

Research Article

Evaluation and Comparison of AquaCrop Model and Intelligent Models to Predict Wheat Yield (Case study: Miandoab and Mahabad cities)

M Sharafi¹, J Behmanesh^{2*}, V Rezaverdinejad³, S Samadianfard⁴

Received: October 28, 2021

Accepted: May 22, 2022

Revised: April 17, 2022

Published online: March 20, 2024

1- M.Sc. student, Dept. of Water Eng., Faculty of Agric., Urmia University, Iran

2, 3-Prof., Dept. of Water Eng., Faculty of Agric., Urmia University, Iran

4- Assoc. Prof., Dept. of Water Eng., Faculty of Agric., University of Tabriz, Iran

* Corresponding Author, E-mail: j.behmanesh@urmia.ac.ir

Abstract

Background and Objectives

Due to population growth and Iran's location in arid and semi-arid regions of the world, the need for water and food has increased and as a result, the pressure on water and soil resources will be more than before. On the other hand, the risk of drying up Lake Urmia, which causes environmental problems in the region, requires macro-water planning for the region and the use of optimal cultivation pattern to deal with water scarcity. Therefore, optimal use of water preserves water resources and increases the quality of products. Today more than ever, increasing the production of strategic crops such as wheat requires the proper use of water resources. The main source of food for the Iranian people is wheat and related products, and any action that increases the yield of wheat due to limited soil resources, especially water resources, is important and necessary at the same time. In recent years, significant advances have been made in modeling product growth and development using mechanical models. Plant growth models are increasingly used in the analysis of agricultural systems and simulate the plant's response to growth factors using mathematical equations. The AquaCrop model is one of the dynamic and user-friendly models developed by the FAO. The AquaCrop model receives information about farm, plant, soil, irrigation and climate, and ultimately predicts important parameters such as crop. Wheat yield simulation allows efficient management and better planning under various environmental inputs such as soil and water. To achieve higher accuracy and less model error, field parameters must be properly calibrated by the model to achieve proper performance. Also, calibration of the model, if not done correctly, causes a high error prediction by the model, which leads to incorrect management, water loss, plant drought and other cases. Therefore, using a model that has accurate and close prediction to the AquaCrop model and requires fewer input parameters is essential, which saves time, reduces costs and eliminates calibration errors. However, this model requires relatively large input parameters and is a time-consuming model in the presence of multiple scenarios.

Methodology

In recent years, smart models have been able to show high accuracy and become reliable models. Therefore, in the present study, to solve this problem and develop a model with less input data, using the ANN, SVR and SVR-FFA intelligent models and creating 440 scenarios in 2 farms, the performance of the AquaCrop model was compared 99WestW2 farm which is located in Miandoab city and has a yield of 6.588 (ton ha⁻¹) and WestW10 farm is located in Mahabad city and has a yield of 5.05 (ton ha⁻¹).

Findings

The results of the model are performed using 5 evaluation criteria of Correlation coefficient, Root mean square error, Nash-Sutcliffe coefficient, Wilmot's index of agreement and, Mean absolute percentage error. The results of this study showed that for both 99WestW2 and WestW10 farms, the SVR-FFA3 model could have the lowest error rate, so that for the yield index, the RMSE value for the mentioned farms was 0.033



and 0.069 (ton ha⁻¹), respectively. The use of three models SVR, SVR-FFA, and ANN and their comparison with the AquaCrop model to predict wheat yield has been done for the first time in this study. The SVR model was able to show the highest accuracy after the SVR-FFA model. For 99WestW2 farm, it can reduce the error rate to 0.043 (ton ha⁻¹) and for WestW10 farm to 0.077 (ton ha⁻¹) and show good performance. The ANN model, after the SVR model, was able to show acceptable accuracy. The ANN model for 99WestW2 farm was able to reduce the error rate to 0.123 (ton ha⁻¹) and for WestW10 farm to 0.094 (ton ha⁻¹). Finally, the ANN model had a relatively higher error than the SVR-FFA and SVR models, respectively, and showed a relatively lower performance than the two models.

Conclusion

Finally, the intelligent SVR-FFA, SVR and ANN models, despite having the least number of inputs, were able to predict yield values in the shortest time and with the highest accuracy. However, the results showed that the lower the model inputs, the weaker the model prediction. For further studies, it is suggested that the ANN model be combined using the firefly algorithm (MLP-FFA) to increase the accuracy of the ANN model and make more accurate predictions of wheat yield.

Keywords: Aquaculture, Crop yield, Sustainable agriculture, Wheat

مقاله پژوهشی

ارزیابی و مقایسه مدل AquaCrop و مدل‌های هوشمند جهت پیش‌بینی عملکرد گندم (مطالعه موردی: شهرستان‌های میاندوآب و مهاباد)

میلاذ شرفی^۱، جواد بهمنش^{۲*}، وحید رضاوردی‌نژاد^۳، سعید صمدیان‌فرد^۴

تاریخ دریافت: ۱۴۰۰/۰۸/۰۶

تاریخ پذیرش: ۱۴۰۱/۰۳/۰۱

تاریخ ویرایش: ۱۴۰۱/۰۱/۲۸

تاریخ انتشار آنلاین: ۱۴۰۳/۰۱/۰۱

۱- دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۲ و ۳- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

۴- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

* مسئول مکاتبات، پست الکترونیکی: j.behmanesh@urmia.ac.ir

چکیده

امروزه بیش از هر زمان دیگری افزایش تولید محصولات استراتژیک مانند گندم نیاز به استفاده صحیح از منابع آب دارد. مدل AquaCrop یکی از مدل‌های پویا و کاربرپسند بوده که توسط سازمان خواروبار جهانی فائو توسعه داده شده است. اما این مدل به پارامترهای ورودی نسبتاً زیادی نیاز داشته و در صورت وجود سناریوهای متعدد، مدلی وقت‌گیر می‌باشد. در تحقیق حاضر برای رفع این مشکل و توسعه مدلی با داده‌های ورودی کمتر، با استفاده از مدل‌های هوشمند شبکه عصبی مصنوعی (ANN)، رگرسیون بردار پشتیبان (SVR) و رگرسیون بردار پشتیبان هیبرید شده با الگوریتم بهینه‌سازی کرم شب‌تاب (SVR-FFA) و با ایجاد ۴۴۰ سناریو در ۲ مزرعه عملکرد مدل AquaCrop مقایسه گردید. مزارع WestW10 و 99WestW2 به ترتیب در شهرستان‌های میاندوآب و مهاباد واقع گردیده و عملکرد (ton ha⁻¹) و ۶/۵۸۸ (ton ha⁻¹)^۱ را داشته‌اند. نتایج اجرای مدل‌ها با استفاده از ۵ معیار مورد ارزیابی قرار گرفت. نتایج این تحقیق نشان داد که برای هر دو مزرعه 99WestW2 و WestW10 مدل SVR-FFA3 توانست کمترین میزان خطا را داشته باشد، به طوری که برای شاخص عملکرد، مقدار RMSE برای مزارع مذکور به ترتیب (ton ha⁻¹) ۰/۰۳۳ و (ton ha⁻¹) ۰/۰۶۹ به دست آمد. مدل‌های SVR و ANN نیز پس از مدل SVR-FFA توانستند عملکرد مناسبی را از خود نشان دهند. در نهایت مدل‌های هوشمند SVR-FFA، SVR و ANN با وجود کمترین تعداد ورودی قادر به پیش‌بینی مقادیر عملکرد در کمترین زمان و با بیشترین دقت بوده‌اند. در هر حال، نتایج نشان داد هر چه ورودی‌های مدل‌ها کمتر شود، پیش‌بینی مدل‌ها نیز ضعیف‌تر خواهد بود.

