبیه‌سازی عملکرد گندم با استفاده از تلفیق داده‌های اقلیمی و

شاخص‌های سنجش از دور

چکیده

گندم به عنوان یک محصول استراتژیک نقش اساسی در امنیت غذایی کشور دارد. این تحقیق با هدف مقایسه الگوریتم‌های مختلف برای افزایش دقت مدل‌سازی عملکرد گندم با استفاده از شبکه عصبی مصنوعی در مقیاس مزرعه‌ای انجام شد. برای این منظور، ترکیب دو مجموعه داده شامل شاخص‌های سنجش از دور و داده‌های اقلیمی برای ۶۱ مزرعه، به عنوان ورودی مدل‌ها، مورد استفاده قرار گرفت. مزارع شهرستان‌های اشنویه، نقده و پیرانشهر که در جنوب استان آذربایجان غربی واقع شده‌اند، به عنوان محدوده‌ی مطالعاتی در نظر گرفته شدند. از شبکه عصبی مصنوعی (ANN) به عنوان مدل پایه و از دو الگوریتم فرا ابتکاری جستجوی خردگان (RSA) و کرم شب‌تاب (FFA) برای بهبود افزایش دقت آموزش شبکه عصبی مصنوعی استفاده شد. داده‌های ورودی شامل شاخص‌های تفاضلی نرمال شده گیاهی (NDVI) و شاخص گیاهی درصدی مادون قرمز (IPVI) همراه با پنج پارامتر اقلیمی شامل بارش، میانگین حداکثر دما، میانگین حداقل دما، میانگین متوسط دما و میانگین رطوبت نسبی می‌باشند. نتایج نشان داد که عملکرد مدل‌های هیبریدی توسعه داده شده در شبیه‌سازی عملکرد گندم نسبت به مدل مجزای ANN بهتر بود. عملکرد ANN-FFA با ضریب تبیین ۰/۷۵۸ و میانگین جذر مربعات خطا ۰/۱۸۹ تن بر هکتار در مرحله آزمون عملکرد مناسب‌تری نسبت به مدل ANN-RSA با مقادیر به ترتیب ۰/۷۴۸ و ۰/۱۹۰ تن بر هکتار دارد. هر دو الگوریتم، شاخص خطای شبیه‌سازی عملکرد گندم را به میزان متوسط ۰/۰۴۲ تن بر هکتار کاهش دادند. در نتیجه مدل هیبریدی ANN-FFA موجب بهبود دقت شبیه‌سازی عملکرد گندم گردید که برای به جامعیت شناخت آن نیازمند استفاده و ارزیابی آن در سایر محدوده‌های مشابه است.

کلیدواژه‌ها: الگوریتم جستجوی خردگان، الگوریتم کرم شب‌تاب، امنیت غذایی، شبکه عصبی مصنوعی، محصولات دیم.

عملکرد محصولات کشاورزی به خصوص محصولات دیم نقش مهمی در برنامه‌ریزی و امنیت غذایی دارد. این پدیده تابع عوامل مختلفی مانند بارش، دما و نوع خاک است. شناخت تأثیر این عوامل بر میزان تولید محصولات، می‌تواند منجر به برنامه‌ریزی بهتر، جهت‌دهی به سیاست‌های کلان کشور و کاهش اثرات پدیده‌هایی مانند خشک سالی شود (Roselaar, 2020). علاوه بر این، درآمد کشاورزان نیز تحت تأثیر میزان تولید محصولات و عوامل اقلیمی قرار می‌گیرد. در ایران، کشت گندم دیم بیشتر در مناطقی که بارندگی سالیانه آن از ۲۵۰ میلی‌متر بیشتر است، انجام می‌شود. بیشترین سطح دیم‌کاری در ایران با بارندگی سالیانه بین ۲۵۰ تا ۴۰۰ میلی‌متر در طی ماه‌های (مهر - تا - خرداد) می‌باشد. در ایران، گندم با بیش از ۶ میلیون هکتار سطح زیر کشت، حدود ۵۶/۶ درصد از مساحت زمین‌های زراعی را به خود اختصاص داده است، که ۳۴/۲ درصد به صورت کشت آبی و ۶۵/۸ درصد این اراضی به صورت کشت دیم است (جعفری و همکاران، ۱۴۰۲). پیش‌بینی به موقع عملکرد محصول می‌تواند پشتیبانی از داده‌ها را برای انجام مدیریت مناسب برای کشاورزان فراهم کند (Zhao et al., 2022).

شبیه‌سازی عملکرد گندم دیم با استفاده از روش‌های محاسبات نرم و مدل‌های یادگیری ماشین از جمله رویکردهای نوین در کشاورزی هوشمند است (امیر عشایری و همکاران، ۱۴۰۴). از جمله مزایای این روش نسبت به سایر روش‌هایی مانند مدل‌های عددی و فیزیکی می‌توان به عدم نیاز به اطلاعات اساسی و زمین‌شناسی محدوده و زمان‌بر نبودن دوره مدل‌سازی اشاره کرد. در سال‌های اخیر، استفاده از روش‌های هوش مصنوعی نظیر شبکه عصبی مصنوعی^۱ (ANN)، جنگل تصادفی^۲ (RF) و شبکه‌های عصبی عمیق (DNN) به دلیل توانایی آن‌ها در مقابله با مسائل پیچیده و غیرخطی در مطالعات مختلف کشاورزی استفاده شده‌اند (Sinwar et al., 2020). یکی از شناخته‌شده‌ترین و متداول‌ترین این مدل‌ها، شبکه عصبی مصنوعی (ANN) می‌باشد، که الگوریتمی کارآمد در تحلیل سری‌های زمانی است و می‌تواند روابط و تعاملات غیرخطی پیچیده بین متغیرها را مدیریت کند (Lee et al., 2009). با این حال، در برخی موارد، این روش‌ها عملکرد قابل قبولی در پیش‌بینی از خود نشان نمی‌دهند که می‌تواند نگران‌کننده باشد (Kayhomayoon et al., 2022). به همین منظور در سال‌های اخیر، الگوریتم‌های بهینه‌سازی فرا ابتکاری به طور گسترده در مسائل بهینه‌سازی و افزایش دقت مدل‌های منفرد مانند ANN، ANFIS^۳ و SVR^۴ به کار گرفته شده است (Milan et al., 2021).

الگوریتم جستجوی خزندگان^۵ (RS) یکی از الگوریتم‌های فرا ابتکاری است که می‌تواند در مسائل بهینه‌سازی مورد استفاده قرار گیرد. این الگوریتم از نحوه رفتار محاصره و شکار کروکدیل‌ها الهام گرفته شده است که در زمینه بهینه‌سازی می‌تواند به محققان و مهندسان در بهبود عملکرد و دقت حل مسائل مختلف، کمک کند (Abualigah et al., 2022). یکی دیگر از الگوریتم‌های بهینه‌سازی، الگوریتم کرم شب‌تاب^۶ (FA) است که الهام گرفته از رفتار کرم‌های شب‌تاب واقعی در طبیعت است. توانایی این الگوریتم در جستجوی جهانی و بهبود کیفیت راه‌حل‌ها، آن را به ابزاری ارزشمند و ساده در مجموعه تکنیک‌های بهینه‌سازی تبدیل کرده است (Xin-She & Slowik, 2008). تحقیقات انجام شده نشان داده‌اند که ترکیب الگوریتم‌های بهینه‌سازی و مدل‌های منفرد موجب افزایش دقت پیش‌بینی سری‌های زمانی شده است. به عنوان مثال، در این زمینه می‌توان به پیش‌بینی خشک سالی (Malik et al., 2020)، پیش‌بینی تبخیر از مخازن سد با استفاده از الگوریتم‌های بهینه‌سازی PSO^۷ و HHO^۸ در ترکیب با مدل شبکه‌ی عصبی مصنوعی^۹ (Azar et al., 2022)، پیش‌بینی سطح آب زیرزمینی با استفاده از مدل‌های هیبریدی (Milan et al., 2021) و پیش‌بینی سیلاب (Ahmadi & Fard Moradnian, 2024) اشاره کرد. مدل‌های یادگیری ماشین

^۱Artificial Neural Network

^۲Random Forest

^۳Deep Neural Networks

^۴Adaptive Neuro-Fuzzy Inference System

^۵Support Vector Regression

^۶Reptile Search Algorithm

^۷Firefly Algorithm

^۸Harris Hawk Optimization

^۹Particle Swarm Optimization

(M) در تحقیقات مشابه با پیش‌بینی عملکرد محصول نیز با دقت قابل قبول مورد استفاده قرار گرفته‌اند (Rezapour et al., 2021; Zhao et al., 2022; Meraj et al., 2022).

