



Evaluation of the Hybrid Artificial Neural Network-Coati Optimization Algorithm (ANN-COA) Model for Predicting Saffron Water Demand Using Limited Climatic Parameters

Abbas Khashei-Siuki^{1*}, Ali Maroosi² and Moein Tosan³

Article type:

Research Article

Article history:

Submitted: 2 July 2024

Revised: 30 November 2024

Accepted: 1 December 2024

Available Online: 1 December 2024

How to cite this article:

Khashei-Siuki, A., Maroosi, A., and Tosan, M. 2024. Evaluation of the Hybrid Artificial Neural Network-Coati Optimization Algorithm (ANN-COA) Model for Predicting Saffron Water Demand Using Limited Climatic Parameters, 12(4): 391-413.

DOI: 10.22048/jsat.2024.465148.1533

Abstract

Accurate estimation of saffron water demand is essential for sustainable water resource management in saffron-growing regions. This study examines the optimization of the Artificial Neural Network (ANN) model for predicting saffron water demand using the hybrid Coati Optimization Algorithm (COA). The performance of the ANN-COA model was compared with ANN, ANN-GA, ANN-PSO, ANN-MFO, Quadratic Regression (QR), Tree Regression (TR), and Pattern Regression models. Input data included temperature (minimum, maximum, average), wind speed, relative humidity, net radiation, and day of the year. The results showed that under conditions using all climatic parameters, the ANN-COA model achieved an R^2 of 0.995 and a Mean Squared Error (MSE) of 0.0001 for the Mashhad station, and an R^2 of 0.973 and MSE of 0.0005 for the Birjand station, indicating acceptable accuracy in predicting saffron water demand. Additionally, under conditions with limited climatic parameters, the ANN-COA model, using maximum temperature, wind speed, and day of the year, exhibited the best performance in predicting saffron water demand. Based on the findings of this research, hybrid neural network models show superior accuracy in estimating saffron water demand with minimal climatic parameters compared to other data mining models.

Keywords: Machine learning, Sustainable, Temperature, Water resources management.

1 - Professor of Water Science and Engineering, Faculty of Agriculture, University of Birjand.

2 - Assistant Professor, University of Torbat Heydarieh, Torbat Heydarieh, Iran

3 - Ph.D. Candidate of Water Resources, University of Birjand.



Corresponding author email: abbaskhashei@birjand.ac.ir

مقاله پژوهشی

ارزیابی مدل هیبریدی شبکه عصبی کواتی ANN-COA برای پیش بینی نیاز آبی زعفران با استفاده از پارامترهای اقلیمی محدود

عباس خاشعی سیوکی^{۱*}، علی ماروسی^۲ و معین توسن^۳

تاریخ دریافت: ۱۲ تیر ۱۴۰۳

تاریخ بازنگری: ۱۰ آذر ۱۴۰۳

تاریخ پذیرش: ۱۱ آذر ۱۴۰۳

خاشعی سیوکی، ع، ماروسی، ع، و توسن، م. ۱۴۰۳. ارزیابی مدل هیبریدی شبکه عصبی کواتی ANN-COA برای پیش‌بینی نیاز آبی زعفران با استفاده از پارامترهای اقلیمی محدود. زراعت و فناوری زعفران، ۱۲(۴): ۳۹۱-۴۱۳.

چکیده

تخمین دقیق نیاز آبی زعفران برای مدیریت پایدار منابع آب در مناطق کاشت این محصول ضروری است. در این پژوهش، بهینه‌سازی مدل شبکه عصبی مصنوعی (ANN) برای تخمین نیاز آبی زعفران با استفاده از الگوریتم بهینه‌سازی هیبریدی کواتی (COA) بررسی شد. عملکرد مدل ANN-COA با مدل‌های ANN-GA، ANN-PSO، ANN-MFO، رگرسیون مرتبه دوم (QR)، رگرسیون درختی (TR) و رگرسیون الگویی (Pattern) مقایسه شد. داده‌های ورودی شامل دما (حداقل، حداکثر، متوسط)، سرعت باد، رطوبت نسبی، تابش خالص و روز از سال بود. نتایج نشان داد که در شرایط استفاده از کلیه پارامترهای اقلیمی، مدل ANN-COA با ضریب تعیین $R^2=0.995$ و خطای میانگین مربعات $MSE=0.0001$ برای ایستگاه مشهد و $R^2=0.973$ و $MSE=0.0005$ برای ایستگاه بیرجند، دقت قابل قبولی در تخمین نیاز آبی زعفران دارد. همچنین در شرایط استفاده از پارامترهای اقلیمی محدود، مدل ANN-COA با ترکیب دمای حداکثر و سرعت باد به همراه روز از سال، بهترین عملکرد را در تخمین نیاز آبی زعفران داشت. بر اساس یافته‌های این پژوهش، مدل‌های شبکه عصبی هیبریدی برای تخمین نیاز آبی زعفران در شرایط استفاده از حداقل پارامترهای اقلیمی، در مقایسه با سایر مدل‌های داده‌کاوی، از دقت بالاتری برخوردار می‌باشند.