واژه‌های کلیدی: کشاورزی پایدار، گندم، عملکرد محصول، AquaCrop

مقدمه

گزارش کنوانسیون بین المللی حفاظت از گیاهان نشان می‌دهد که تغییرات آب‌وهوایی بر اکوسیستم‌ها و بخش‌های مختلف جامعه تأثیر منفی می‌گذارد (چنج، ۲۰۰۷). تأثیر منفی تغییر اقلیم و خشکسالی، که منجر به تغییر الگوهای آب‌وهوا و سایر عوامل مرتبط می‌شود، می‌تواند عملکرد را کاهش داده و در نتیجه خطرات تولید محصول را افزایش دهد. (سویی و همکاران ۲۰۱۵؛ کبیو و همکاران ۲۰۱۶). تحقیقات صورت‌گرفته نشان داده است که کشاورزی بیش‌ترین آسیب‌پذیری را در برابر کم‌آبی دارد، به‌ویژه در کشورهای در حال توسعه که به‌شدت به منابع زیست‌محیطی خود متکی هستند (یگیمی و همکاران ۲۰۱۳). ایران کشوری در حال توسعه بوده و بیش از ۷۵ درصد از مساحت آن به‌عنوان خشک یا نیمه‌خشک طبقه‌بندی شده است (شیفته و همکاران ۲۰۱۳). مدل‌های رشد محصول نقش بسزایی در مدیریت کشاورزی هوشمند دارند. این مدل‌ها نه تنها اطلاعات کمی در مورد توسعه محصول ارائه می‌کنند، بلکه استراتژی‌های مدیریتی مختلف را نیز ارزیابی می‌کنند (ژانگ و همکاران ۲۰۱۹). در سال‌های اخیر، پیشرفت‌های قابل توجهی در مدل‌سازی رشد و توسعه محصول با استفاده از مدل‌های مکانیکی صورت گرفته است (آرایا و همکاران ۲۰۲۲؛ قو و همکاران ۲۰۲۲؛ قوارین و اسنگ ۲۰۲۲؛ هولزورث و همکاران ۲۰۱۵؛ ما و همکاران ۲۰۲۲). یکی از مدل‌هایی که توسط سازمان خواربار و کشاورزی (FAO) در سازمان ملل، با هدف بهبود تولید محصول برای مناطقی که با کمبود آب مواجه هستند، توسعه داده است، مدل AquaCrop می‌باشد (استدیوتو و همکاران ۲۰۰۹). مدل AquaCrop در تحقیقات متعددی در مناطق مختلف، به شبیه‌سازی محصول گندم پرداخته است. ژانگ و همکاران، در مطالعه‌ای به مدل‌سازی با AquaCrop جهت یافتن آبیاری بهینه گندم زمستانه برای بهبود عملکرد دانه و

بهره‌وری آب با ۶۲۵ سناریو، این مدل را مورد بررسی قرار دادند. نتایج این تحقیق نشان داد که مدل AquaCrop مدل قابل اعتمادی برای آشکار کردن رشد و تولید محصول در شرایط کمبود آب بوده است (ژانگ و همکاران ۲۰۲۲). با توسعه مدل‌های هوش مصنوعی در سال‌های اخیر، مجموعه‌ای از الگوریتم‌های شبکه عصبی مصنوعی به‌وجود آمده‌اند (نگوین و همکاران ۲۰۲۱). این مدل‌ها به‌طور گسترده‌ای در پیش‌بینی، ساخت مدل، شبیه‌سازی پویا و تشخیص الگو استفاده می‌شوند (فن و ژانگ ۲۰۲۲). یکی از مدل‌های قابل اعتماد و توانمند، رگرسیون بردار پشتیبان (SVR^1) می‌باشد که در مطالعات مختلفی مورد استفاده قرار گرفته است (کارگر و همکاران ۲۰۲۰؛ مالکارچونا راثو و همکاران ۲۰۲۲؛ ورما ۲۰۲۰). همچنین یکی از مدل‌های بهینه‌سازی ارزشمند، مربوط به نظریه مفهومی کرم شبتاب (FFA^2) می‌باشد، که توسط یانگ در سال ۲۰۱۰ ارائه شده، براساس شیوه چشمک‌زن شبتاب‌ها است (یانگ ۲۰۱۰). FFA با موفقیت در مطالعات مختلف استفاده شده است (قربانی و همکاران ۲۰۱۷؛ موزن‌زاده و همکاران ۲۰۱۸). از سوی دیگر، روش‌های پیش‌بینی محاسباتی مورد اعتماد به‌طور قابل توجهی مانند شبکه عصبی مصنوعی (ANN^3)، به‌کار گرفته شده است (کمری و همکاران ۲۰۱۶؛ کریم و همکاران ۲۰۱۸). به‌عنوان یکی از جالب‌ترین کاربردهای ANN می‌توان به پیش‌بینی عملکرد محصول اشاره کرد. پیش‌بینی عملکرد گندم در تحقیق‌های بسیاری از محققین به‌کار رفته است (گوپتا ۲۰۲۱؛ نیدبالا ۲۰۱۹). با توجه به اهمیت بالای گندم به‌عنوان محصولی استراتژیک و نیز اهمیت مدل‌های گیاهی و هوش مصنوعی در مدل‌سازی این محصول، بایستی توجه ویژه‌ای به مدیریت مناسب آب در مزارع انجام گیرد. از سوی دیگر خطر خشک شدن

¹ Support vector regression

² Firefly Optimization Algorithm

³ Artificial neural network

تحقیق برای اولین بار به مقایسه مدل گیاهی AquaCrop با مدل‌های هوشمند SVR، SVR-FFA و ANN پرداخته است. لذا هدف از این تحقیق، ارزیابی و مدل‌سازی رشد گندم در برآورد پارامترهای آب و گیاه می‌باشد.

ارزیابی توانایی روش‌های داده محور در مدل‌سازی رشد گیاهی و برآورد پارامترهای آب و گیاه گندم در شهرستان‌های میاندوآب و مهاباد طی سال‌های زراعی ۱۳۹۹-۱۳۹۸ و ۱۴۰۰-۱۳۹۹ انجام گردیده است. برای انجام این تحقیق از داده‌های ۲ مزرعه به نام‌های 99WestW2 و WestW10 استفاده شده است. مزرعه 99WestW2 در شهرستان میاندوآب و مزرعه WestW10 در شهرستان مهاباد واقع می‌باشند.

دریاچه ارومیه که باعث ایجاد مشکلات زیست‌محیطی در سطح منطقه می‌گردد، نیازمند برنامه‌ریزی کلان آبی برای منطقه و استفاده از الگوی کشت بهینه برای مقابله با کم‌آبی است. لذا استفاده بهینه از آب موجب حفظ منابع آبی و افزایش کیفیت محصولات می‌شود. این مواد و روش‌ها

منطقه مورد مطالعه

داده‌های این تحقیق از نتایج اجرای پروژه "همکاری در احیای دریاچه ارومیه با مشارکت جوامع محلی در استقرار کشاورزی پایدار" در شهرستان‌های میاندوآب و مهاباد واقع در استان آذربایجان غربی اخذ گردیده است. این مطالعه در مقیاس مزرعه و برای

جدول ۱ نیز مشخصات فیزیکی و شیمیایی خاک مزارع مورد مطالعه را نشان می‌دهد.

جدول ۱- مشخصات فیزیکی و شیمیایی خاک مزارع مورد مطالعه.

مزرعه	عمق (cm)	رس	شن	سیلت	شوری EC (dS m ⁻¹)	بافت	اسیدیته pH
99WestW2	۰-۳۰	۳۴	۱۳	۵۳	۲/۱۶	Silty clay	۷/۹۶
West10	۰-۳۰	۱۸	۳۸	۴۴	۱/۵۳	Loam	۸/۰۵

ادامه جدول ۱- مشخصات فیزیکی و شیمیایی خاک مزارع مورد مطالعه.

مزرعه	رطوبت اشباع (cm ³ .cm ⁻³) θ _s	بذر مصرفی (Kg ha ⁻¹)	کربن آلی OC (%)	FC (cm ³ cm ⁻³)	PWP (cm ³ cm ⁻³)	جرم مخصوص ظاهری (g cm ⁻³)
99WestW2	۰/۴۸	۲۲۰	۱/۲۵	۰/۳۱۸	۰/۱۲۵	۱/۲۷
West10	۰/۴۱۶	۳۰۰	۱/۳۶	۰/۲۸۲	۰/۰۸۴	۱/۳

(یزدان‌سپاس و همکاران ۲۰۱۱). جدول ۲ نتایج کلی پایش آبیاری در مزارع گندم مورد مطالعه را نشان می‌دهد. این جدول دارای اطلاعات مفیدی درباره‌ی مساحت مزرعه، تاریخ کاشت و برداشت، تعداد نوبت آبیاری، میزان آبیاری و درنهایت تاریخ آبیاری می‌باشد.