در کنار مدل‌های مناسب پیش‌بینی، تکنیک سنجش از دور می‌تواند راه‌حل‌های دقیق‌تر و کم‌هزینه‌تری را نسبت به روش‌های مرسوم برای پیش‌بینی و مدل‌سازی محصولات کشاورزی و به‌خصوص گندم دیم که به عنوان محصولی استراتژیک است، ارائه دهد. Qader و همکاران (2018) برای پیش‌بینی عملکرد گندم و جو در عراق از شاخص‌های تفاضلی نرمال شده پوشش گیاهی (NDVI) و پوشش گیاهی تقویت‌شده (EVI) استفاده کردند. نتایج نشان داد که میزان خطای نسبی عملکرد گندم دیم با استفاده از شاخص‌های NDVI و EVI بین ۲۰- تا ۲۰+ درصد متغیر بود، همچنین نتایج نشان داد که دو شاخص مذکور تأثیر زیادی بر عملکرد گندم دارند. همچنین در تحقیقی دیگر Saenz و همکاران (2024) به بررسی برآورد عملکرد گندم دیم در سه استان مرکزی اسپانیا طی دوره ۲۰۱۹-۲۰۲۰ با استفاده از شاخص NDVI پرداختند. نتایج حاصل از این مطالعه نشان داد که بین عملکرد دیم و حداکثر شاخص NDVI بیشترین همبستگی وجود داشت. علاوه بر این، مدل‌هایی مانند مدل شبکه عصبی وزن‌دار جغرافیایی و زمانی (GTWNN) تو سطر Feng و همکاران (2021)، RF، SVM و ANN تو سطر Li و همکاران (۲۰۲۲) و مدل‌های RF، LASSO، SVM تو سطر Arshad و همکاران (2023) در پیش‌بینی عملکرد گندم مورد استفاده قرار گرفته است که نتایج امیدوارکننده‌ای به همراه داشته است.

در جنوب استان آذربایجان غربی به علت مناسب بودن شرایط اقلیمی، به‌خصوص در نواحی که شرایط خاک و شیب محدوده مطلوب است، کشت دیم صورت گرفته است. پیش‌بینی محصولات تولیدی در چنین شرایطی می‌تواند کمک مؤثری در تأمین نیازهای محدوده باشد. با توجه به موارد ذکر شده، این تحقیق با هدف ارائه شبیه‌سازی برای تخمین عملکرد گندم دیم در مقیاس مزرعه‌ای، در ۶۱ مزرعه از شهرستان‌های اشنویه، نقده و پیرانشهر واقع در جنوب استان آذربایجان غربی و بخش غربی حوضه دریاچه ارومیه که یکی از مهم‌ترین محدوده‌های شمال غرب ایران است، انجام شد. در این راستا، با ادغام شاخص‌های سنجش از دور و داده‌های اقلیمی، ورودی‌های مختلفی برای مدل تدوین گردید. علاوه بر این، از جنبه نوآوری این تحقیق می‌توان به به‌کارگیری الگوریتم‌های جستجوی خزندگان و کرم شب‌تاب در ترکیب با شبکه عصبی مصنوعی جهت بهبود دقت مدل‌سازی و مقایسه روش‌های ترکیبی اشاره نمود. با توجه به اهمیت راهبردی گندم دیم به عنوان یک محصول استراتژیک، مدل‌سازی و شبیه‌سازی دقیق عملکرد این محصول می‌تواند به بهبود و افزایش امنیت غذایی در کشور، کمک شایانی نماید.

مواد و روش‌ها

منطقه مورد مطالعه

استان آذربایجان غربی یکی از استان‌هایی است که در زمینه تولید و مصرف گندم سابقه دیرینه دارد. در کناره شرقی این استان، دریاچه ارومیه قرار دارد. این استان از نظر موقعیت جغرافیایی از شمال به جمهوری آذربایجان و ترکیه، از غرب به کشورهای ترکیه و عراق، از شرق به استان آذربایجان شرقی و استان زنجان و از جنوب به استان کردستان محدود است. محدوده مطالعاتی این پژوهش، بخش جنوبی استان آذربایجان غربی را در بر می‌گیرد که شامل شهرستان‌های اشنویه، پیرانشهر و نقده است؛ این نواحی در جنوب حوضه آبریز دریاچه ارومیه واقع شده‌اند. گندم جزء عمده‌ترین محصولات زراعی این شهرستان می‌باشد. شهرستان اشنویه در نیمه‌ی جنوبی استان آذربایجان غربی قرار دارد میانگین بارندگی شهرستان اشنویه حدود ۴۵۶ میلی‌متر است که ۷۰ درصد آن به پاییز و زمستان تعلق دارد. شهرستان پیرانشهر در جنوب استان آذربایجان غربی بین دو شهرستان اشنویه و سردشت در ضلع شمال غربی کشور قرار گرفته است. شهرستان پیرانشهر با میانگین بارش سالانه ۷۰۱

¹Machine Learning


²Normalized Difference Vegetation Index

³Enhanced Vegetation Index

⁴Support Vector Machine


⁵Least Absolute Shrinkage and Selection Operator

میلی‌متر است. شهرستان نقده نیز در جنوب استان آذربایجان غربی قرار دارد. میانگین بارندگی در نقده حدود ۳۳۰ میلی‌متر است. همچنین میانگین دما در شهرستان‌های پیرانشهر، اشنویه و نقده به ترتیب برابر با ۱۳/۷، ۱۱/۷ و ۱۲/۸ درجه سانتی‌گراد می‌باشد. در شکل (۱) موقعیت جغرافیایی شهرستان‌های اشنویه، پیرانشهر و نقده و پراکنش موقعیت‌های مزارع واقع در این سه شهرستان همچنین پراکنش ایستگاه‌های سینوپتیک مورد استفاده در این پژوهش نشان داده شده است. بارش در این سه شهرستان عمدتاً از اوایل پاییز آغاز شده و تا اواخر بهار ادامه می‌یابد. ماه‌های فروردین و اردیبهشت پر باران‌ترین ماه سال می‌باشند. در مقابل، دوره‌ی تابستان به‌ویژه از اواسط خرداد تا شهریور از نظر بارش بسیار خشک است. در اشنویه و پیرانشهر به دلیل ارتفاع بیشتر، احتمال بارش برف در فصل زمستان بیشتر از نقده است. زمستان‌های این مناطق سرد و نسبتاً طولانی بوده و در فصل تابستان، دمای هوا به شدت افزایش می‌یابد. مطابق طبقه‌بندی دوما رتن اصلاح شده، شهرستان‌های اشنویه و نقده دارای اقلیم نیمه خشک سرد و شهرستان پیرانشهر دارای اقلیم مرطوب سرد می‌باشند.



شکل ۱. موقعیت محدوده‌ی مورد مطالعه

تغییرات بارش روزانه در محدوده‌های مورد بررسی نشان می‌دهد که به طور کلی بارش در انتهای دوره مورد بررسی بعد از سال ۱۳۹۵ افزایش نسبی در هر سه شهرستان داشته است (شکل ۲). میانگین بارش در شهرستان پیرانشهر بیشتر از دو شهر دیگر و برابر با ۱/۹۶ میلی‌متر در روز می‌باشد. مقدار انحراف از معیار نیز برابر ۶/۸۲ میلی‌متر در روز می‌باشد. شهرستان نقده نیز از کم‌ترین بارش روزانه با میانگین کمتر از یک میلی‌متر در روز برخوردار است. این شهرستان همچنین دارای حداکثر دمای بیشتری نسبت به دو شهرستان دیگر است. در این شهرستان میانگین حداکثر دما برابر ۲۰/۰۸ درجه سانتی‌گراد است که از انحراف معیار ۱۰/۷۳ درجه سانتی‌گراد برخوردار است. اشنویه نسبت به دو شهرستان دیگر از دمای حداقل کمتری برخوردار است به طوری که میانگین حداقل دما و انحراف معیار آن به ترتیب برابر ۴/۷۶ و ۷/۹۵ درجه سانتی‌گراد است (شکل ۲).



شکل ۲. تغییرات روزانه بارش، دمای حداقل و حداکثر در سه شهرستان پیرانشهر، نقده و آشنویه

داده‌های مورد استفاده

در این پژوهش، دو مجموعه داده شامل داده‌های هواشناسی محدوده مورد مطالعه (سال‌های زراعی ۱۳۸۵-۱۳۸۴ تا ۱۴۰۳-۱۴۰۲) و برخی شاخص‌های سنجش از دور (شاخص NDVI و IPVI) به عنوان ورودی مدل‌ها مورد استفاده قرار گرفته‌اند، که در ذیل تشریح شده‌اند. به منظور تخصیص داده‌های اقلیمی ایستگاهی به مزارع، از مدل‌سازی رگرسیونی بین پارامترهای اقلیمی و ارتفاع استفاده شد. با توجه به تفاوت ارتفاعی بین مزارع و اثر شناخته‌شده ارتفاع بر پارامترهای اقلیمی، روابط رگرسیونی برازش داده شده برای هر پارامتر، امکان برآورد دقیق‌تری از شرایط اقلیمی محلی را فراهم نمود. به این ترتیب به جای استفاده از مقادیر تکراری ایستگاه‌ها، داده‌های اقلیمی خاص هر مزرعه بر اساس ارتفاع میانگین آن محاسبه و در فرآیند مدل‌سازی وارد شد. به منظور شبیه‌سازی عملکرد گندم در مزارع سه شهرستان آشنویه، پیرانشهر و نقده، داده‌های واقعی (مشاهدات مزرعه) مربوط به ۶۱ مزرعه در بازه‌ی آماری مذکور، از سازمان جهاد کشاورزی استان آذربایجان غربی جمع‌آوری گردید.