کلمات کلیدی: پایداری، دما، مدیریت منابع آب، یادگیری ماشین.

۱- استاد گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

۲- دکتری مهندسی کامپیوتر نرم افزار، گروه مهندسی کامپیوتر دانشگاه تربیت حیدریه

۳- دانشجوی دکتری منابع آب، گروه علوم و مهندسی آب، دانشگاه بیرجند

*- نویسنده مسئول: abbaskhashei@birjand.ac.ir

مقدمه

در سال‌های اخیر، منابع آب برای تولید محصولات زراعی در سرتاسر جهان به‌ویژه در واکنش به برداشت بی‌رویه از مخازن آب و تغییرات اقلیمی محدود شده است (KhasheiSiuki et al., 2023)؛ از این رو، نیاز فوری به بررسی استراتژی‌های صرفه‌جویی در مصرف آب و طراحی سیستم‌های آبیاری کارآمدتر در کشاورزی وجود دارد (Azari et al., 2024). زعفران (*Crocus sativus L.*) یکی از گران‌ترین و کمیاب‌ترین محصولات کشاورزی در سراسر جهان است (Yaqubi et al., 2024; Han et al., 2024). تولید جهانی زعفران در سال ۲۰۱۹ حدود ۵۰۰ تن تخمین زده شده است که ایران با ۹۴ درصد از تولید جهانی، به‌عنوان تولیدکننده پیشرو به‌حساب می‌آید (Mehmeti et al., 2024). ارزش بازار جهانی زعفران در سال ۲۰۲۲ به ۱/۰۷ میلیارد دلار رسیده است و پیش‌بینی می‌شود که بین سال‌های ۲۰۲۳ تا ۲۰۲۹ با ۷/۳ درصد CAGR به ارزش ۱/۷۷ میلیارد دلار برسد (Abou Fayssal et al., 2024). زعفران سرشار از کاروتنوئیدها (کرو سین و کرو ستین) (رنگ)، پیروکروسین (طعم)، سافرانال (عطر) و ترپن‌ها است (Rezvani et al., 2016). زعفران به دلیل نیاز آبی کم و سازگاری با اقلیم‌های خشک یکی از گران‌ترین و ارزشمندترین محصولات در کشورهایی است که با کمبود آب دست و پنجه نرم می‌کنند (Akbari et al., 2024; Mahdian Moghadam & Tosan, 2015). بیشتر مناطق کشت زعفران در ایران آبی است و آبیاری قبل از گلدهی برای تسهیل رویش گل ضروری است. با این حال، کشاورزان در این مناطق با کمبود آب مواجه هستند (Razmavaran et al., 2024b).

زعفران به‌عنوان محصولی مناسب برای سیستم‌های کم‌نهاد در مناطق خشک و نیمه‌خشک در نظر گرفته می‌شود (Feizi & Tosan, 2016)، زیرا تولیدات گیاهی در این مناطق

عموماً محدود به آب است (Koocheki et al., 2020). فصل رشد زعفران بیشتر در زمستان و بهار است (Tosan et al., 2024). بنابراین می‌توان از بارندگی برای تأمین آب موردنیاز خود استفاده کرد. عملکرد زعفران دیم تحت تأثیر بارندگی سالانه و پراکنش آن است. کاهش یا وقوع دیرهنگام بارندگی ممکن است عملکرد و کیفیت زعفران را کاهش دهد (Razmavaran et al., 2024b). دوره رشد زعفران در بهار پس از تولید بنه‌های جایگزین (تازه تشکیل شده) در حدود ۲۲۰ روز از اولین آبیاری به پایان می‌رسد. این زمان‌بندی در تمام زمینه‌های تولید زعفران در سراسر جهان مشابه است (Koocheki et al., 2019). در این مدت، بسیاری از آب موردنیاز این گیاه از طریق بارندگی تأمین می‌شود (Fallahi et al., 2017). در واقع، زعفران نیاز آبی کمی دارد، زیرا تنها ۳۰۰۰-۳۶۰۰ مترمکعب در هکتار آب در سال برای تولید زعفران در ایران استفاده می‌شود (Fallahi & Mahmoodi, 2018). از آنجایی که برآورد نادرست نیاز آبی منجر به برنامه‌ریزی اشتباه و در نتیجه هدر رفت منابع آب می‌شود، برآورد دقیق، نقطه شروع در این مسیر است. با توجه به سطح زیر کشت قابل توجه این محصول در نواحی شرقی، محققان باید تلاش مجدانه‌ای را برای بهبود مدل‌سازی نیاز آبی زعفران انجام دهند (Pereira et al., 2020).