در این تحقیق از گندم میهن به عنوان وارسته مورد نظر استفاده شد. متوسط عملکرد دانه این رقم در شرایط آبیاری نرمال، ۷۷۸۰ کیلوگرم در هکتار و در شرایط تنش آبی (قطع آبیاری پس از مرحله گلدهی)، ۵۹۶۰ کیلوگرم در هکتار در شرایط تحقیقاتی بوده است

جدول ۲- خلاصه اطلاعات مزارع گندم.

WestW10	99WestW2	مزرعه	
۰/۴۳	۰/۹۰	مساحت مزرعه (ha)	
۹۹/۰۸/۲۶	۹۸/۸/۲۵	تاریخ کشت	
۱۴۰۰/۰۴/۱۴	۹۹/۴/۱۵	تاریخ برداشت	
۳	۴	تعداد نوبت آبیاری	
۷۴/۱۲	۱۴۱/۵	عمق آبیاری (mm)	آبیاری اول
۱۴۰۰/۰۱/۲۵	۹۸/۸/۲۹	تاریخ آبیاری	
۹۳/۲۴	۱۶۸/۱	عمق آبیاری (mm)	آبیاری دوم
۱۴۰۰/۰۲/۲۰	۹۹/۲/۲۰	تاریخ آبیاری	
۲۵۸/۰۲	۲۸۵/۳	عمق آبیاری (mm)	آبیاری سوم
۱۴۰۰/۰۳/۱۱	۹۹/۰۳/۰۹	تاریخ آبیاری	
-	۲۷۷/۳	عمق آبیاری (mm)	آبیاری چهارم
-	۹۹/۳/۲۸	تاریخ آبیاری	

عملکرد به عنوان خروجی مدل نشان داده شده‌اند. منظور از درصد مقدار آبیاری در شکل ۱، مقدار درصدی از آبیاری موجود در جدول ۲ برای هر مزرعه می‌باشد. همچنین منظور از آب سهل‌الوصول نسبتی از حد بالای آب قابل استفاده گیاه در خاک می‌باشد که به راحتی قابل جذب بوده و گیاه در آن دچار تنش رطوبتی نشده و در نتیجه حداکثر رشد و عملکرد را خواهد داشت.

همچنین مشخصات شیمیایی منابع آب مورد استفاده برای مزارع 99WestW2 و WestW10 به ترتیب مقادیر ۷/۱۰ و ۶/۹۸ برای pH و ۱/۲۸ و ۱/۰۵ (m^{-1}) (dS) برای EC می‌باشد.

این مطالعه با هدف ارزیابی توانایی روش‌های داده محور در مدل‌سازی رشد گیاهی و برآورد پارامترهای آب و گیاه گندم انجام شده است. برای دستیابی به دقت بالای مدل AquaCrop، این مدل به داده‌های ورودی نسبتاً زیادی نیاز دارد. برای حل این مشکل می‌توان مدل‌های هوشمند را به کار برد. برای سنجش و ارزیابی مدل‌های هوشمند در مقایسه با مدل AquaCrop بایستی این مدل را با سناریوهای مختلفی اجرا نمود. در این تحقیق برای هر مزرعه مدل AquaCrop ۲۲۰ بار با سناریوهای مختلف و در مجموع به تعداد ۴۴۰ بار برای هر دو مزرعه اجرا گردید. شکل ۱ نحوه ترکیب پارامترهای مقدار آبیاری، آب سهل‌الوصول^۱ و بذر مصرفی به عنوان ورودی مدل و پارامتر

¹ Readily available water



شکل ۱- سناریوهای مورد استفاده در مدل AquaCrop.

گیاه براساس پوشش تاج از رابطه ۳ محاسبه می‌شود (راس و همکاران ۲۰۰۹):

$$Tr = K_s \times CC \times K_c \times ET_0 \quad [3]$$

که در آن، K_s و K_c به ترتیب ضرایب تنش آبی و گیاهی هستند. زیست‌توده طبق رابطه ۴ برآورد می‌شود:

$$B = WP^* \times \sum_{i=1}^n \left(\frac{Tr}{ET_0} \right) \quad [4]$$

که در آن، Tr مقدار کل تعرق روزانه در طول فصل زراعی، WP^* بهره‌وری آب (زیست‌توده ناشی از هر واحد تعرق تجمعی)، ET_0 تبخیر و تعرق گیاه مرجع و B عملکرد زیست‌توده است (راس و همکاران ۲۰۰۹).

در مدل AquaCrop عملکرد از رابطه ۵ حاصل می‌شود.

$$Y = f_{HI} \times HI_0 \times B \quad [5]$$

که در آن f_{HI} ضریب اصلاحی شاخص برداشت در شرایط تنش آبی، HI_0 شاخص برداشت پایه و B زیست‌توده تولیدی می‌باشد.

در جهت تطبیق نتایج مدل AquaCrop با مقادیر واقعی اندازه‌گیری شده، پارامترهای ورودی مدل به گونه‌ای تنظیم شدند که عملکرد دانه پیش‌بینی شده توسط مدل AquaCrop با عملکرد دانه اندازه‌گیری شده

معرفی مدل AquaCrop

اساس تخمین عملکرد محصول در مدل AquaCrop رابطه زیر است (دورنبوس و کسام ۱۹۷۹).

$$\left(\frac{Y_x - Y_a}{Y_x} \right) = K_y \left(\frac{ET_x - ET_a}{ET_x} \right) \quad [1]$$

در رابطه ۱، Y_x و Y_a به ترتیب مقدار بیشینه و واقعی عملکرد محصول، ET_x و ET_a به ترتیب مقدار بیشینه و واقعی تبخیر-تعرق گیاه و K_y ضریب نسبی میزان کاهش محصول نسبت به کاهش تبخیر-تعرق است. این مدل با تفکیک تبخیر و تعرق (ET) به دو جزء تبخیر از سطح خاک (E) و تعرق از سطح گیاه (Tr)، از مصرف غیرتولیدی آب از طریق تبخیر جلوگیری می‌کند. این عمل با شبیه‌سازی پوشش تاج گیاه به جای شاخص سطح برگ (LAI^1) انجام می‌شود. بدین ترتیب که توسعه پوشش تاج گیاه از زمان جوانه‌زنی تا مقدار بیشینه پوشش تاج از رابطه ۲ محاسبه می‌شود (راس و همکاران ۲۰۰۹):

$$CC = CC_0 \times e^{CGC.t} \quad [2]$$

در این رابطه، CC پوشش تاج در مرحله توسعه گیاه (%، CC_0 پوشش تاج اولیه (%، CGC ضریب رشد پوشش تاج (day^{-1}) و t زمان (day) است. میزان تعرق

¹ Leaf area index

شده حداقل شود. در ادامه مدل با استفاده از تیمارهای مختلف بذر مصرفی و مقدار آبیاری اجرا گردید. نتایج مقادیر اصلاح شده پارامترهای گیاهی گندم در جدول ۳ آورده شده است (فاتح ۲۰۰۹).

کمترین اختلاف را داشته باشند. در واقع مدل با تغییر برخی از پارامترهای حساس که در مزرعه اندازه گیری نشده بودند (حداکثر سطح پوشش (CCX)، بهره‌وری آب نرمال شده (WP*) و ...) واسنجی گردید. به طوری که خطای نسبی بین عملکرد اندازه‌گیری شده و شبیه‌سازی

جدول ۳- پارامترهای گیاهی به‌کاررفته در مدل AquaCrop برای شبیه‌سازی عملکرد دانه گندم.