متغیرهای هواشناسی مورد استفاده به عنوان متغیرهای مستقل ورودی به مدل‌ها

پارامترهای هواشناسی مدنظر که در این مطالعه به عنوان متغیرهای مستقل در نظر گرفته شدند شامل مجموع بارش، میانگین حداکثر دما، میانگین دما، میانگین حداقل دما و میانگین رطوبت نسبی می‌باشند که از ایستگاه‌های سینوپتیک واقع در شهرستان‌های آشنویه، پیرانشهر و نقده استخراج گردیده است. لازم به ذکر است که برای استخراج پارامتر بارش از آمار ایستگاه‌های باران‌سنجی موجود در محدوده طرح نیز استفاده شده است. در هر یک از متغیرهای مذکور نواقص آماری موجود در داده‌های مربوط، با استفاده از روش‌های همبستگی نظیر میانگین‌گیری بازسازی شد. همان‌طور که در جدول (۱) ارائه شده است بیشترین و کمترین دمای متوسط در محدوده مطالعاتی مزارع سه شهرستان در فصل زراعی به ترتیب ۱۳/۰ و ۸/۲۸ درجه

سانتی گراد بوده است. در فصل زراعی بیشترین و کمترین مقدار بارش به ترتیب ۸۴۳/۵۶ و ۲۱۰/۲۳ میلی متر بوده است. که بیشترین بارش مربوط به مزارع نزدیک به شهرستان پیران شهر و کمترین بارش مربوط به مزارع نزدیک شهرستان نقده بوده است. میانگین متوسط رطوبت نسبی در محدوده مطالعاتی در فصل زراعی حدود ۶۰ درصد بوده است. همچنین عملکرد گندم دیم بین ۰/۶۸ و ۳/۲۰ تن بر هکتار متغیر بوده است. بیشترین عملکرد گندم دیم در سه شهرستان مانند بارش مربوط به مزارع شهرستان پیرانشهر می باشد.

جدول ۱. مشخصات پارامترهای هواشناسی آماری داده های مورد استفاده

پارامترهای هواشناسی	بیشترین	کمترین	میانگین	انحراف معیار
بارش (mm)	۸۴۳/۵۶	۲۱۰/۲۳	۵۵۵/۲۳	۱۲۴
میانگین حداکثر دمای فصل زراعی (°C)	۱۹/۶۴	۱۴/۰۲	۱۶/۸۸	۱/۱۱
میانگین حداقل دمای فصل زراعی (°C)	۷/۲۳	۱/۸۸	۴/۳۲	۱/۱۰
میانگین متوسط دمای فصل زراعی (°C)	۱۳/۰	۸/۲۸	۱۰/۶۰	۱/۰
میانگین متوسط رطوبت نسبی فصل زراعی (%)	۶۶	۵۴	۶۰	۲/۵۶
عملکرد گندم دیم (ton.ha ⁻¹)	۳/۲۰	۰/۶۸	۲/۱۸	۰/۴۰

شاخص های سنجش از دور

در این پژوهش، از دو شاخص NDVI و IPVI برای بررسی پوشش گیاهی منطقه مورد مطالعه استفاده شده است. محاسبه این شاخص ها با استفاده از تکنیک سنجش از دور و در محیط Google Earth Engine (GEE) انجام شد. برای استخراج شاخص های پوشش گیاهی طی سال های ۲۰۰۶ تا ۲۰۱۲ (۱۳۸۵ تا ۱۳۹۱) از تصاویر ماهواره لندست پنج و برای سال های ۲۰۱۳ تا ۲۰۲۴ (۱۳۹۲ تا ۱۴۰۳) از تصاویر ماهواره لندست هشت استفاده شد. تصاویر ماهواره ای مطابق با فصل رشد گندم در منطقه (ماه های مهر تا تیر) و با اعمال فیلتر ابری کمتر از ۱۰ درصد به منظور حذف پوشش ابری در منطقه انتخاب شدند. شاخص NDVI یکی از پرکاربردترین شاخص های طیفی برای ارزیابی وضعیت رشد و سلامت پوشش گیاهی است. این شاخص از ترکیب بازتاب باندهای قرمز و مادون قرمز نزدیک محاسبه می شود، که حساسیت بالایی به تغییرات زیست توده گیاهی دارد و با استفاده از رابطه (۱) قابل محاسبه است (Näsen et al., 2025).

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad \text{رابطه (۱)}$$

که در آن، NIR بازتاب در باند مادون قرمز نزدیک (باندهای ۴ و ۵ به ترتیب در ماهواره های لندست ۵ و ۸) و Red بازتاب در باند قرمز (باندهای ۳ و ۴ به ترتیب در ماهواره های لندست ۵ و ۸) می باشد. مقادیر NDVI در بازه ۱- تا ۱ قرار دارد. مقادیر نزدیک به ۱ نشان دهنده پوشش گیاهی متراکم و سالم، مقادیر نزدیک به صفر نشان دهنده خاک یا پوشش گیاهی ضعیف و مقادیر منفی نشان دهنده آب یا سایر سطوح غیرگیاهی است. شاخص IPVI یکی دیگر از شاخص های پوشش گیاهی است که رابطه نزدیکی با NDVI دارد اما محاسبه آن ساده تر است. این شاخص به صورت رابطه (۲) تعریف می شود (میرموسوی و همکاران، ۱۳۸۹):

$$IPVI = \frac{NIR}{NIR + Red} \quad \text{رابطه (۲)}$$

مقادیر این شاخص بین ۰ تا ۱ قرار دارد. مقدار نزدیک به ۱ نشان دهنده پوشش گیاهی متراکم و مقدار نزدیک به صفر بیانگر سطوح غیرگیاهی یا پوشش گیاهی ضعیف است. مزیت این شاخص در مقایسه با NDVI، عدم نیاز به تفاضل باندهای طیفی است که آن را کمتر وابسته به خطاهای اندازه گیری و کالیبراسیون حسگر می کند. با توجه به شباهت ساختاری و همبستگی بالای بین NDVI و IPVI، استفاده ترکیبی از این دو شاخص امکان تحلیل دقیق تری از تغییرات زیست توده گیاهی را فراهم می سازد. محاسبه شاخص ها با استفاده از باندهای استخراج شده و توابع محاسباتی در GEE انجام شد.

مدل سازی تخمین عملکرد گندم دیم

برای مدل سازی عملکرد گندم دیم پس از آماده سازی ورودی ها، ۷۵ درصد از داده ها برای مرحله آموزش و ۲۵ درصد باقی مانده

برای مرحله آزمون مورد استفاده قرار گرفتند. مجموعه داده‌های تدوین شده در ابتدا توسط شبکه عصبی اجرا و مقادیر عملکرد گندم دیم را شبیه‌سازی نمودند. در گام بعدی، عملکرد شبکه عصبی توسط دو الگوریتم تکاملی RSA و FFA بهینه گردید. در نتیجه عملکرد گندم دیم توسط مدل‌های ترکیبی ANN-RSA و ANN-FFA شبیه‌سازی شدند.

مدل‌های مورد استفاده

شبکه عصبی مصنوعی

برای ارزیابی عملکرد گندم دیم در این مطالعه، از شبکه عصبی مصنوعی با ساختار سه لایه میانی، که در هر لایه ۱۲ نورون قرار داشت، استفاده شد. برای آموزش ساختار شبکه عصبی مصنوعی از الگوریتم آموزشی لاوانبرگ-مارکوارت (LV et al., 2017) استفاده شد، به طوری که این الگوریتم به منظور نزدیکی سریع‌تر و عدم نیاز به سیکل‌های آموزشی بیشتر، نسبت به روش پس‌انتشار برتری دارد. همچنین حداکثر تعداد تکرار ۱۰۰۰۲ عدد در نظر گرفته شد. در ادامه الگوریتم‌های مورد استفاده به منظور بهبود آموزش شبکه عصبی مصنوعی تشریح شده‌اند.

الگوریتم بهینه‌سازی جستجوی خزندگان

الگوریتم جستجوی خزندگان به دلیل ترکیب خاص کاوش و بهره‌برداری^۴ یکی از الگوریتم‌های منحصربه‌فرد برای بهبود عملکرد و یافتن راه‌حل‌های بهینه در مقایسه با سایر الگوریتم‌های موجود است. این الگوریتم در سال ۲۰۲۲ توسط Abualigah و همکاران معرفی شد (Abualigah et al., 2022). راه‌حل‌های تصادفی ایجاد شده در این الگوریتم به صورت رابطه (۳) می‌باشد (AI- (Shourbaji et al., 2022; Elgarnal et al., 2022

$$x_{i,j} = rand_{\in[0,1]} \times (UB_j - LB_j) + LB_j \quad \text{for } i \in \{1, 2, \dots, N\} \text{ and } j \in \{1, 2, \dots, M\} \quad (\text{رابطه ۳})$$

که در آن، $x_{i,j}$ نامین راه‌حل ورودی j برای N راه‌حل‌هایی با ویژگی‌های M است، $rand_{\in[0,1]}$ یک عدد تصادفی تولید شده با محدوده توزیع یکنواخت $(0, 1)$ و ویژگی نامین با UB_j و LB_j به عنوان مرزهای بالا و پایین در نظر گرفته شده است. برای اتخاذ رفتار کروکودیل‌ها، یک فرآیند با چهار تکرار در نظر گرفته شده است. دو مرحله اول از تکرارها بر اساس کاوش برای عملکرد فراگیر، از جمله ترتیب‌های راه رفتن بالا و راه رفتن روی شکم استفاده می‌شود. کروکودیل‌ها برای شکار منطقه، شروع به گردش در مدار می‌کنند و امکان شکار جامع بیشتری از فضای راه‌حل را فراهم می‌کنند (شکل ۳). این فرآیند حلقه‌سازی را می‌توان به صورت ریاضی مدل‌سازی کرد (Abualigah et al., 2022) (رابطه ۴):

$$x_{i,j}(g+1) = \begin{cases} [-\eta_{i,j}(g) \cdot \gamma \cdot Best_j(g)] - [rand_{\in[1,N]} \cdot R_{i,j}(g)] & g \leq \frac{T}{4} \\ ES(g) \cdot Best_j(g) \cdot x_{(rand_{\in[1,N]}, j)} & \frac{T}{4} < g \leq \frac{2T}{4} \end{cases} \quad (\text{رابطه ۴})$$