با توجه به اهداف و برنامه‌ریزی‌های مختلف، پیش‌بینی نیاز آبی را می‌توان به پیش‌بینی کوتاه مدت، میان مدت و بلند مدت تقسیم کرد (Anele et al., 2017). با توجه به اینکه استفاده از روش قطره‌ای در آبیاری زعفران افزایش یافته و دور آبیاری در سیستم‌های آبیاری قطره‌ای روزانه است، اهمیت پیش‌بینی نیاز آبی در دوره‌های کوتاه حائز اهمیت است. پیش‌بینی کوتاه مدت عموماً به‌صورت پیش‌بینی روزانه نیاز آبی برای کنترل بهینه سیستم‌های مصرف آب می‌باشد که به دقت و سرعت پیش‌بینی بالا نیاز دارد (Tian, 2020). در سال‌های اخیر مدل‌های برآورد

این حال، مدل فائو پنمن مونتیث (FAO-56) نیاز به طیف وسیعی از داده‌های هوا شناسی دارد که شامل حداکثر و حداقل دما، سرعت باد، رطوبت نسبی و تشعشع خالص می‌شود که کاربرد جهانی آن را به شدت محدود می‌کند (Goyal et al., 2023).

در سال‌های اخیر مطالعات زیادی درخصوص جنبه‌های مختلف تعیین نیاز آبی زعفران انجام شده است (Yarami & Sepaskhah, 2015; Maleki et al., 2011; Shamsabadi et al., 2015; Jafarzadeh et al., 2015; Koocheki et al., 2016; Yarami & Sepaskhah, 2016). گندم‌کار و همکاران (Gandomkar et al., 2015) جهت محاسبه نیاز آبی زعفران در استان اصفهان، تبخیر و تعرق زعفران را به روش پنمن مونتیث برآورد کردند. در این تحقیق نیاز آبی روزانه زعفران به روش پنمن مونتیث و ضریب گیاهی با استفاده از داده‌های هواشناسی ۱۵ ساله برآورد شد. علی اکبری و همکاران (Aliakbari et al., 2018) نرخ تبخیر و تعرق بالقوه و واقعی و مناسب‌ترین مدل را برای تخمین نیاز آبی زعفران در تربت‌حیدریه تعیین کردند. در این مطالعه روش‌های مختلف پنمن-مونتیث فائو، بلانی-کریدل، هارگریوز-سامانی، تورنت وایت، جنسن-هایس و تورک مورد ارزیابی قرار گرفت. مقایسه نتایج به دست آمده از روش پنمن-مونتیث فائو با روش‌های دیگر با استفاده از آزمون کای دو انجام شد. نتایج نشان داد روش پنمن-مونتیث فائو از دقت بیشتری نسبت به سایر روش‌ها برخوردار است. مشیزی و همکاران (Moshizi et al., 2023) به منظور پیش‌بینی ردپای آبی سبزی و آبی محصول زعفران از مدل‌های محاسباتی نرم و الگوریتم‌های تکاملی بهره گرفتند. نتایج نشان داد که مهم‌ترین متغیرهای مؤثر بر ردپای آبی سبزی و آبی تعرق، تبخیر و تعرق و عملکرد گیاهی می‌باشند.

ژانگ و همکاران (Zhang et al., 2008) با ترکیب داده‌های آب و هوایی و نیاز آبی محصولات و استفاده از الگوریتم‌های

نیاز آبی متعددی در دسترس قرار گرفته‌اند که اغلب بر اساس تبخیر و تعرق محصول پیشنهاد شده در دستورالعمل‌های FAO است (Pereira et al., 2020). استفاده از آب برای آبیاری محصولات به شدت تحت تأثیر تغییرات اقلیمی و محیطی است، لذا نیاز به کاهش تلفات و هدر رفت آب و بهبود بهره‌وری محصولات آبیاری امری حیاتی است. یک رویکرد مهم شامل بستن شکاف بین آب مورد استفاده و نیاز آبی واقعی محصول است. این شکاف‌ها به مسائل مختلف آبیاری از جمله بهبود روش‌های آبیاری و برنامه‌ریزی آبیاری و انتقال آب، استفاده از فناوری‌های اطلاعات و ارتباطات، روش‌های دقیق‌تر کشت و مدیریت آب و آموزش کشاورزان اشاره دارد. در رأس این پیشرفت‌ها، نیاز به توسعه پژوهش‌ها، به‌ویژه در مورد نیاز آبی محصولات، در نتیجه فرآیندهای تبخیر و تعرق محصول و روش‌های تعیین آن است (Pereira et al., 2020).