پارامتر گیاهی	مقدار مورد استفاده	مقدار پیش فرض	واحد	روش تعیین
دمای پایه رشد (Tbase)	۰	۰	°C	پیش فرض
حد بالای دما (Tupper)	۲۶	۲۶	°C	پیش فرض
ضریب کاهش پوشش تاجی (CDC)	۳/۱	۷/۲	% .day ⁻¹	واسنجی
ضریب تعرق گیاهی برای پوشش کامل (x.KcTr)	۱/۱	۱/۱	% .day ⁻¹	پیش فرض
حداکثر پوشش گیاهی (CCx)	۱۰۰	۹۶	%	واسنجی
آستانه بالای تخلیه رطوبتی خاک برای رشد رویشی (Pupper)	۰/۲	۰/۲	-	پیش فرض
آستانه پایینی تخلیه رطوبتی خاک برای رشد رویشی (PLower)	۰/۷	۰/۷	-	پیش فرض
فاکتور شکل منحنی برای ضریب تنش روزنه‌ای (fshaper)	۵	۵	-	پیش فرض
آستانه بالایی تخلیه رطوبتی خاک برای ضریب تنش پیری (Pupper)	۰/۷	۰/۷	-	پیش فرض
فاکتور شکل منحنی برای ضریب تنش پیری (fshaper)	۲/۵	۲/۵	-	پیش فرض
شاخص برداشت مرجع (HI ₀)	۳۶	۳۸	%	واسنجی
پوشش کانوپی اولیه در زمان تکمیل ۹۰ درصد سبز شدن (CC)	۱/۵	۱/۵	cm ²	پیش فرض
ماکزیم عمق ریشه	۱/۳	۱/۵	m	واسنجی
مینیم عمق ریشه	۰/۳	۰/۴	m	واسنجی
ضریب رشد پوشش تاجی (CGC)	۳	۴/۹	% .day ⁻¹	واسنجی
ضریب بهره‌وری آب نرمال شده (WP*)	۱۶	۱۵	g.m ⁻²	واسنجی

رگرسیون بردار پشتیبان (SVR¹)

اولین کاربرد این روش در مسائل آب را برای شبیه‌سازی بارش-رواناب گزارش کردند (دیبیک و همکاران ۲۰۰۱). ماشین بردار پشتیبان از اصل استقرای کمینه‌سازی خطای ساختاری استفاده می‌کند و به یک جواب کلی منجر می‌شود (اسکندری و همکاران، ۲۰۱۲). در واقع می‌توان گفت که ماشین بردار پشتیبان سیستم یادگیری کارآمدی است که به‌منظور رسیدن به یک جواب بهینه از اصل استقرای کمینه‌سازی خطای ساختاری استفاده می‌کند (شرفی و همکاران ۲۰۲۱). مدل SVM یک الگوریتم محاسبات نرم تحت نظارت

است که همزمان خطاهای برآورد و پیچیدگی مدل را به حداقل می‌رساند (بنیمام و همکاران ۲۰۲۰). در یک مدل رگرسیونی ماشین بردار پشتیبان لازم است وابستگی تابعی متغیر وابسته y به مجموعه‌ای از متغیرهای مستقل x تخمین زده شود (هامل ۲۰۱۱).

$$y = f(x) + Noise \quad [6]$$

بنابراین موضوع اصلی، پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که ماشین بردار پشتیبان تاکنون تجربه نکرده است، پیش‌بینی کند، تابع خطا در روش رگرسیون بردار پشتیبان که به‌صورت گسترده در مسائل رگرسیونی

¹ Support vector regression

الگوریتم بهینه‌سازی کرم شب‌تاب (FFA³)

الگوریتم کرم شب‌تاب اولین بار توسط یانگ ارائه شد که رفتار اجتماعی کرم شب‌تاب را شبیه‌سازی می‌کند (یانگ ۲۰۰۹). سه قانون اساسی برای این الگوریتم ایجاد شده است (کومار سریواستوا و سینگ ۲۰۱۶؛ یانگ ۲۰۰۹): ۱- هر کرم شب‌تاب می‌تواند توسط کرم شب‌تاب دیگری جذب شود. ۲- در برخی از کرم شب‌تاب‌ها، کرم شب‌تاب با نور کمتر به سمت کرم شب‌تاب دیگری می‌رود. اگر روشنایی هر دو یکسان باشد، حرکت آن‌ها تصادفی خواهد بود. ۳- روشنایی کرم شب‌تاب با تابع هدف به دست می‌آید. امتیاز تناسب به عنوان شدت نور با توجه به عملکرد هدف هر کرم شب‌تاب تعیین می‌شود. جذب کرم شب‌تاب به این صورت است که کرم‌های شب‌تاب که نور کمتری دارند توسط نورهای روشن اطراف جذب می‌شوند. حرکت یک کرم شب‌تاب "i" به سمت یک کرم شب‌تاب پر نورتر "j" بر اساس رابطه زیر انجام می‌شود:

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma |x_j^t - x_i^t|} + \alpha t \quad [8]$$


در رابطه ۸، i و j نمایانگر کرم‌های شب‌تاب با شدت نور متفاوت هستند. در حالی که x_j^t و x_i^t ترتیب موقعیت‌های فعلی کرم شب‌تاب i و j را در تکرار t ام نشان می‌دهند. پارامتر β_0 نشانگر جاذبه اولیه، γ ضریب جذب نور و $|x_j^t - x_i^t|$ فاصله بین کرم شب‌تاب i و j است. مزیت اصلی FFA مکانیسم جذب آن است. حرکت مبتنی بر جاذبیت باعث می‌شود که ازدحام کرم شب‌تاب به‌طور خودکار به زیرگروه‌ها تقسیم شود و هر گروه حول یک راه حل بهینه جمع شوند. وقتی اندازه جمعیت به اندازه‌ای بزرگ باشد که از تعداد راه‌حل‌های بهینه محلی فراتر رود، در اصل، توانایی تقسیم‌بندی FFA می‌تواند همه مقادیر بهینه را همزمان پیدا کند، بنابراین مقدار بهینه به دست می‌آید. بنابراین، FFA برای مسائل بهینه‌سازی چندوجهی مناسب است و مطالعات این را

کاربرد دارد، به صورت رابطه ۷ تعریف می‌شود (احمدی و همکاران ۲۰۱۵):

$$Error\ function = \frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad [7]$$

شبکه عصبی مصنوعی پرسپترون چندلایه (ANN-) (MLP¹)

شبکه عصبی مصنوعی به‌طور گسترده در تحقیقات هوش مصنوعی استفاده می‌شود و در جایی کاربرد دارد که یک تابع تقریبی برای نگاشت غیرخطی بین پارامترهای ورودی و خروجی نیاز است (کیم و همکاران ۲۰۰۵). طراحی یک شبکه عبارت است از تعیین تعداد لایه‌های مناسب، تعداد مناسب نورون‌ها در هر لایه و نوع تابع تحریک در هر لایه به گونه‌ای که خطای آموزش و آزمایش شبکه به حداقل برسد (نصیری و همکاران ۲۰۱۰). برای بدست آوردن تعداد لایه میانی و همچنین تعداد گره مناسب، می‌توان از روش لونیبرگ مارکواریت^۲ استفاده کرد که از سریع‌ترین روش‌های آموزش است (هاگان و منهاج ۱۹۹۴). شکل ۳ ساختار شبکه عصبی پرسپترون چندلایه را نشان می‌دهد که از سه بخش لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است.



شکل ۲- ساختار شبکه عصبی پرسپترون چندلایه.