که در آن، برای ویژگی نام، $Best_j(g)$ بهترین نتیجه است با نامین راه‌حل، $\eta_{i,j}$ عملگر شکار است. γ برای کنترل دقت اکتشاف استفاده می‌شود. همچنین $R_{i,j}(g)$ برای فشرده‌سازی و بهینه‌سازی فضای جستجو استفاده می‌شود. $rand_{\in[1,N]}$ برای تصادفی


^۱Backpropagation

^۲Number of iterations

^۳Exploration

^۴Exploitation

سازی راه‌حل‌های کاندید احتمالی و $ES(g)$ برای کاهش نسبت احتمال استفاده می‌شود. در آخرین مرحله تکرارها، مدل RSA از بهره‌برداری برای جستجوی فضای راه‌حل برای یافتن یک راه‌حل بهینه استفاده می‌کند، که مستقیماً به هماهنگی و همکاری شکار بستگی دارد، که در آن از معادله (۴) برای به‌روزرسانی بهینه‌ترین راه‌حل برای شکار استفاده می‌شود (AI-Shourbaji et al., 2022). تعداد تکرار در نظر گرفته شده ۳۰۰۰ تکرار بود و همچنین جمعیت اولیه ۲۰ خزنده در نظر گرفته شد. تعداد نوروں‌های در نظر گرفته شده نیز ۸ بود که ساختار الگوریتم RSA را تشکیل دادند. برای بررسی جزئیات بیشتر در مورد این الگوریتم می‌توانید به تحقیقات (A-Shourbaji et al., 2022; Abualigah et al., 2022) رجوع کنید.



شکل ۳. احاطه کردن طعمه: (الف) محاصره کردن طعمه، (ب) حمله به طعمه

الگوریتم بهینه‌سازی کرم شب‌تاب

الگوریتم FFA یک روش بهینه‌سازی مبتنی بر ازدحام هوشمند است که توسط (Yang XS, 2009) برای حل مسائل بهینه‌سازی توسعه داده شده است و رفتار اجتماعی کرم‌های شب‌تاب را شبیه‌سازی می‌کند. این الگوریتم از رفتار طبیعی کرم‌های شب‌تاب الهام گرفته است، که با استفاده از نور خود چشمک می‌زنند و هر نوع از کرم شب‌تاب، الگوی فلاش خاص خود را دارد. کرم‌های شب‌تاب از روشنایی خود برای برقراری ارتباط با یکدیگر، محافظت از خود در برابر شکارچیان و جذب طعمه استفاده می‌کنند. الگوریتم کرم شب‌تاب بر اساس دو عامل اصلی طراحی شده است (Yang XS, 2009): ۱. تغییر در شدت نور که به کرم‌های شب‌تاب اجازه می‌دهد به یکدیگر جذب شوند و ۲. جذابیت هر کرم شب‌تاب که تأثیرگذار در جلب توجه دیگران در فرآیند جستجو و بهینه‌سازی است. ارزش جذابیت یک کرم شب‌تاب بر اساس فاصله آن از سایر کرم‌های شب‌تاب تعیین می‌شود. برای محاسبه فاصله بین دو کرم شب‌تاب، موقعیت‌های مربوط به آن‌ها مطابق رابطه (۵) در نظر گرفته می‌شود (Yang XS, 2009):

$$r_{ij} = \|x_i - x_j\| \quad \text{رابطه (۵)}$$

که در آن، r_{ij} فاصله بین دو کرم شب‌تاب، x_i موقعیت شب‌تاب i ام و x_j موقعیت شب‌تاب j ام می‌باشد. سطح جذابیت نشان داده شده توسط کرم شب‌تاب مستقیماً با شدت نوری که از خود ساطع می‌کند، در ارتباط است. هنگامی که شدت نور کم می‌شود، سطح جذابیت نمایش داده شده توسط کرم شب‌تاب نیز کاهش می‌یابد. محاسبه جذابیت کرم شب‌تاب (β) با استفاده از رابطه (۶) محاسبه می‌شود:

$$\beta(r) = \beta_0 e^{-\gamma r^2} \quad \text{رابطه (۶)}$$

که در آن، $r = r_{ij}$ فاصله بین موقعیت‌های x_i و x_j و B_0 میزان جاذبیت برای $r=0$ است، همچنین γ ضریبی برای جذب رو شنایی است. حرکت لامین کرم شب‌تاب با جاذبیت آن نسبت به سایر کرم شب‌تاب مشخص می‌شود. اگر جاذبیت کرم شب‌تاب i از کرم شب‌تاب j کمتر باشد، کرم شب‌تاب i موقعیت خود را متناسب با آن تنظیم می‌کند. در واقع برای دو کرم شب‌تاب با رو شنایی متفاوت، کرم شب‌تاب با رو شنایی کمتر به سمت کرم شب‌تاب با رو شنایی بیشتر حرکت می‌کند. که معادله (۷) این تغییر موقعیت را نشان می‌دهد (Yang XS, 2009) :

$$x_i = x_i + \beta_0 e^{-\gamma r^2} (x_j - x_i) + \alpha (rand - \frac{1}{2}) \quad \text{(رابطه ۷)}$$

که در آن، Rand عدد تصادفی بین ۰ و ۱ است و α بین ۰ و ۱ که پارامترهای تصادفی سازی هستند. در الگوریتم کرم شب‌تاب حرکت کرم‌های شب‌تاب تحت تأثیر متغیرهای متفاوتی است. معادله (۷) شامل سه قسمت، موقعیت فعلی کرم شب‌تاب، رو شنایی کرم شب‌تاب و یک جزء حرکت تصادفی، زمانی که هیچ کرم شب‌تاب رو شنایی در نزدیکی وجود ندارد، می‌باشد. مکانیسم حرکت کرم شب‌تاب به طور مکرر تکرار می‌شود تا زمانی که یک شرط توقف برآورده شود. مناسب‌ترین کرم شب‌تاب نشان‌دهنده بهترین راه‌حل است، در واقع مزیت اصلی الگوریتم کرم شب‌تاب مکانیسم جذب آن و ساده بودن آن نسبت به سایر الگوریتم‌های بهینه‌سازی است، که در آن، حرکت مبتنی بر جاذبیت باعث می‌شود که ازدحام کرم شب‌تاب به طور خودکار به زیرگروه‌ها تقسیم شود و هر گروه حول یک راه‌حل بهینه جمع شوند. در نتیجه، FFA برای مسائل بهینه‌سازی چندوجهی و همچنین افزایش دقت مدل‌های هوشمند مصنوعی مناسب است، که نتایج تحقیقات انجام شده این را تأیید کرده‌اند (Yang & He, 2013; Katipoğlu et al., 2024; Osaba et al., 2017). سرعت همگرایی الگوریتم در رسیدن به یک راه‌حل رضایت‌بخش (محلی یا سراسری) به مقادیر اختصاص داده شده به پارامترهای α ، β_0 و γ بستگی دارد. ۲۵۰ تکرار برای رسیدن به دقت مناسب در نظر گرفته شده و جمعیت در نظر گرفته شده نیز ۳۰ کرم شب‌تاب بود. همچنین ۹ نبرون در نظر گرفته شد.

معیارهای ارزیابی خطا

به منظور ارزیابی نتایج حاصل از اجرای هر یک از مدل‌ها و الگوهای ورودی مختلف از هفت شاخص برای ارزیابی اثربخشی عملکرد مدل‌های محاسباتی نرم در دو مرحله توسعه (یعنی مراحل آموزش و آزمون) مربوط به ارزیابی عملکرد گندم دیم شامل ضریب همبستگی (R^2) (Bahmani et al., 2025)، جذر میانگین مربعات خطا ($RMSE$) (Sarafi et al., 2025)، ریشه میانگین مربعات خطای نرمال شده^۳ (NRMSE) (ضاوردی‌نژاد و همکاران، ۱۳۹۷) (میانگین خطای مطلق (MAE) (Min et al., 2021) ضریب تبیین^۵ (R^2) (Amirashayeri et al., 2023)، شاخص نش ساتکلیف^۶ (NSE) (Azar et al., 2023) و میانگین خطای درصدی مطلق ($MAPE$) (Maddam et al., 2021) استفاده گردید.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_o - x_p)^2}{n}} \quad 0 \leq RMSE \leq +\infty \quad \text{(رابطه ۸)}$$

$$NSE = 1 - \frac{\sum_{i=1}^n (x_o - x_p)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad -\infty \leq NSE \leq 1 \quad \text{(رابطه ۹)}$$

Correlation Coefficient

^۳Root Mean Square Error

^۴Normalized Root Mean Square Error

^۵Mean Absolute Error

^۶R- squared statistic (Coefficient of Determination; Pearson's r squared)