نیاز آبی محصولات را می‌توان مستقیماً با استفاده از تکنیک‌های تجربی مانند برج‌های کوواریانس گردابی، لایسیمترها و تعادل انرژی نسبت بوون اندازه‌گیری کرد (Alam et al., 2024). با این حال، این فناوری‌ها پیچیده، گران و در بسیاری از زمینه‌ها عملی نیستند (Bian et al., 2024). علاوه بر این، تعیین نیاز آبی هر گیاه به صورت جداگانه یک کار چالش‌برانگیز است. بنابراین تبخیر و تعرق مرجع (ET_0) را می‌توان قبل از تبدیل به ET گیاه هدف با استفاده از ضریب گیاهی تخمین زد (Razmavaran et al., 2024a). تبخیر و تعرق (ET_0) یک فرآیند هیدرولوژیکی پیچیده و غیرخطی است که تأثیر قابل توجهی بر برنامه‌ریزی کارآمد منابع آب و مدیریت بلندمدت دارد (Alam et al., 2024). توسعه مدل‌های محاسباتی برای تخمین نیاز آبی، که اغلب به ET_0 متکی هستند، یک جایگزین قابل اعتماد برای غلبه بر این شکاف است. مدل فائو پنمن مونتیث به عنوان روش استاندارد برای تخمین نیاز آبی در نقاط مختلف در سراسر جهان مورد استفاده قرار گرفته است. با

عصبی مصنوعی (ANN) به منظور تخمین نیاز آبی روزانه گندم و ذرت استفاده کردند. نتایج نشان دهنده توانایی مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی، به ویژه آن‌هایی که دو لایه پنهان در ساختار خود دارند، در تخمین نیاز آبی روزانه می‌باشند. بهترین مدل برای تخمین نیاز آبی روزانه گندم و ذرت با پارامترهای ورودی T_{max} ، T_{min} ، RH_{max} ، RH_{min} ، U_2 ، LAI و h بود.

جعفرزاده و همکاران (Jafarzadeh et al., 2023) در پژوهشی جهت ارزیابی عملکرد روش‌های مدل‌سازی گروهی در شبیه‌سازی نیاز آبی زعفران نشان دادند که علی‌رغم دقت و کارایی نسبی مدل درخت تصمیم در شبیه‌سازی نیاز آبی زعفران، امکان بهبود نتایج همچنان وجود دارد. همچنین، نتایج اثبات کرد که مدل‌سازی گروهی ظرفیت بالقوه‌ی خوبی در زمینه ارتقای نتایج دارد. به طوری که یادگیری گروهی بانظارت (Boosting) دقت مدل درخت تصمیم را بیش از ۳۰ درصد بهبود بخشید.

الگوریتم‌های بهینه‌سازی از عملگرهای پیشرفته برای یافتن راه‌حل‌های بهینه استفاده می‌کنند. الگوریتم‌های بهینه‌سازی مختلفی وجود دارد. در مسائل ترکیبی در مقیاس بزرگ و مسائل غیرخطی، الگوریتم‌های بهینه‌سازی کلاسیک کافی نیستند. در نتیجه، الگوریتم‌های بهینه‌سازی فراابتکاری توسعه یافته‌اند (Abualigah et al., 2023). الگوریتم‌های بهینه‌سازی مختلفی مانند الگوریتم‌های بهینه‌سازی مبتنی بر ازدحام، الگوریتم‌های بهینه‌سازی مبتنی بر گیاه و الگوریتم‌های بهینه‌سازی مبتنی بر زیست‌شناسی وجود دارد (Sammen et al., 2023).

ایده رویکرد پیش‌بینی هیبریدی، به معنی استفاده از مدل‌های چندگانه برای پیش‌بینی موضوعات تحقیق و میانگین وزنی نتایج مدل‌های پیش‌بینی چندگانه، به منظور بهبود اثر پیش‌بینی است (Zhao et al., 2024). در ادبیات ترکیب پرسپترون چندلایه افتراق مرتبه اول و پرسپترون چندلایه خطی با کاهش روند توسعه یافته و با مدل پرسپترون چندلایه مستقل

ژنتیک برای تولید قوانین فازی، مدلی فازی ایجاد کردند که قادر به پیش‌بینی دقیق نیاز آبی محصولات است. نتایج نشان داد که استفاده از مدل قوانین فازی، روشی مؤثر برای پیش‌بینی نیاز آبی محصول است. با این حال، ایجاد قوانین فازی بیش از حد به تجربه دستی برای انطباق با تغییرات پیچیده در سیستم کشاورزی متکی است.

گیو و همکاران (Guo et al., 2011) از ماشین بردار پشتیبان حداقل مربعات (LSSVM) برای پیش‌بینی و محاسبه نیازهای آبیاری محصول استفاده می‌کنند. اشکال روش پیش‌بینی پیشنهادی آن‌ها این است که تعیین پارامترهای LSSVM دشوار است. احمد (Ahmed, 2018) از الگوریتم‌های رگرسیون خطی چندگانه برای پیش‌بینی نیاز آبی استفاده کرد. نتایج نشان داد با توجه به این که نیاز آبی محصول یک سیستم غیرخطی پیچیده است، بنابراین مدل‌های خطی برای پیش‌بینی نیاز آبی مناسب نیستند.