¹ Artificial neural network-Multi layer perceptron

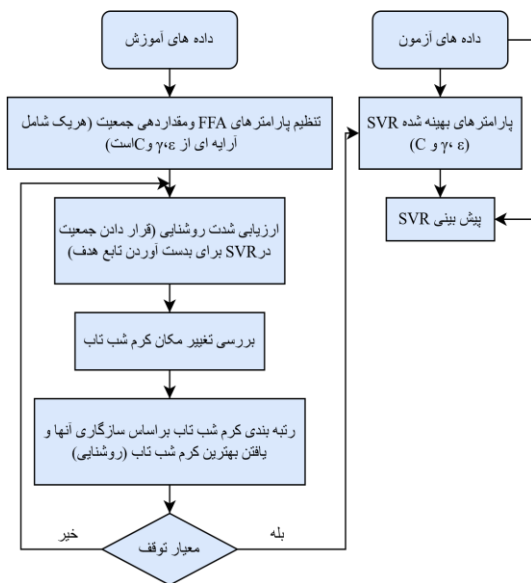
² Levenberg-Marquardt

³ Firefly Optimization Algorithm

فلوچارت ۷ به عنوان پهنای باند تابع هسته و γ و C سه پارامتر از پیش تعیین شده، تعریف می‌شود. در این تحقیق برای به دست آوردن بالاترین دقت، پس از واسنجی، مقادیر $0/001$ ، $0/01$ و 1 به ترتیب برای هر سه پارامتر γ ، C و ϵ انتخاب شدند.

تایید کرده‌اند (فیستر و همکاران ۲۰۱۳؛ ماریچلوام و قیسا ۲۰۱۴؛ اوسابا و همکاران ۲۰۱۷؛ یانگ و هی ۲۰۱۳).

شکل ۳، فلوچارت مدل ترکیبی SVR-FFA را نشان می‌دهد (نایت‌عمار و زرابی ۲۰۱۹). در این



شکل ۳- فلوچارت مدل ترکیبی SVR-FFA.

روش‌های محاسباتی، از جمله توسعه مدل SVR-FFA، در محیط MATLAB پیاده‌سازی شدند و پارامترهای تابع هسته از طریق آزمون و خطا بهینه‌سازی شدند.

عملکرد دانه می‌باشد. از کل ۲۲۰ دانه موجود برای هر مزرعه، ۳۰٪ دانه‌ها (۶۶ دانه) به صورت تصادفی برای آزمون و ۷۰٪ دانه‌ها (۱۵۴ دانه) برای مرحله آموزش مورد استفاده قرار گرفت.

جدول ۴ سناریوهای مورد استفاده در این مطالعه را برای پیش‌بینی مقادیر عملکرد گیاه گندم با استفاده از مدل‌های ANN، SVR و SVR-FFA را نشان می‌دهد. ورودی‌ها شامل بذر مصرفی، مقدار آبیاری و ترکیبی از بذر مصرفی و آبیاری بوده و خروجی نیز شامل

جدول ۴- سناریوهای مورد استفاده برای پیش‌بینی مقادیر عملکرد گیاه گندم.

سناریو	ورودی	خروجی
۱	بذر	عملکرد
۲	آبیاری	عملکرد
۳	بذر - آبیاری	عملکرد

معیارهای ارزیابی مدل

در روابط بالا، N تعداد کل داده‌ها، \bar{O}_i میانگین مقادیر مشاهداتی و پارامترهای P_i و O_i به ترتیب مقادیر پیش‌بینی و مشاهداتی می‌باشند.

نتایج و بحث

مقادیر مشاهداتی و پیش‌بینی شده عملکرد گندم در هر دو مزرعه مورد مطالعه را در مدل AquaCrop نشان می‌دهد. نکته قابل توجه این است که خطای موجود، که از تفریق مقادیر عملکرد مشاهداتی و پیش‌بینی شده برای هر دو مزرعه حاصل گردیده، مقداری ناچیز است. با توجه به جدول ۳، مدل با تغییر برخی از پارامترهای حساس که در مزرعه اندازه‌گیری نشده بودند واسنجی گردید. به طوری که خطای نسبی بین عملکرد اندازه‌گیری شده و شبیه‌سازی شده حداقل شود. در ادامه مدل با استفاده از تیمارهای مختلف بذر مصرفی و مقدار آبیاری اجرا گردید.

در این پژوهش برای ارزیابی سناریوهای مختلف تعریف شده برای روش‌های مورد مطالعه از پارامترهای آماری ضریب همبستگی (R^1)، جذر میانگین مربعات خطا ($RMSE^2$)، ضریب نش-ساتکلیف (NS^3)، شاخص توافق ویلموت (WI^4) و درصد میانگین مطلق خطا ($MAPE^5$) برای پیش‌بینی مقادیر عملکرد استفاده شده است. مقدار شاخص‌های ضریب همبستگی، ضریب نش-ساتکلیف و شاخص توافق ویلموت از ۱- تا ۱ متغیر است. به طوری که مقدار ۱ نشان‌دهنده بالاترین دقت و مقدار ۱- نشان‌دهنده کمترین دقت مدل‌ها می‌باشد. برای شاخص جذر میانگین مربعات خطا و درصد میانگین مطلق خطا نیز هرچه مقدار این شاخص‌ها به صفر نزدیک‌تر باشد نشانگر خطای کمتر مدل می‌باشد.

$$R = \frac{(\sum_{i=1}^N O_i P_i - \frac{1}{N} \sum_{i=1}^N O_i \sum_{i=1}^N P_i)}{((\sum_{i=1}^N O_i^2 - \frac{1}{N} (\sum_{i=1}^N O_i)^2)(\sum_{i=1}^N P_i^2 - \frac{1}{N} (\sum_{i=1}^N P_i)^2))} \quad [9]$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad [10]$$

$$NS = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \right] \quad [11]$$

$$WI = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (|P_i - \bar{P}_i| + |O_i - \bar{O}_i|)^2} \right] \quad [12]$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{O_i - P_i}{O_i} \right| \quad [13]$$

¹ Correlation coefficient

² Root mean squared error

³ Nash-Sutcliffe coefficient

⁴ Willmott's index of agreement

⁵ Mean absolute percentage error

جدول ۵- مقادیر مشاهداتی و پیش‌بینی شده عملکرد گندم در مدل AquaCrop.

نام مزرعه	عملکرد (ton ha ⁻¹)	
	پیش‌بینی شده	خطا (ton ha ⁻¹)
99WestW2	۶/۵۸۸	۰/۰۳
WestW10	۵/۰۵	۰/۰۰۴

در این مطالعه، سه ترکیب مختلف از متغیرهای پیش‌بینی کننده پارامترهای بذر مصرفی و مقدار آبیاری، به عنوان ورودی مدل‌ها در جدول ۴ در نظر گرفته شد. در این بخش، الگوریتم‌های ANN، SVR و SVR-FFA بر روی سه مجموعه داده برای پیش‌بینی مقادیر عملکرد استفاده شده است. تطابق بین مقادیر مشاهداتی و پیش‌بینی شده عملکرد در جدول ۶ از نظر پارامترهای آماری طی مراحل اعتبارسنجی در دوره آزمون در مزرعه 99WestW2 آمده است.

نتایج ارزیابی مدل‌های مورد استفاده در جدول ۶ برای پیش‌بینی عملکرد دانه در مزرعه 99WestW2 نشان می‌دهد که مدل SVR-FFA3 با داشتن ضریب همبستگی ۰/۹۹۴، جذر میانگین مربعات خطا (ton ha⁻¹) ۰/۰۳۳، ضریب نش-ساتکلیف ۰/۹۸۸، شاخص توافق و یلموت ۰/۹۹۷ و درصد میانگین مطلق خطا ۰/۳۶۶ کمترین خطا را نسبت به سایر ترکیبات SVR-FFA و نیز تمام مدل‌ها در این مطالعه، سه ترکیب مختلف از متغیرهای پیش‌بینی کننده پارامترهای بذر مصرفی و مقدار آبیاری، به عنوان ورودی مدل‌ها در جدول ۴ در نظر گرفته شد. در این بخش، الگوریتم‌های ANN، SVR و SVR-FFA بر روی سه مجموعه داده برای پیش‌بینی مقادیر عملکرد استفاده شده است. تطابق بین مقادیر مشاهداتی و پیش‌بینی شده عملکرد در جدول ۶ از نظر پارامترهای آماری طی مراحل اعتبارسنجی در دوره آزمون در مزرعه 99WestW2 آمده است.