^۷Nash–Sutcliffe model efficiency coefficient

^۸Mean absolute percentage error

$$CC = \frac{\sum_{i=1}^n (x_p - \bar{x}_p)(x_o - \bar{x}_o)}{\sqrt{\sum_{i=1}^n (x_p - \bar{x}_p)^2 \sum_{i=1}^n (x_o - \bar{x}_o)^2}} \quad -1 \leq CC \leq 1 \quad \text{رابطه ۱۰}$$

$$MAE = \frac{\sum_{i=1}^n |x_o - x_p|}{n} \quad 0 \leq MAE \leq +\infty \quad \text{رابطه ۱۱}$$

$$R^2 = \left[\frac{\sum_{i=1}^n (x_p - \bar{x}_p)(x_o - \bar{x}_o)}{\sqrt{\sum_{i=1}^n (x_p - \bar{x}_p)^2 \sum_{i=1}^n (x_o - \bar{x}_o)^2}} \right]^2 \quad 0 \leq R^2 \leq 1 \quad \text{رابطه ۱۲}$$

$$MAPE = \frac{1}{n} \left(\sum_{i=1}^n \left| \frac{x_o - x_p}{x_o} \right| \right) \times 100 \quad 0 \leq MAPE \leq +\infty \quad \text{رابطه ۱۳}$$

$$NRMSE = \frac{RMSE}{\bar{x}_o} \times 100 \quad 0 \leq NRMSE \leq +\infty \quad \text{رابطه ۱۴}$$


در این روابط x_p و x_o به ترتیب آیین داده شبیه‌سازی شده توسط مدل و مقدار واقعی (مشاهده شده)، $\bar{x}_p$ و $\bar{x}_o$ به ترتیب میانگین کل داده‌های x_p و x_o در جامعه آماری و n تعداد نمونه‌ها است. مقدار محاسبه شده ضریب همبستگی (CC) میزان همبستگی بین دو متغیر وابسته را نشان می‌دهد که مقدار آن بین $+1$ و -1 می‌باشد. اگر مقدار به دست آمده مثبت باشد یعنی تغییرات دو متغیر به طور هم‌جهت اتفاق می‌افتد، ولی اگر ضریب همبستگی منفی شد یعنی دو متغیر در جهت عکس هم عمل می‌کنند، در صورتی که هیچ رابطه‌ای بین دو متغیر وجود نداشته باشد مقدار به دست آمده صفر خواهد شد. R^2 نشانگر ضریب تبیین بوده و مجذور ضریب همبستگی می‌باشد که بین صفر و $+1$ می‌باشد، هر چه ضریب مذکور به 1 نزدیک‌تر، نشان از مدل صحیح‌تر و منطبق‌تر می‌باشد (امیرعشایی و همکاران، ۱۳۹۹). همچنین، $RMSE$ برای اندازه‌گیری خطای دقت شبیه‌سازی مدل استفاده می‌شود که صفر تا یک عدد مثبت بزرگ ادامه می‌یابد و واحد آن از جنس متغیر خروجی مشاهداتی می‌باشد. MAE مقدار میانگین مثبت خطاها در یک مجموعه از مقادیر شبیه‌سازی شده را محاسبه می‌کند و واحد آن از جنس پارامتر خروجی مشاهداتی می‌باشد. مقدار این شاخص آماری معمولاً مشابه مقدار $RMSE$ می‌باشد. همچنین دامنه تغییرات کارایی نش-ساتکلیف (NSE) بین $+1$ و -1 می‌باشد. که هر چه این مقدار به $+1$ نزدیک‌تر، نشان دهنده مدل صحیح‌تر و منطبق‌تر می‌باشد. مقادیر $MAPE$ نیز از صفر تا بی نهایت می‌باشد که مقادیر کمتر آن نشان از عملکرد مناسب شبیه‌سازی می‌باشد. مقادیر بالا در پارامتر R^2 ، کم در $RMSE$ و $NRMSE$ و زیاد در NSE نشان دهنده عملکرد بالای مدل می‌باشد. مدل‌های مورد استفاده نیز همان‌طور که پیش‌تر بیان شده بود شامل ANN و مدل‌های توسعه داده شده آن توسط الگوریتم‌های فرا ابتکاری RSA و FEA می‌باشد. همچنین کدهای مدل‌های مذکور با استفاده از ورودی‌های مورد نظر انتخاب شده در محیط نرم افزار $MATLAB$ 2024a توسعه داده شدند.

نتایج و بحث

داده‌های ورودی به مدل‌ها

انتخاب متغیرهای ورودی مناسب برای مدل‌های هوشمند مصنوعی و روش‌های داده‌کاوی بسیار در عملکرد هر یک از مدل‌ها اثرگذار می‌باشد. از این‌رو، بر اساس مشاهدات تجربی و مطالعات سایر محققان از جمله متغیرهای ورودی مؤثر در شبیه‌سازی عملکرد گندم در یک حوضه آبریز می‌توان متغیرهای هواشناسی نظیر بارش، میانگین حداکثر دما، میانگین حداقل دما، میانگین متوسط دما، میانگین رطوبت نسبی، وزش باد و همچنین شاخص‌های سنجش از دور شامل $NDVI$ ، $IPVI$ که اثرگذاری قابل‌توجهی بر خروجی مدل‌ها دارند به عنوان متغیرهای مستقل به عنوان ویژگی‌های ورودی به مدل‌ها، استفاده نمود. شکل (۴) مقادیر ضریب همبستگی بین متغیرهای ورودی نسبت به یکدیگر و نسبت به مقادیر عملکرد گندم را نشان می‌دهد. بدین‌صورت که محورهای افقی و عمودی متغیرهایی که بر عملکرد گندم تأثیر می‌گذارند قرار دارند. سپس ضریب همبستگی بین آن‌ها محاسبه شده است. میزان همبستگی به صورت طیف رنگی مشخص شده است. همان‌طور که مشاهده می‌گردد بیش‌ترین ضریب همبستگی نسبت به مقادیر عملکرد گندم مربوط به متغیر مجموع بارش (Precipitation) است که بیش‌ترین همبستگی (0.718) را با داده

عملکرد گندم داریم. همچنین میانگین دمای حداقل ($T_{\min}$) و متوسط میانگین دما (T_{avg}) نیز از همبستگی بالایی برخوردار هستند (به ترتیب برابر ۰/۴۵۶ و ۰/۳۴۶۵). در حالی که عملکرد گندم نسبت به میانگین دمای حداکثر ($T_{\max}$) از همبستگی کمتری نسبت به دمای حداقل و متوسط دما برخوردار هستند. این نشان می‌دهد که در مزارع منطقه‌ی مورد مطالعه میانگین حداکثر دمای فصل زراعی تأثیر کمتری نسبت به عملکرد گندم دارد. همچنین شاخص‌های سنجش از دور NDVI و IPVI به ترتیب (۰/۳۲۰ و ۰/۳۹۶) از همبستگی خوبی نسبت به عملکرد گندم برخوردار بودند که همبستگی IPVI نسبت به NDVI بالاتر بود. همچنین ضرایب همبستگی نشان می‌دهد که هیچ یک از متغیرهای مورد بررسی، رابطه عکس با عملکرد گندم ندارد. با این حال نتایج بررسی نشان می‌دهد که میانگین رطوبت نسبی کمترین همبستگی (۰/۰۵۸) را با عملکرد گندم دارد. در نتیجه با توجه به اطلاعات موجود در این شکل بیش مناسبی از نحوه‌ی ترکیب متغیرهای ورودی به مدل‌ها جهت شبیه‌سازی عملکرد گندم داریم بیان می‌کند.



شکل ۴. مقادیر ضریب همبستگی بین متغیرهای ورودی و خروجی عملکرد گندم (Heat map)


عملکرد گندم داریم با استفاده از پارامترهای هواشناسی مجموع بارش، دما (حداقل، میانگین) و پارامترهای سنجش از دور (شاخص‌های NDVI و IPVI) با استفاده از مدل ANN و ترکیب آن با الگوریتم‌های بهینه‌سازی RSA و FFA شبیه‌سازی شد. مقادیر شاخص‌های آماری مدل‌ها جهت شبیه‌سازی عملکرد گندم برای مرحله‌ی آموزش و آزمون در جدول (۲) ارائه شده است. در مرحله اول، مطابق نتایج به دست آمده از دو مرحله آزمون و آموزش، این استنباط وجود دارد که مدل‌های مورد استفاده عملکرد قابل قبولی در شبیه‌سازی عملکرد گندم داشته‌اند. مقایسه بین مدل‌های منفرد با ترکیبی نشان می‌دهد که مدل‌های ترکیبی در حالت کلی از دقت شبیه‌سازی بالایی برخوردار بوده‌اند، به عبارتی می‌توان گفت، الگوریتم‌های آموزش‌دهنده در مدل‌های ترکیبی با استفاده از یک الگوریتم بهینه‌ساز، تقویت شده و باعث بهینه کردن پارامترهای مدل در مرحله آموزش شده و داده‌های خروجی را با دقت بیشتری شبیه‌سازی کرده است. مدل شبکه عصبی مصنوعی مرحله آموزش و آزمون را تقریباً با دقت یکسانی تخمین زده است، شاخص‌های ارزیابی خطا شامل: R^2 ، RMSE، NRMSE، MAE، MAPE و NSE به ترتیب ۰/۶۳۸، ۰/۲۳۱، تن بر هکتار، ۱۰/۱ درصد، ۰/۱۸۴

تن بر هکتار، ۸/۵ درصد و ۰/۷۹۹ در این مدل برای مرحله آزمون، به دست آمده است. به طوری که مدل ANN-FFA با معیارهای $RMSE=0/187(ton.ha^{-1})$, $MAPE=7/1(\%)$, $MAE=0/145(ton.ha^{-1})$, $R^2=0/786$, $CC=0/887$, $NSE=0/786$ ($NRMSE=8/3(\%)$), $RMSE=0/189(ton.ha^{-1})$ و برای مرحله آموزش ($MAE=0/150(ton.ha^{-1})$, $R^2=0/758$, $CC=0/870$, $NSE=0/750$, $RMSE=0/190(ton.ha^{-1})$, $MAPE=6/9(\%)$, $NRMSE=8/3(\%)$) با معیارهای ANN-RSA مدل انجام داده است. برای مرحله آزمون، دقت نزدیکی به مدل ANN-FFA داشته است. در واقع استفاده از دو الگوریتم RSA و FFA باعث افزایش دقت مدل شبکه عصبی مصنوعی در مرحله آموزش مدل شده است، به طوری که در مرحله آموزش ترکیب روش ANN با الگوریتمهای RSA و FFA به ترتیب باعث ارتقا شاخص ضریب تبیین به میزان ۱۳/۸۸ و ۱۷/۳۱ درصد و همچنین در مرحله آزمون به میزان ۱۷/۲۴ و ۱۸/۸۰ درصد گردید. در نتیجه با توجه به نتایج به دست آمده در دو بخش آموزش و آزمون می توان به این نکته اشاره کرد که عملکرد الگوریتمها خصوصاً الگوریتم FFA در بهبود دقت ANN مناسب بوده است.