احمدی و همکاران (Ahmadede et al., 2016) با بررسی مدل مناسب جهت تعیین نیاز آبی زعفران در دشت بیرجند نشان دادند مدل تک پارامتره مبتنی بر دما می‌تواند برآورد دقیقی نسبت به سایر روش‌های تعیین نیاز آبی داشته باشد که در شرایط عدم دسترسی به همه پارامترهای هواشناسی می‌تواند مورد استفاده قرار گیرد. با این حال، مدل‌های پیش‌بینی ایجاد شده توسط نویسندگان بسیار پیچیده هستند و به پارامترهای زیادی نیاز دارند. اگرچه روش‌های پیش‌بینی نیاز آبی محصول به نتایجی دست یافته‌اند، اما کاستی‌ها و معایب خاص خود را نیز دارند. مهم‌ترین مشکل این است که این روش‌ها یا مدل‌های پیش‌بینی منفرد هستند. هر مدل یا روش پیش‌بینی کاستی‌های خاص خود را دارد. بنابراین، رویکرد پیش‌بینی ترکیبی یک جهت تحقیقاتی مهم برای افزایش دقت پیش‌بینی است (Peng et al., 2019).

ابریشمی و همکاران (Abrishami et al., 2019) از شبکه

می‌تواند داده‌های با نویز بالا و شرایط نامشخص را مدیریت کند، از طرفی از آنجا که فقط چند پارامتر دارد، پیاده‌سازی الگوریتم آسان است. برخلاف الگوریتم‌های بهینه‌سازی هوشمند کلاسیک، مانند الگوریتم ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO)، COA یک سری قوانین را برای ساخت یک مدل ریاضی فرموله می‌کند (Lei et al., 2024)، لذا در این پژوهش عملکرد الگوریتم هیبریدی شبکه عصبی کوآتی با الگوریتم‌های بهینه‌سازی هوشمند کلاسیک، مانند الگوریتم ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO) مقایسه شد. اهداف اصلی این پژوهش را می‌توان به صورت زیر عنوان کرد:

۱. ارزیابی کارایی مدل هیبریدی شبکه عصبی مصنوعی - کوآتی (ANN-COA) در پیش‌بینی نیاز آبی زعفران
۲. مقایسه عملکرد مدل هیبریدی ANN-COA با سایر مدل‌های رایج مانند ANN-GA، ANN-PSO و ANN-MFO) و همچنین روش‌های داده‌کاوی سنتی (مانند رگرسیون مرتبه دوم، رگرسیون درختی و رگرسیون الگویی)
۳. شناسایی بهترین ترکیب داده‌های ورودی برای مدل‌سازی نیاز آبی زعفران
۴. ارزیابی تأثیر الگوریتم بهینه‌سازی کوآتی (COA) در بهبود عملکرد مدل شبکه عصبی مصنوعی
۵. ارائه یک مدل پیش‌بینی دقیق و قابل اعتماد برای نیاز آبی زعفران: در نهایت، هدف این پژوهش ارائه یک مدل پیش‌بینی دقیق و قابل اعتماد برای نیاز آبی زعفران بوده است که بتوان از آن در مدیریت بهینه منابع آب در مناطق کشت زعفران استفاده کرد.

مواد و روش‌ها

منطقه مورد مطالعه

این پژوهش بر روی ایستگاه مشهد، در شمال شرقی استان

(MP) برای پیش‌بینی مصرف آب ماهانه استانبول مقایسه شده است (Yin et al., 2024). نتایج مطالعه نشان داد که روش پیشنهادی یک تکنیک پیش پردازش قابل اعتماد برای پیش‌بینی تقاضای آب ماهانه است. در مطالعه الزهرانی و ابومنصر (Al-Zahrani & Abo-Monasar, 2015)، تکنیک ترکیبی شبکه‌های عصبی مصنوعی و مدل‌های سری زمانی بر اساس مصرف آب روزانه موجود ساخته شده است. نتایج نشان می‌دهد که مدل‌های ترکیبی اثر پیش‌بینی بهتری دارند. هو و همکاران (Hu et al., 2019)، یک مدل ترکیبی مبتنی بر شبکه عصبی کانولوشن و شبکه‌های حافظه بلندمدت و کوتاه‌مدت دوطرفه برای پیش‌بینی نیاز آبی پیشنهاد کرد. نتایج شبیه‌سازی نشان می‌دهد که مدل پیش‌بینی هیبریدی پیشنهادی دارای خطاهای پیش‌بینی کمتری است. بسیاری از نتایج تحقیقات نشان می‌دهد که مدل پیش‌بینی ترکیبی اثر پیش‌بینی بهتری دارد.