های مورد استفاده را داراست. با این حال، مدل SVR3 با ضریب همبستگی ۰/۹۹، جذر میانگین مربعات خطا (ton ha⁻¹) ۰/۰۴۳، ضریب نش-ساتکلیف ۰/۹۸، شاخص توافق و یلموت ۰/۹۹۵ و درصد میانگین مطلق خطا ۰/۴۲۹ پس از مدل SVR-FFA3، دقت بیشتری را نسبت به سایر ترکیبات در برآورد عملکرد را ارائه کرد. در بین مدل‌های ANN نیز مدل ANN3 با داشتن ضریب همبستگی ۰/۹۵۹، جذر میانگین مربعات خطا (ton ha⁻¹) ۰/۱۲۳، ضریب نش-ساتکلیف ۰/۸۳۱، شاخص توافق و یلموت ۰/۹۹۵ و درصد میانگین مطلق خطا ۱/۵۷۵ کمترین خطا را نسبت به سایر ترکیبات ANN دارد.


مقایسه نتایج بین مدل‌ها برای پیش‌بینی مقادیر عملکرد در مزرعه 99WestW2 نشان داد که مدل SVR-FFA3 بالاترین دقت و کمترین خطا را در هر دو پیش‌بینی داشته است.

جدول ۶- پارامترهای ارزیابی مدل‌های مورد مطالعه در دوره آزمون در مزرعه 99WestW2 (مرحله واسنجی).

مدل	عملکرد				
	R	RMSE (ton ha ⁻¹)	NS	WI	MAPE
ANN1	۰/۰۶	۰/۳۱۲	-۰/۰۸۲	۰/۲۸۷	۲/۳۷۸
ANN2	۰/۹۵۱	۰/۱۴۳	۰/۷۷۳	۰/۹۴۱	۱/۸۳۷
ANN3	۰/۹۵۹	۰/۱۲۳	۰/۸۳۱	۰/۹۹۵	۱/۵۷۵
SVR1	۰/۲۱۱	۰/۳۰۷	۰/۰۴۸	۰/۳۷۲	۱/۶۸۲
SVR2	۰/۹۵	۰/۰۹۵	۰/۹	۰/۹۷۴	۱/۲۳۷
SVR3	۰/۹۹	۰/۰۴۳	۰/۹۸	۰/۹۹۵	۰/۴۲۹
SVR-FFA1	۰/۲۱۱	۰/۳۰۸	-۰/۰۷۷	۰/۳۹	۱/۹۰۶
SVR-FFA2	۰/۹۴۵	۰/۰۹۹	۰/۸۹	۰/۹۷۲	۱/۲۷۸
SVR-FFA3	۰/۹۹۴	۰/۰۳۳	۰/۹۸۸	۰/۹۹۷	۰/۳۶۶

که مدل SVR-FFA3 همبستگی بالاتری نسبت به مدل SVR3 و مدل SVR3 نیز همبستگی بالاتری نسبت به مدل ANN3 دارد.




نمودارهای پراکنش مقادیر مشاهداتی و پیش‌بینی شده در شکل ۵ آورده شده است. در این نمودارها بهترین سناریوی هر مدل برای پیش‌بینی عملکرد رسم گردیده است. همچنین مقایسه بین مدل‌ها نشان می‌دهد




شکل ۴- نمودارهای پراکنش مقادیر مشاهداتی و پیش‌بینی شده عملکرد در مزرعه 99WestW2.

متفاوتی از مقادیر مشاهداتی داشته و نتوانسته دقت مناسبی را از خود نشان دهد. در نمودار ویولن پلات نیز دایره و مربع سفید رنگ واقع در داخل هر مدل به ترتیب نشانگر میانه و میانگین آن مدل می‌باشد. مقایسه بین نمودارها نتایج مطالعه را تصدیق کرده و نشان می‌دهد دقت مدل SVR-FFA3 به ترتیب بیشتر از مدل‌های SVR3 و ANN3 می‌باشد.

شکل ۵ نمودارهای باکس پلات و ویولن پلات را در مزرعه 99WestW2 نشان می‌دهند. در این نمودارها بهترین سناریوی هر مدل برای پیش‌بینی عملکرد رسم گردیده است. مقایسه بین مدل‌های مورد استفاده نشان می‌دهد که باکس مربوط به مدل SVR-FFA3 بیشترین تشابه را با مقادیر مشاهداتی دارد. مدل SVR3 نیز پس از مدل SVR-FFA3 تشابه بالایی را از خود نشان داد. نکته قابل توجه این است که مدل ANN3 باکس کاملا



شکل ۵- نمودارهای باکس پلات (a) و ویولن پلات (b) مقادیر عملکرد در مزرعه 99WestW2.




جدول ۷ برای پیش‌بینی عملکرد دانه در مزرعه WestW10 در مرحله اعتبارسنجی را نشان می‌دهد. مدل SVR-FFA3 با داشتن ضریب همبستگی ۰/۹۹۶، جذر میانگین مربعات خطا (ton ha⁻¹) ۰/۰۶۹، ضریب نش-ساتکلیف ۰/۹۹۲، شاخص توافق ویلموت ۰/۹۹۸ و درصد میانگین مطلق خطا ۱/۱۳۴ کمترین خطا و بیشترین دقت را نسبت به سایر ترکیبات SVR-FFA و تمام مدل‌های مورد استفاده را داراست. مدل SVR2 نیز با داشتن ضریب همبستگی ۰/۹۹۶، جذر میانگین مربعات خطا (ton ha⁻¹) ۰/۰۷۷، ضریب نش-ساتکلیف ۰/۹۹۲، شاخص توافق ویلموت ۰/۹۹۸ و درصد میانگین مطلق خطا ۱/۱۸۶ عملکرد ضعیف‌تری نسبت به مدل

جدول ۷- پارامترهای ارزیابی مدل‌های مورد مطالعه در دوره آزمون در مزرعه WestW10 (مرحله اعتبارسنجی).

مدل	عملکرد				
	R	RMSE (ton ha ⁻¹)	NS	WI	MAPE
ANN1	-۰/۱۳۴	۰/۸۴۴	-۰/۱۸۴	۰/۳۳۲	۱۵/۲۹۱
ANN2	-۰/۹۹۳	۰/۰۹۴	۰/۹۸۵	۰/۹۹۶	۱/۶۴۸
ANN3	-۰/۹۹۳	۰/۱۰۱	۰/۹۸۳	۰/۹۹۶	۱/۷۴۸
SVR1	-۰/۱۵۸	۰/۸۴۹	-۰/۱۹۹	۰/۲۷۵	۱۵/۷۳۴
SVR2	-۰/۹۹۶	۰/۰۷۷	۰/۹۹	۰/۹۹۸	۱/۱۸۶
SVR3	-۰/۹۹۲	۰/۱	۰/۹۸۳	۰/۹۹۶	۱/۲۸۵
SVR-FFA1	-۰/۰۰۱	۰/۸۴	-۰/۱۷۷	۰/۳۶۹	۱۴/۹۳۲
SVR-FFA2	-۰/۹۹۵	۰/۰۷۵	۰/۹۹۱	۰/۹۹۸	۱/۳۱
SVR-FFA3	-۰/۹۹۶	۰/۰۶۹	۰/۹۹۲	۰/۹۹۸	۱/۱۳۴