جدول ۲. نتایج ارزیابی عملکرد مدل های پیشنهادی با ترکیب داده های هواشناسی و شاخص های سنجش از دور

مدل ها	R^2	MAPE (%)	RMSE ($ton.ha^{-1}$)	NRMSE (%)	MAE ($ton.ha^{-1}$)	NSE	CC
مرحله آموزش							
ANN	۰/۶۷۰	۹/۲	۰/۲۳۳	۱۰/۹	۰/۱۸۲	۰/۶۶۷	۰/۸۱۸
ANN-RSA	۰/۷۶۳	۸/۱	۰/۲۰۱	۹/۴	۰/۱۶۵	۰/۷۵۱	۰/۸۷۳
ANN-FFA	۰/۷۸۶	۷/۱	۰/۱۸۷	۸/۷	۰/۱۴۵	۰/۷۸۶	۰/۸۸۷
مرحله آزمون							
ANN	۰/۶۳۸	۸/۵	۰/۲۳۱	۱۰/۱	۰/۱۸۴	۰/۶۳۸	۰/۷۹۹
ANN-RSA	۰/۷۴۸	۶/۹	۰/۱۹۰	۸/۳	۰/۱۵۰	۰/۷۴۷	۰/۸۶۵
ANN-FFA	۰/۷۵۸	۶/۶	۰/۱۸۹	۸/۳	۰/۱۵۰	۰/۷۵۰	۰/۸۷۰

شکل های (۵) و (۶) نحوه پراکندگی مقادیر عملکرد گندم دیم مشاهده شده و شبیه سازی شده توسط مدل منفرد ANN و مدل های ترکیبی ANN-FFA و ANN-RSA را در مرحله آموزش و آزمون نشان می دهد. مشاهدات نشان می دهد که داده ها در اطراف خط ۴۵ درجه متمرکز شده و پراکندگی کمتری در مدل های هیبریدی مشاهده می گردد. یکی از ویژگی های اصلی نمودار پراکندگی بررسی پدیده Over-estimation و Under-estimation است، که در واقع تخمین رو به بالا داده های عملکرد گندم دیم و یا تخمین رو به پایین آن می باشد. مقدار ضریب همبستگی به دست آمده برای مدل ANN-FFA ($CC=0/887$) و همچنین تراکم بالای داده ها در اطراف خط رگرسیون نشان می دهد که این مدل دقت بیشتری در شبیه سازی مرحله آموزش برای عملکرد گندم دیم داشته است، اما در شبیه سازی داده های آزمون دو مدل ANN-RSA و ANN-FFA با ضرایب همبستگی به ترتیب ۰/۸۶ و ۰/۸۷ عملکرد بهتری نسبت به مدل منفرد داشته است. این مقادیر نشان می دهند که عملکرد مدل های هیبریدی مناسب بوده است، همچنین باعث افزایش دقت مدل در دو مرحله آموزش و آزمون نسبت به مدل منفرد شده است.




شکل ۵. مقادیر همبستگی داده‌های مشاهداتی و شبیه‌سازی شده با مدل‌های یادگیری ماشین - مرحله آموزش، (ضریب همبستگی: CC)



شکل ۶. مقادیر همبستگی داده‌های مشاهداتی و شبیه‌سازی شده با مدل‌های یادگیری ماشین - مرحله آزمون، (ضریب همبستگی: CC)




در ادامه مقایسه مدل‌ها، از نمودار (Ridge line) برای تجسم توزیع داده‌های شبیه‌سازی شده با مدل‌های یادگیری ماشین و داده‌های مشاهده‌ای در مرحله آزمون استفاده شد، که نتایج آن در شکل (۷) ارائه شده است. در شکل مربوط به مرحله آزمون اگرچه هر سه مدل مقادیر کمینه و بیشینه را تا حدودی شبیه هم تخمین زده‌اند، اما شکل توزیع داده‌ها در محدوده ۱/۵ تا ۳ تن بر هکتار متفاوت از داده‌های مشاهداتی است. شکل مدل ANN-FFA به داده‌های مشاهداتی نزدیک‌تر است. در واقع مدل‌های ترکیبی تا حد زیادی

این مقادیر را متناسب با داده‌های مشاهداتی برآورد کرده‌اند، اما مدل منفرد این مقادیر را با مقدار کمتری برآورد کرده است. همچنین شکل توزیع داده‌های مدل‌های ترکیبی به شکل توزیع داده‌های مشاهداتی نزدیک‌تر و هم‌خوانی بیشتری دارند، که نشان از دقت شبیه‌سازی مدل‌های ترکیبی نسبت به مدل منفرد ANN می‌باشد.



شکل ۷. دیاگرام Ridgeline داده‌های مشاهداتی و شبیه‌سازی شده

مقادیر داده‌های شبیه‌سازی شده توسط هر مدل و اندازه‌گیری شده میدانی در شکل (۸) قابل مشاهده است. روند تغییرات مقادیر شبیه‌سازی شده نشان می‌دهد که تشخیص روند تغییرات عملکرد گندم دیم توسط مدل‌های هیبریدی مناسب بوده است. مقادیر پایه (در محدوده کمتر از میانگین داده‌ها) به خوبی توسط مدل‌های هیبریدی شبیه‌سازی شده است. اما در روش مدل شبکه عصبی مصنوعی در محدوده بین ۴۰۰ تا ۶۰۰ عدم تطابق مناسبی بین دو مجموعه داده مشاهداتی و شبیه‌سازی شده مشاهده می‌گردد. در مدل‌های هیبریدی در این محدوده‌ها همان‌طور که مشخص است با دقت مناسب‌تری نسبت به مدل منفرد ANN تخمین زده شده‌اند. کمینه مقادیر توسط مدل منفرد ANN به خوبی شبیه‌سازی نشده است که این مشکل تا حدودی توسط الگوریتم RSA بهبود یافته است اما الگوریتم FFA توانسته آن را بهتر نسبت به الگوریتم RSA بهبود بخشد. که عملکرد مناسب این مدل ترکیبی را نسبت به مدل‌های ارائه شده نشان می‌دهد. در نتیجه از مشاهدات نتایج چنین استنباط می‌گردد که عملکرد مدل‌های هیبریدی در شبیه‌سازی عملکرد گندم دیم مناسب بوده است.



شکل ۸. نمودار سری زمانی داده‌های مشاهداتی و شبیه‌سازی شده

از مهم‌ترین یافته‌های این تحقیق می‌توان به بهبود دقت مدل شبیه‌سازی برای عملکرد گندم دیم اشاره کرد، که برای سایر محدوده‌های مشابه می‌تواند مورد استفاده قرار گیرد. علاوه بر این، استفاده از الگوریتم‌های فرا ابتکاری جدید در شبیه‌سازی عملکرد گندم دیم می‌تواند به عنوان یک گام مؤثر برای استفاده از محاسبات نرم در کشاورزی و امنیت غذایی تلقی گردد. همچنین با استفاده از این رویکرد می‌توان یک سامانه هوشمند تصمیم‌یار ایجاد نمود تا با کمک متغیرهای هواشناسی میزان گندم تولیدی دیمی را برای سال بعد تخمین زد. این عمل می‌تواند یک دید روشن‌تری به کشاورزی جهت تولید و سود حاصل از آن در سال بعد را تخمین زند. به علاوه، مدیران اجرایی نیز می‌توانند یک دید مناسبی از تولید گندم دیم برای سال بعد داشته باشند که منجر به اتخاذ تصمیم مناسب‌تر جهت امنیت غذایی منطقه خواهد شد.