الگوریتم بهینه‌سازی کوآتی در سال‌های اخیر به شدت در زمینه‌های مختلف علمی از جمله مهندسی کشاورزی (Saini et al., 2024) مورد استفاده قرار گرفته است (Elshara et al., 2024; Houssein et al., 2024).

محققان متعددی به منظور پیش‌بینی انرژی بادی و شناسایی مهم‌ترین پارامترهای اقلیمی (سرعت باد، دما و رطوبت) مؤثر بر آن از الگوریتم کوآتی استفاده کردند (Abou Houran et al., 2023; Wang et al., 2024; Zhou et al., 2024). در این مطالعه برای پیش‌بینی نیاز آبی زعفران از الگوریتم بهینه‌سازی جدید کوآتی استفاده شد که در سال ۲۰۲۳ توسط دهقانی و همکاران (Dehghani et al., 2023) ارائه شد. ثامن و همکاران (Sammen et al., 2023) جهت پیش‌بینی سطح آب مخزن که به عواملی مانند پارامترهای آب و هوایی وابسته است با موفقیت از این الگوریتم استفاده کردند. این الگوریتم می‌تواند چندین هدف را به طور همزمان بهینه کند (Yaseen et al., 2019). علاوه بر این، الگوریتم کوآتی قوی است، به این معنی که

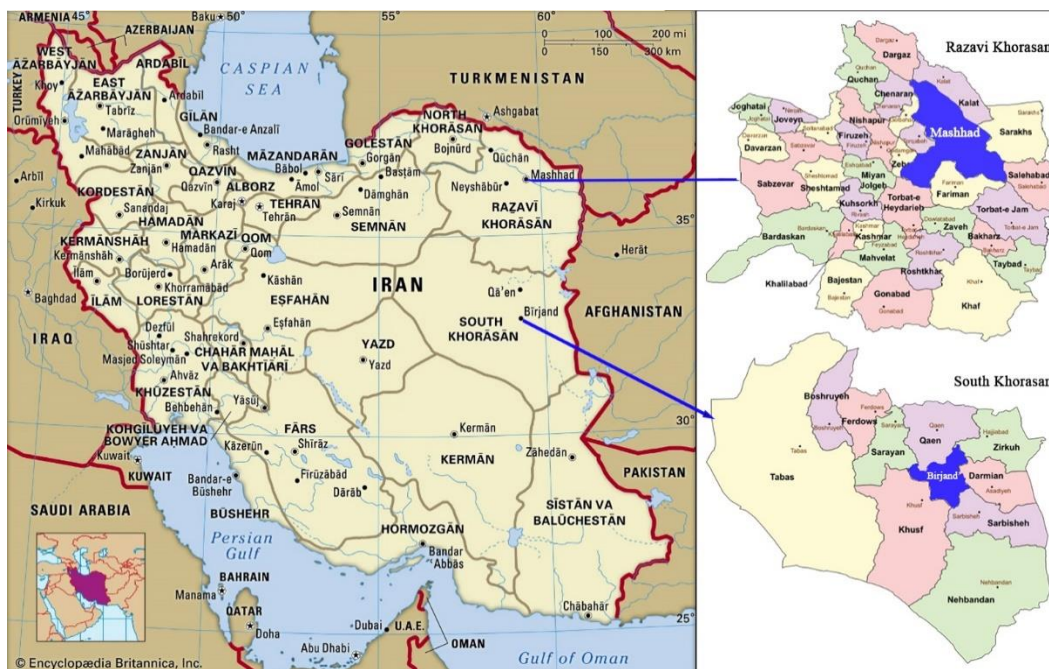
همچنین میانگین تبخیر سالانه در این منطقه ۱۷۴۵/۳۸ میلی‌متر می‌باشد (Niroomandfad et al., 2023). در این پژوهش از اطلاعات ۲۴ ساله (۲۰۰۰-۲۰۲۳) شهرستان‌های مشهد و بیرجند که از سازمان هواشناسی کشور اخذ شد، استفاده شد. این پارامترها شامل دمای میانگین (AT)، دمای حداقل (T_{min}) و دمای حداکثر (T_{max}) برحسب درجه سانتی‌گراد، تعداد ساعات آفتابی (SS)، سرعت باد در ارتفاع ۲ متری (WS)، رطوبت نسبی میانگین (AP) و تشعشع خالص دریافتی (RS) بودند. جدول ۱ آمار توصیفی پارامترهای اقلیمی مورد استفاده در این پژوهش در ایستگاه‌های سینوپتیک مشهد و بیرجند در دوره آماری ۲۰۰۰ الی ۲۰۲۳ نشان می‌دهد.