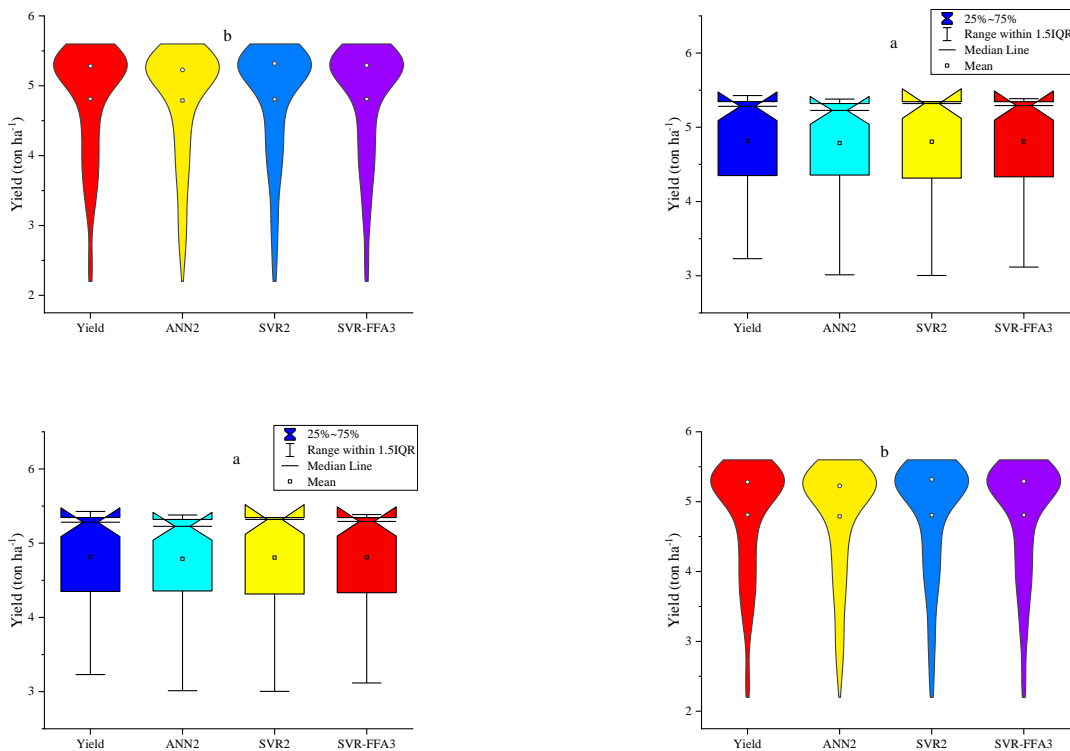
نمودارهای پراکنش مقادیر مشاهداتی و پیش‌بینی شده در شکل ۷ آورده شده است. در این نمودارها بهترین سناریوی هر مدل برای پیش‌بینی عملکرد رسم گردیده است. همچنین مقایسه بین مدل‌ها نشان می‌دهد برای

مقادیر عملکرد مدل SVR-FFA3 همبستگی بالاتری نسبت به مدل SVR2 و مدل SVR2 نیز همبستگی بالاتری نسبت به مدل ANN2 دارد. در نهایت نتایج بین مقایسه نمودارها صحت مقادیر جدول ۷ را تایید می‌کند.



شکل ۵- نمودارهای پراکنش مقادیر مشاهداتی و پیش‌بینی شده عملکرد در مزرعه WestW10.

نمودارهای باکس‌پلات و ویولن‌پلات را در مزرعه WestW10 نشان می‌دهند. در این نمودارها بهترین سناریوی هر مدل برای پیش‌بینی عملکرد رسم گردیده است. مقایسه بین مدل‌های مورد استفاده نشان می‌دهد که باکس مربوط به مدل SVR-FFA3 بیش‌ترین تشابه را با مقادیر مشاهداتی در پیش‌بینی عملکرد داشته است. باکس‌های مربوط به مدل‌های SVR و ANN نیز توانستند دقت قابل قبولی را از خود نشان دهند.



شکل ۶- نمودارهای باکس‌پلات (a) و ویولن‌پلات (b) مقادیر عملکرد در مزرعه WestW10.

دارد. این مدل توانست برای مزرعه WestW2 99 مقادیر عملکرد را با استفاده از معیار ارزیابی RMSE (به ton)

مقایسه بین نتایج به‌دست آمده نشان داد که مدل SVR-FFA3 توانایی بالایی در پیش‌بینی مقادیر عملکرد

مقایسه مدل AquaCrop پرداخته شده است، تا بتوان مدلی را که به ورودی‌های کمتری نیاز داشته و در عین حال باعث صرفه‌جویی در وقت نیز گردد، پیشنهاد داد. از پارامترهای ورودی مقدار بذر مصرفی و مقدار آبیاری در سه سناریو به عنوان ورودی مدل‌های هوشمند استفاده گردید. نتایج اجرای مدل‌ها با استفاده از ۵ معیار مورد ارزیابی قرار گرفت. مدل AquaCrop در ابتدا با استفاده از مقادیر واقعی در سال زراعی ۱۳۹۹-۱۳۹۸ واسنجی شده و سپس با توجه به شرایط اقلیمی برای سال زراعی ۱۴۰۰-۱۳۹۹ اعتبارسنجی شد. در نهایت مدل AquaCrop با مدل‌های هوشمند مقایسه گردید. مدل‌های SVR و ANN نیز پس از مدل SVR-FFA توانستند عملکرد مناسبی را از خود نشان دهند. در نهایت مدل‌های هوشمند SVR-FFA، SVR و ANN با وجود کمترین تعداد داده ورودی قادر به پیش‌بینی مقادیر عملکرد در کمترین زمان و با بیشترین دقت بودند. لذا طراحان و مهندسان با استفاده از مدل‌های پیشنهادی می‌توانند علاوه بر صرفه‌جویی در زمان، با کاربردن تیمارهای مختلف آبیاری سبب کاهش مصرف آب و در عین حال افزایش عملکرد شوند، تا بتوان با مصرف بهینه آب گامی مهم در احیای دریاچه ارومیه برداشت.

0.33 ha^{-1} و برای مزرعه WestW10 مقادیر عملکرد را با استفاده از معیار ارزیابی RMSE به $0.69 \text{ (ton ha}^{-1})$ کاهش دهد. هان و همکاران، در تحقیقی به پیش‌بینی عملکرد گندم بر اساس داده‌های چندمنبعی و یادگیری ماشین در چین پرداختند. نتایج نشان داد که مدل‌ها می‌توانند به طور دقیق عملکرد را ۱ تا ۲ ماه قبل از تاریخ برداشت با $R^2 < 0.75$ و خطای عملکرد ۱۰٪ پیش‌بینی کنند (هان و همکاران ۲۰۲۰). بنابراین مدل SVR-FFA3 توانست مقادیر عملکرد را با دقت بالاتر و خطای کمتری نسبت به مطالعات قبلی پیش‌بینی کند.

نتیجه‌گیری کلی

هدف سازمان فائو از توسعه مدل AquaCrop، فراهم نمودن ابزاری برای کمک به کشاورزان و مدیران کشت و صنعت‌ها برای انتخاب مدیریت بهینه آبیاری در سیستم‌های کشاورزی موجود در سرتاسر جهان می‌باشد. بکارگیری این مدل به ویژه برای محصولات استراتژیک مانند گندم ضروری است، مدل AquaCrop به ورودی‌های نسبتاً زیادی نیاز داشته و در صورت وجود سناریوهای متعدد مدلی وقت‌گیر می‌باشد. بنابراین در این تحقیق با استفاده از مدل‌های هوشمند ANN، SVR و SVR-FFA و با ایجاد ۴۴۰ سناریو در ۲ مزرعه واقع در شهرستان‌های میاندوآب و مهاباد به

منابع مورد استفاده

- Ahmadi F, Radmanesh F and Mirabbasi N, 2015. Comparison between genetic programming and support vector machine methods for daily river flow forecasting (Case study: Barandoozchay River). *Journal of Water and Soil* 28(6):1162-1171 (in Persian with English abstract).
- Araya A, Vara Prasad P, Ciampitti IA, Rice CW and Gowda PH, 2022. Using crop simulation models as tools to quantify effects of crop management practices and climate change scenarios on wheat yields in northern Ethiopia. *Enhancing agricultural research and precision management for subsistence farming by integrating system models with experiments* 20(1): 29-47.
- Benimam H, Si-Moussa C, Laidi M and Hanini S, 2020. Modeling the activity coefficient at infinite dilution of water in ionic liquids using artificial neural networks and support vector machines. *Neural Computing and Applications* 32(12): 8635-8653.
- Change, 2007. Intergovernmental panel on climate. "Climate change: the physical science basis: summary for policymakers. Switzerland.
- Dibike YB, Velickov S, Solomatine D and Abbott MB, 2001. Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering* 15(3): 208-216.
- Doorenbos J and Kassam A, 1979. Yield response to water. *Irrigation and drainage, England.*