این مطالعه نقش مهم یادگیری ماشین و ترکیب با الگوریتم‌های بهینه‌ساز فرا ابتکاری را در بهبود تصمیم‌گیری‌های کشاورزی برجسته می‌کند و رویکردی ساده و دقیق برای شبیه‌سازی عملکرد به منظور حمایت از تولید پایدار غذا ارائه می‌دهد. نتایج خروجی نشان‌دهنده این است که مدل‌های هوشمند مصنوعی و به خصوص شبکه عصبی مصنوعی-الگوریتم‌های فرا ابتکاری بر اساس پارامترهای هواشناسی محدوده، توانایی خوبی در شبیه‌سازی و مدل‌سازی عملکرد گندم دیم دارد. این نتایج با نتایج تحقیق جعفری و همکاران (۱۴۰۲) که از مدل‌های مختلف شبکه عصبی برای تخمین عملکرد گندم دیم استفاده کرده بود، هم‌خوانی دارد. نتایج حاصل از این تحقیق نشان داد که با در نظر گرفتن اطلاعات هواشناسی و در کنار آن اطلاعات برخی از شاخص‌های سنجش از دور می‌توان دقت شبیه‌سازی مناسبی از عملکرد گندم دیم داشت. مشابه تحقیقاتی که پیش‌تر توسط Arshad و همکاران (2023) در استفاده از برخی شاخص‌های سنجش از دور در پیش‌بینی عملکرد گندم، Ahmed و همکاران (2025) در استفاده از برخی شاخص‌های سنجش از دور در پیش‌بینی عملکرد گندم داشتند و با نتایج تحقیق حاضر هم‌خوانی دارد. این امر می‌تواند در کاهش هزینه جمع‌آوری اطلاعات و آماربرداری بسیار مفید باشد. چرا که با چنین اطلاعات در دسترس اندازه‌گیری آن‌ها با هزینه کمتری انجام می‌گردد. بر اساس نتایج این تحقیق مشاهده شد که عملکرد گندم دیم در مناطق مطالعاتی، بیشترین تأثیر را از بارش و دما دارد که عوامل مذکور را می‌توان به عنوان مهم‌ترین متغیرهای هواشناسی در شبیه‌سازی عملکرد گندم دیم ذکر کرد. استفاده از مدل‌های ترکیبی نشان داد که الگوریتم‌های فرا ابتکاری ابزارهای مناسبی هستند که می‌توانند موجب بهبود عملکرد شبیه‌سازی‌ها توسط مدل‌های یادگیری منفرد گردند. در تحقیقاتی که انجام شده است، محققان (Kayhomayoon et al., 2025; Bahmani et al., 2025)، به ترتیب در پیش‌بینی جریان رودخانه و همچنین شاخص خشکسالی، به این نتیجه رسیده‌اند که الگوریتم‌های فرا ابتکاری در ساختار مدل‌های منفرد نظیر ANN، ANFIS و SVR قادر هستند تا دقت مدل‌ها را از یک مقدار فراتر ببرند. همچنین این الگوریتم‌ها در نقاط کمینه محلی و سراسری به دام نمی‌افتند و به همگرایی سریع می‌رسند؛ به همین دلیل نتایجی که ارائه می‌دهند دارای عملکرد قابل قبول هستند. برای این منظور می‌توان به نتایج تحقیقات شرفی و همکاران (۱۴۰۳) برای مدل‌سازی و پیش‌بینی عملکرد گندم و Azar و همکاران (2023) در استفاده از مدل‌های هیبریدی ANN-GWO جهت پیش‌بینی تبخیر از مخازن سدها اشاره کرد. نتایج تحقیقات ذکر شده نشان دادند که الگوریتم‌های بهینه‌ساز فرا ابتکاری به طور قابل توجهی ضعف‌های مدل‌های منفرد را پوشش می‌دهند. همچنین نتایج این تحقیق نشان داد که الگوریتم کرم شب‌تاب علی‌رغم ساختار ساده‌تر نسبت به الگوریتم جستجوی جزندگان که جدیدتر است؛ اما دقت مناسب‌تری در شبیه‌سازی عملکرد گندم دیم داشت. لذا به نظر می‌رسد که تحقیقات بیشتر در این زمینه برای رسیدن به مناسب‌ترین مدل جهت شبیه‌سازی و مدل‌سازی مورد نیاز است. همچنین عملکرد مدل‌ها با توجه به مکان‌ها و زمان‌های مختلف متغیر است که پیشنهاد می‌گردد رویکرد پیش رو در سایر محدوده‌ها مورد ارزیابی قرار گیرد تا کارایی آن به صورت جامع‌تر اثبات گردد.

نتیجه‌گیری

در این تحقیق از مدل شبکه عصبی مصنوعی و دو الگوریتم بهینه‌ساز RSA و FFA برای افزایش دقت آموزش مدل شبکه عصبی مصنوعی برای بررسی عملکرد گندم دیم در شهرستان‌های استان آذربایجان غربی استفاده شد. از ادغام پارامترهای اقلیمی و سنجش از دور که شامل پارامترهای مجموع بارش فصل زراعی، میانگین حداقل دمای فصل زراعی، میانگین متوسط دمای فصل

زراعی و دو شاخص سنجش از دور NDVI و IPVI به عنوان ورودی مدل‌ها استفاده شد. نتایج بیانگر عملکرد مناسب مدل‌های ترکیبی ANN-FFA و ANN-RSA نسبت به مدل منفرد ANN بود. در بین الگوریتم‌ها نیز عملکرد FFA بهتر از RSA بود. ترکیب پارامترهای هواشناسی و شاخص‌های سنجش از دور به عنوان ورودی مدل‌ها مناسب ارزیابی شد. عملکرد مدل‌های هیبریدی در شبیه‌سازی عملکرد گندم به‌تر از مدل منفرد ANN تشخیص داده شد. در این مدل‌ها ANN-FFA توانست نتایج بهتری نسبت به مدل‌های دیگر ارائه دهد. از محدودیت‌های این تحقیق می‌تواند به عدم در نظر گرفتن داده‌های فیزیکی و مکان‌دار اراضی مورد بررسی اشاره کرد. همچنین در این تحقیق عدم قطعیت در نتایج و داده‌ها در نظر گرفته نشده بود، همچنین تحلیل حساسیت متغیرهای ورودی به مدل‌ها در این تحقیق صورت نگرفته بود که از طریق آن می‌توان به ویژگی‌های مهم توسط برخی روش‌ها مانند آزمون گامانست به آن دست یافت، لذا در تحقیقات آتی به عنوان چشم‌انداز این تحقیق می‌تواند در نظر گرفته شود.

منابع

امیر عشایری، امین؛ بهمنش، جواد؛ رضا وردی نژاد، وحید و فتح اله زاده، نسرين (۱۳۹۹). پیش‌بینی تبخیر- تعرق مرجع روزانه با استفاده از روش ترکیبی هوشمند مصنوعی بر پایه الگوریتم پیش‌پردازش‌کننده تجزیه مد تجزیه. *نشریه آبیاری و زهکشی ایران*، ۱۴(۴)، ۱۳۹۰-۱۳۷۶.

امیر عشایری، امین؛ رضاوردی نژاد، وحید؛ بهمنش، جواد؛ اسدزاده، فرخ و رحیمی، مینا (۱۴۰۴). مدل سازی و پیش‌بینی عملکرد گندم دیم براساس متغیرهای هواشناسی با استفاده از روش‌های ترکیبی هوش مصنوعی. *نشریه آبیاری و زهکشی ایران*، ۱۹(۲)، ۲۴۳-۲۶۱.

جعفری، محمد مهدی؛ لیاقت، عبدالمجید و محتشمی، سهیلا (۱۴۰۲). مقایسه و ارزیابی الگوریتم‌های BRLM و GD شبکه عصبی مصنوعی در برآورد عملکرد گندم دیم براساس پارامترهای هواشناسی (مطالعه موردی: استان کرمانشاه). *نشریه آبیاری و زهکشی ایران*، ۱۷(۳)، ۵۲۹-۵۴۴.

رضاوردی نژاد، وحید؛ رحیمی، مینا؛ و اسدزاده، فرخ (۱۳۹۷). ارزیابی کیفیت آب چشمه‌های استان آذربایجان غربی از نظر پتانسیل گرفتگی گسیلنده‌ها در سامانه‌های آبیاری قطره‌ای. *دانش آب و خاک*، ۲۸(۴)، ۱۵۳-۱۴۱.

شرفی، میلاد؛ بهمنش، جواد؛ رضاوردی نژاد، وحید و صمدیان فرد، سعید (۱۴۰۳). ارزیابی و مقایسه مدل AquaCrop و مدل‌های هوشمند جهت پیش‌بینی عملکرد گندم (مطالعه موردی: شهرستان‌های میاندوآب و مهاباد). *دانش آب و خاک*، ۳۴(۱)، ۱-۱۸.

میر موسوی، سید حسین؛ بابایی، غالب و کریمی، ستار (۱۳۸۹). برآورد سطح پوشش گیاهی با استفاده از شاخص‌های مختلف تصاویر ماهواره‌ای و مقایسه‌ی آنها با شاخص جهانی NDVI در حوضه قشلاق-سندج. *اندیشه جغرافیه*، ۴(۷)، ۸۸-۶۶.

References

Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W., & Gandomi, A. H. (2022). Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*, 191, 116158.

Ahmadi, N., & Fard Moradinia, S. (2024). An approach for flood flow prediction utilizing new hybrids of ANFIS with several optimization techniques: a case study. *Hydrology Research*, 55(5), 560-575.

Ahmed, N., Mahmood, S. A., Haseeb, M., Tahir, Z., & Batool, S. (2025). Enhancing food security: machine learning-based wheat yield prediction using remote sensing and climate data in Pakistan. *Theoretical and Applied Climatology*, 156(5), 1-19.

Al-Shourbaji, I., Kachare, P. H., Alshathri, S., Duraibi, S., Elnaim, B., & Abd Elaziz, M. (2022). An efficient parallel reptile search algorithm and snake optimizer approach for feature selection. *Mathematics*, 10(13), 2351.