خراسان رضوی و ایستگاه بیرجند مرکز استان خراسان جنوبی متمرکز است (شکل ۱). میانگین بارندگی سالانه مشهد ۲۶۱ میلی‌متر بوده که با تبخیر و تعرق ۱۷۷۶ میلی‌متر مقابله می‌نماید. با حجم آب تجدیدپذیر ۴۴۳ میلیون مترمکعب، مخزن ۳۰ ساله آب زیرزمینی این شهر، کسری سالانه ۸۲- میلیون مترمکعب را نشان می‌دهد. با مصرف تقریباً ۶۵ درصد آب کشاورزی، شهر مشهد با بیش از ۳ میلیون نفر جمعیت، با چالش‌های آبی قابل توجهی مواجه است. از این رو، یک تلاش هماهنگ با هدف همسویی دیدگاه‌های ذینفعان و ایجاد یک نقشه راه جمعی برای مدیریت منابع آب است (Kolahi et al., 2024). اقلیم شهرستان بیرجند به روش دومارتن خشک بوده و میانگین دمای سالانه ۱۶/۴ درجه سانتی‌گراد و بارش متوسط سالانه ۱۷۱ میلی‌متر و

جدول ۱- آمار توصیفی پارامترهای اقلیمی ایستگاه‌های سینوپتیک مشهد و بیرجند در دوره آماری ۲۰۰۰ تا ۲۰۲۳

Table 1 - Descriptive statistics of climatic parameters at synoptic stations of Mashhad and Birjand during the 2000 to 2023 period

| متغیر (Variable) | سرعت باد (Wind speed) | دمای حداکثر (Maximum temp.) (°C) | دمای حداقل (Minimum temp.) (°C) | دمای میانگین (Average temp.) (°C) | فشار میانگین (Mean pressure) | میانگین فشار بخار (Mean vapor pressure) (hPa) | بارش ۲۴ ساعته (24-hour precipitation) (mm) | رطوبت نسبی (Relative humidity) (%) | ساعات آفتابی (Sunshine hours) (hours) | میزان تابش ۲۴ ساعته (24-hour radiation) (W.m ⁻²) |
|------------------------|-----------------------|----------------------------------|---------------------------------|-----------------------------------|------------------------------|---|--|------------------------------------|---------------------------------------|--|
| مشهد Mashhad | | | | | | | | | | |
| میانگین Mean | 2.49 | 17.41 | 5.25 | 10.83 | 904.59 | 7.17 | 0.88 | 58.1 | 6.57 | 1583.81 |
| انحراف معیار Std. Dev. | 1.22 | 8.74 | 6.74 | 7.68 | 4.74 | 2.75 | 3.13 | 20 | 3.65 | 80.01 |
| واریانس Variance | 1.48 | 76.36 | 45.36 | 58.96 | 22.45 | 7.55 | 9.8 | 399.91 | 13.32 | 6401.56 |
| بیرجند Birjand | | | | | | | | | | |
| میانگین Mean | 2.52 | 19.01 | 2.82 | 10.54 | 851.83 | 4.67 | 0.53 | 40.48 | 8.04 | 1910.61 |
| انحراف معیار Std. Dev. | 1.34 | 7.39 | 6.47 | 6.76 | 3.40 | 2.00 | 2.31 | 19.51 | 2.94 | 103.31 |
| واریانس Variance | 1.79 | 54.66 | 41.82 | 45.77 | 11.57 | 4.01 | 5.35 | 380.72 | 8.66 | 10672.67 |



شکل ۱- نقشه موقعیت جغرافیایی مناطق مورد مطالعه
Figure 1- Geographical location map of the studied area.

تبخیر و تعرق مرجع

محاسبه تبخیر و تعرق (ET) در مدیریت منابع آب، مطالعات هیدرولوژیکی، برنامه‌ریزی آبیاری و مطالعات مدل‌سازی محصول مورد نیاز است (Veysi et al., 2024). روش‌های مختلفی برای تخمین ET یک محصول خاص وجود دارد، با این حال، استفاده از تبخیر و تعرق مرجع (ET_0) و ضریب محصول (K_c) رایج‌ترین رویکرد است (Ramos et al., 2024). فائو به دلیل مناسب بودن روش فائو پنمن مونیتث در مناطق مختلف آب و هوایی، آن را به‌عنوان روش استاندارد برای محاسبه ET_0 توصیه کرد (Bian et al., 2024). در مطالعه حاضر، مقدار ET_0 محاسبه‌شده با استفاده از این روش به‌عنوان مقدار استاندارد در نظر گرفته شد. ET_0 به‌صورت زیر محاسبه شد:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad (1)$$

که در آن ET_0 تبخیر و تعرق مرجع (mm.day^{-1})، فشار بخار اشباع e_s (kPa)، e_a فشار بخار واقعی (kPa)، Δ شیب منحنی

فشار بخار اشباع ($\text{kPa } ^\circ\text{C}^{-1}$)، R_n تابش خورشیدی روزانه رسیده به سطح گیاه ($\text{MJm}^{-2}.\text{day}^{-1}$)، G شار گرما به داخل خاک ($\text{MJm}^{-2}.\text{day}^{-1}$)، γ ثابت سایکرومتری ($\text{kPa}^\circ\text{C}^{-1}$)، U_2 سرعت باد در ارتفاع دومتری (m.s^{-1})، T میانگین دمای هوا ($^\circ\text{C}$) و $e_s - e_a$ کاهش فشار بخار (kPa) می‌باشد.