- Eskandari A, Nouri R, Meraji H and Kiaghadi A, 2012. Developing a proper model for online estimation of the 5-day biochemical oxygen demand based on artificial neural network and support vector machine. *Journal of Environmental Studies* 38(1): 71-82 (In Persian with English abstract).
- Fan L and Zhang L, 2022. Multi-system fusion based on deep neural network and cloud edge computing and its application in intelligent manufacturing. *Neural Computing and Applications* 34(5): 3411-3420.
- Fatih M, 2009. Investigation of the effect of different irrigation levels and seed density on grain yield of Shiraz cultivar by surface irrigation method in Bajgah climatic conditions (Fars province). Master Thesis, Department of Irrigation and Drainage, Shiraz University. (In Persian with English abstract).
- Fister I, Fister Jr, Yang XS and Brest J, 2013. A comprehensive review of firefly algorithms. *Swarm and Evolutionary Computation* 13: 34-46.
- Ghorbani MA, Shamshirband S, Haghi DZ, Azani A, Bonakdari H and Ebtehaj I, 2017. Application of firefly algorithm-based support vector machines for prediction of field capacity and permanent wilting point. *Soil and Tillage Research* 172: 32-38.
- Gu N, Zhang J, Wang G, Liu C, Wang Z and Lü H, 2022. An atmospheric and soil thermal-based wheat crop coefficient method using additive crop growth models. *Agricultural Water Management* 269(1): 107-131.
- Guarin JR and Asseng S, 2022. Improving Wheat Production and Breeding Strategies Using Crop Models. *Food Security in a Changing Climate* 3(1): 573-591.
- Gupta S, 2021. Artificial neural network modeling and exposure assessments: a new scaling approach. *Human and Ecological Risk Assessment* 27(1): 30-49.
- Hagan MT and Menhaj MB, 1994. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks* 5(6): 989-993.
- Hamel LH, 2011. *Knowledge Discovery with Support Vector Machines* (Vol. 3). John Wiley & Sons.
- Han J, Zhang Z, Cao J, Luo Y, Zhang L, Li Z and Zhang J, 2020. Prediction of winter wheat yield based on multi-source data and machine learning in China. *Remote Sensing* 12(2): 236-251.
- Holzworth DP, Snow V, Janssen S, Athanasiadis IN, Donatelli M, Hoogenboom G, White JW and Thorburn P, 2015. Agricultural production systems modelling and software: current status and future prospects. *Environmental Modelling & Software* 72: 276-286.
- Kamari A, Gharagheizi F, Shokrollahi A, Arabloo M and Mohammadi AH, 2016. Integrating a robust model for predicting surfactant-polymer flooding performance. *Journal of Petroleum Science and Engineering* 137: 87-96.
- Kareem FA, Shariff AM, Ullah S, Keong LK and Mellon N, 2018. Total and partial uptakes of multicomponent vapor-gas mixtures on 13X zeolite at 343K: Experimental and modeling study. *Microporous and Mesoporous Materials* 258: 95-113.
- Kargar K, Samadianfard S, Parsa J, Nabipour N, Shamshirband S, Mosavi A and Chau K, 2020. Estimating longitudinal dispersion coefficient in natural streams using empirical models and machine learning algorithms. *Engineering Applications of Computational Fluid Mechanics* 14(1): 311-322.
- Kibue GW, Liu X, Zheng J, Pan G, Li L and Han X, 2016. Farmers' perceptions of climate variability and factors influencing adaptation: Evidence from Anhui and Jiangsu, China. *Environmental Management* 57(5): 976-986
- Kim IS, Son JS, Park CE, Kim I and Kim H, 2005. An investigation into an intelligent system for predicting bead geometry in GMA welding process. *Journal of Materials Processing Technology* 159(1): 113-118.
- Kumar Srivastava A and Singh H, 2016. An enhance firefly algorithm for flexible job shop scheduling. *International Journal of Computer Applications* 6(5): 1-17.
- Ma C, Liu M, Ding F, Li C, Cui Y, Chen W and Wang Y, 2022. Wheat growth monitoring and yield estimation based on remote sensing data assimilation into the SAFY crop growth model. *Scientific Reports* 12(1): 1-16.
- Mallikarjuna Rao G, Dangeti S and Amiripalli SS, 2022. An efficient modeling based on XGBoost and SVM algorithms to predict crop yield. *Advances in Data Science and Management* 13(1): 565-574.
- Marichelvam M and Geetha M, 2014. Solving tri-objective multistage hybrid flow shop scheduling problems using a discrete firefly algorithm. *International Journal of Intelligent Engineering Informatics* 2(4): 284-303.

- Moazenzadeh R, Mohammadi B, Shamsirband S and Chau K, 2018. Coupling a firefly algorithm with support vector regression to predict evaporation in northern Iran. *Engineering Applications of Computational Fluid Mechanics* 12(1): 584-597.
- Nait Amar M and Zeraibi N, 2019. A combined support vector regression with firefly algorithm for prediction of bottom hole pressure. *SN Applied Sciences* 2(1): 23-41.
- Nasiri M, Modarrs R and Dastoorani M, 2010. Validation of ANN model of rainfall-runoff relationship in Zaynderood Dam Watershed. *Journal of Watershed Researches* 88: 17-26. (In Persian with English abstract).
- Nguyen VD, Nguyen HT, Vranova V, Nguyen LT, Bui QM and Khieu TT, 2021. Artificial neural network modeling for Congo red adsorption on microwave-synthesized akaganeite nanoparticles: optimization, kinetics, mechanism, and thermodynamics. *Environmental Science and Pollution Research* 28(8): 9133-9145.
- Niedbała G, 2019. Simple model based on artificial neural network for early prediction and simulation winter rapeseed yield. *Journal of Integrative Agriculture* 18(1): 54-61.
- Osaba E, Yang XS, Dia, F, Onieva E, Masegosa AD and 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.
- Raes D, Steduto P, Hsiao TC and Fereres E, 2009. AquaCrop—the FAO crop model to simulate yield response to water: II. Main algorithms and software description. *Agronomy Journal* 101(3): 438-447.
- Sharafi M, Samadian Fard S and Hashemi S, 2021. Monthly rainfall Forecasting using genetic programming and support vector machine [Applicable]. *Journal of Rainwater Catchment Systems* 8(4): 63-71. (In Persian with English abstract).
- Shifteh Some'e B, Ezani A and Tabari H, 2013. Spatiotemporal trends of aridity index in arid and semi-arid regions of Iran. *Theoretical and Applied Climatology* 111(1): 149-160.
- Steduto P, Hsiao TC, Raes D and Fereres E, 2009. AquaCrop—The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. *Agronomy Journal* 101(3): 426-437.
- Swe LM, Shrestha RP, Ebberts T and Jourdain D, 2015. Farmers' perception of and adaptation to climate-change impacts in the dry zone of Myanmar. *Climate and Development* 7(5): 437-453.
- Verma A, 2022. SVM, CNN and VGG16 Classifiers of artificial intelligence used for the detection of diseases of rice crop: A Review. *Sentimental Analysis and Deep Learning* 42(12): 917-931.
- Yang XS, 2009. Firefly algorithms for multimodal optimization. *International Symposium on Stochastic Algorithms* 17(1): 169-178.
- Yang XS, 2010. *Nature-Inspired Metaheuristic Algorithms*. Luniver press.
- Yang XS and He X, 2013. Firefly algorithm: recent advances and applications. *International Journal of Swarm Intelligence* 1(1): 36-50.
- Yazdansepar A, Akbari A, Sanjari AG, Rezaie M, Chaichi M, Babaie T and Ashouri S, 2011. Mihan, a new bread wheat cultivar for irrigated and post-anthesis drought stress conditions in cold regions of Iran. *Seed and Plant Improvement Journal* 27(4): 17-35 (in Persian with English abstract).
- Zhang, C, Xie Z, Wang Q, Tang M, Feng S and Cai H, 2022. AquaCrop modeling to explore optimal irrigation of winter wheat for improving grain yield and water productivity. *Agricultural Water Management* 266: 107580.
- Zhang T, Su J, Liu C and Chen WH, 2019. Bayesian calibration of AquaCrop model for winter wheat by assimilating UAV multi-spectral images. *Computers and Electronics in Agriculture* 167: 105052.