Amirashayeri, A., Behmanesh, J., Rezaverdinejad, V., & Fathollahzadeh Attar, N. (2020). Prediction of daily reference evapotranspiration using hybrid artificial intelligence method based on empirical mode decomposition. *Iranian Journal of Irrigation & Drainage*, 14(4), 1376-1390. (In Persian)

Amirashayeri, A., Behmanesh, J., Rezaverdinejad, V., & Fathollahzadeh Attar, N. (2023). Evapotranspiration estimation using hybrid and intelligent methods. *Soft Computing*, 27(14), 9801-9821.

- Amirashayeri, A., Rezaverdinejad, V., Behmanesh, J., Asadzadeh, F., & Rahimi, M. (2025). Modeling and forecasting rainfed wheat yield based on meteorological variables using combined Artificial intelligence methods. *Iranian Journal of Irrigation & Drainage*, 19(2), 243-261. (In Persian)
- Arshad, S., Kazmi, J. H., Javed, M. G., & Mohammed, S. (2023). Applicability of machine learning techniques in predicting wheat yield based on remote sensing and climate data in Pakistan, South Asia. *European Journal of Agronomy*, 147, 126837.
- Azar, N. A., Kardan, N., & Milan, S. G. (2023). Developing the artificial neural network–evolutionary algorithms hybrid models (ANN–EA) to predict the daily evaporation from dam reservoirs. *Engineering with Computers*, 39(2), 1375-1393.
- Bahmani, M. J., Kayhomayoon, Z., Milan, S. G., Hassani, F., Malekpoor, M., & Berndtsson, R. (2025). Development of a new hybrid model to enhance streamflow estimation using artificial neural network and reptile search algorithm. *Scientific Reports*, 15(1), 6098.
- Elgamal, Z., Sabri, A. Q. M., Tubishat, M., Tbaishat, D., Makhadmeh, S. N., & Alomari, O. A. (2022). Improved reptile search optimization algorithm using chaotic map and simulated annealing for feature selection in medical field. *IEEE Access*, 10, 51428-51446.
- Feng, L., Wang, Y., Zhang, Z., & Du, Q. (2021). Geographically and temporally weighted neural network for winter wheat yield prediction. *Remote Sensing of Environment*, 262, 112514.
- Jafari, M. M., Liaghat, A., & Mohtashami, S. (2023). Comparison and Evaluation of LM, BR and GD Algorithms of Artificial Neural Network in Estimating Rainfed Wheat Yield Based on Meteorological Parameters (Case Study: Kermanshah Province). *Iranian Journal of Irrigation & Drainage*, 17(3), 529-544. (In Persian)
- Katipoğlu, O. M., Ertugay, N., Elshaboury, N., Aktürk, G., Kartal, V., & Pande, C. B. (2024). A novel metaheuristic optimization and soft computing techniques for improved hydrological drought forecasting. *Physics and Chemistry of the Earth, Parts A/B/C*, 135, 103646.
- Kayhomayoon, Z., Bahmani, M. J., Ghordoyee Milan, S., Bazrafshan, O., & Berndtsson, R. (2025). Integration of the reptile search algorithm and the adaptive neuro-fuzzy inference system enhances standardized precipitation evapotranspiration index forecasting. *Scientific Reports*, 15(1), 14647.
- Kayhomayoon, Z., Ghordoyee-Milan, S., Jaafari, A., Arya-Azar, N., Melesse, A. M., & Moghaddam, H. K. (2022). How does a combination of numerical modeling, clustering, artificial intelligence, and evolutionary algorithms perform to predict regional groundwater levels? *Computers and Electronics in Agriculture*, 203, 107482.
- Lee, C. M., & Ko, C. N. (2009). Time series prediction using RBF neural networks with a nonlinear time-varying evolution PSO algorithm. *Neurocomputing*, 73(1-3), 449-460.
- Li, L., Wang, B., Feng, P., Li Liu, D., He, Q., Zhang, Y., Wang, Y., Li, S., Lu, X., Yue, C., & Li, Y. (2022). Developing machine learning models with multi-source environmental data to predict wheat yield in China. *Computers and Electronics in Agriculture*, 194, 106790.
- Lv, C., Xing, Y., Zhang, J., Na, X., Li, Y., Liu, T., Cao, D., & Wang, F.Y. (2017). Levenberg–Marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system. *IEEE Transactions on Industrial Informatics*, 14(8), 3436-3446.
- Malik, A., Kumar, A., Salih, S. Q., Kim, S., Kim, N. W., Yaseen, Z. M., & Singh, V. P. (2020). Drought index prediction using advanced fuzzy logic model: Regional case study over Kumaon in India. *Plos one*, 15(5), e0233280.
- Meraj, G., Kanga, S., Ambadkar, A., Kumar, P., Singh, S.K., Farooq, M., Johnson, B.A., Rai, A. & Sahu, N. (2022). Assessing the yield of wheat using satellite remote sensing-based machine learning algorithms and simulation modeling. *Remote Sensing*, 14(13), 3005.
- Milan, S. G., Roozbahani, A., Azar, N. A., & Javadi, S. (2021). Development of adaptive neuro fuzzy inference system–Evolutionary algorithms hybrid models (ANFIS-EA) for prediction of optimal groundwater exploitation. *Journal of hydrology*, 598, 126258.
- Mirmousavi, H., Babaei, G., & Karimi, S. (2010). Estimate the Amount of Vegetation Cover Using Different

Indicators in Satellite Images and Comparing Them with the Index NDVI in the Region of Geshlag – Sanandaj. *Geographic Thought*, 4(7), 66-88. (In Persian)

Moghaddam, H. K., Milan, S. G., Kayhomayoon, Z., & Azar, N. A. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environ Monit Assess*, 193(4), 1-20.

Nelsen, T. S., Hegarty, J., Tamagno, S., & Lundy, M. E. (2025). NDVI-based ideotypes as a cost-effective tool to support wheat yield stability selection under heterogeneous environments. *Field Crops Research*, 322, 109727.

Osaba, E., Yang, X. S., Diaz, F., Onieva, E., Masegosa, A. D., & Perallos, A. (2017). A discrete firefly algorithm to solve a rich vehicle routing problem modelling a newspaper distribution system with recycling policy. *Soft Computing*, 21(18), 5295-5308.

Qader, S. H., Dash, J., & Atkinson, P. M. (2018). Forecasting wheat and barley crop production in arid and semi-arid regions using remotely sensed primary productivity and crop phenology: A case study in Iraq. *Science of the total Environment*, 613, 250-262.

Raza, A., Shahid, M.A., Zaman, M., Miao, Y., Huang, Y., Safdar, M., Maqbool, S., & Muhammad, N.E. (2025). Improving Wheat Yield Prediction with Multi-Source Remote Sensing Data and Machine Learning in Arid Regions. *Remote Sensing*, 17(5), 774.

Rezapour, S., Jooyandeh, E., Ramezanzade, M., Mostafaeipour, A., Jahangiri, M., Issakhov, A., Chowdhury, S. & Techato, K. (2021). Forecasting rainfed agricultural production in arid and semi-arid lands using learning machine methods: A case study. *Sustainability*, 13(9), 4607.

Rezaverdinejad, V., Rahimi, M., & Asadzadeh, F. (2018). Evaluation of Springs Water Quality of West Azerbaijan Province in Terms of Emitters Clogging Potential in Drip Irrigation Systems. *Water and Soil Science*, 28(4), 141-153. (In Persian)

Roselaar, S. (2020). Agriculture in republican Italy. *A Companion to Ancient Agriculture*, 417-430.

Sáenz, C., Bermejo-Saiz, A., Cicuéndez, V., Pugni, T., Madruga, D., Palacios-Orueta, A., & Litago, J. (2024). Estimation and Prediction of Cereal Production Using Normalized Difference Vegetation Index Time Series (Sentinel-2) Data in Central Spain. *Engineering Proceedings*, 68(1), 26.

Sharafi, M., Amirashayeri, A., Behmanesh, J., Rezaverdinejad, V., & Heidari, H. (2025). Predicting Daily Soil Temperature at 50 Cm Depth Using Advanced Hybrid and Combined Models in Semi-Arid Regions. *Communications in Soil Science and Plant Analysis*, 1-18.

Sharafi, M., Behmanesh, J., Rezaverdinejad, V., & Samadianfard, S. (2024). Evaluation and comparison of AquaCrop model and intelligent models to predict wheat yield (Case study: Miandoab and Mahabad cities). *Journal of Soil and Plant Science*, 34(1), 1-18. (In Persian)

Sinwar, D., Dhaka, V. S., Sharma, M. K., & Rani, G. (2020). AI-based yield prediction and smart irrigation. *Internet of Things and Analytics for Agriculture*, Volume 2, 155-180.

Xin-She, Y., & Slowik, A. (2008). Firefly algorithm. *Nature-inspired metaheuristic algorithms*, 20, 79-90.

Yang XS, 2009. Firefly algorithms for multimodal optimization. *International Symposium on Stochastic Algorithms* 17(1), 169-178.

Yang, X. S., & He, X. (2013). Firefly algorithm: recent advances and applications. *International journal of swarm intelligence*, 1(1), 36-50.

Zhao, Y., Xiao, D., Bai, H., Tang, J., Liu, D. L., Qi, Y., & Shen, Y. (2022). The prediction of wheat yield in the North China Plain by coupling crop model with machine learning algorithms. *Agriculture*, 13(1), 99.

ویدئو استثنای نقشه