نیاز آبی محصول (CWR)

نیاز آبی محصول مقدار آبی است که برابر با آنچه از مزرعه کشت‌شده توسط تبخیر و تعرق از دست می‌رود و با نرخ ET برحسب میلی‌متر در روز بیان می‌شود. در این پژوهش برای تخمین نیاز آبی زعفران از روش پیشنهادی سپاسخواه و همکاران (Sepaskhah & Kamgar, 2009) به شرح زیر استفاده شد:

$$ET_{crop} = K_c(ET_0) \quad (2)$$

که در آن K_c ضریب محصول بوده و نسبت ET_c محصول به ET_0 است و نشان‌دهنده ادغام اثرات چهار کیفیت اساسی است که محصول را از علف متمایز می‌کند، و بازتاب سطح

ارائه شده در جدول ۱ استفاده شد (Sepaskhah & Kamgar, 2009). احمدی و همکاران (Ahmadee et al., 2016) برای محاسبه نیاز آبی زعفران از ضریب گیاهی ارائه شده در جدول ۱ بهره گرفتند. همچنین برای تعیین نیاز آبی زعفران در بیرجند از ضریب گیاهی ارائه شده در جدول ۲ استفاده شد (Ghavamsaeidi Noghabi et al., 2020).

محصول-خاک، ارتفاع محصول، مقاومت تاج و تبخیر از خاک را پوشش می‌دهد. با توجه به تفاوت‌های ET در طول مراحل رشد، KC برای محصول در طول دوره رشد متفاوت خواهد بود که می‌توان آن را حداقل به چهار مرحله مجزا تقسیم کرد: اولیه، توسعه محصول، اواسط فصل و اواخر فصل (Ewaid et al., 2019).

برای تعیین نیاز آبی زعفران در مشهد از ضریب گیاهی

جدول ۱- ضریب گیاهی زعفران در طول دوره رشد گیاه (Sepaskhah & Kamgar-Haghighi, 2009)

Table 1- Consumed inputs during the growing season

| ۹ مهر-۹ آبان October | ۹ آبان-۹ آذر November | ۱۰ آذر-۱۰ دی December | ۱۱ دی-۱۱ بهمن January | ۹ بهمن-۹ اسفند February | ۱۰ اسفند-۱۱ فروردین March | ۱۲ فروردین-۱۰ اردیبهشت April | ۱۱ اردیبهشت- ۱۰ خرداد May |
|----------------------------|-----------------------------|-----------------------------|-----------------------------|-------------------------------|---------------------------------|------------------------------------|---------------------------------|
| 0.45 | 0.55 | 0.93 | 1.10 | 0.93 | .68 | 0.50 | 0.42 |

جدول ۲- ضریب گیاهی زعفران در طول دوره رشد گیاه (Ghavamsaeidi Noghabi et al., 2020)

Table 2- Consumed inputs during the growing season

| ۲۴ شهریور-۲۲ مهر 15 September - 14 October | ۲۳ مهر-۱۲ آذر 15 October - 3 December | ۱۳ آذر-۷ بهمن 4 January - 27 December | ۱۲ فروردین-۱۰ اردیبهشت 28 January - 2 April |
|---|--|--|--|
| 0.45 | 0.55 | 0.93 | 0.50 |

رگرسیون درجه دوم از جمله‌های درجه دوم و اثر متقابل برای نمایش پیچیدگی‌های بیشتر در داده‌ها استفاده می‌کند (Matsui, 2020). این مدل با انعطاف پذیری بالا، قادر به شناسایی الگوهای پیچیده‌تری در داده‌ها نسبت به مدل‌های خطی است.

رگرسیون درختی (RT³)

درخت تصمیم رگرسیونی نوعی از درخت تصمیم است که برای پیش‌بینی مقادیر عددی (پیوسته) به کار می‌رود، برخلاف درخت‌های تصمیم طبقه‌بندی که برای پیش‌بینی کلاس‌ها استفاده می‌شوند (Carrizosa et al., 2021). در این نوع درخت، برگ‌های درخت به جای برچسب کلاس، حاوی یک مقدار

روش‌های رگرسیونی

روش تشخیص الگو (PR¹)

تشخیص الگو شاخه‌ای از یادگیری ماشین و هوش مصنوعی است که به شناسایی الگوها و ساختارهای نهفته در داده‌ها می‌پردازد. هدف اصلی آن، طبقه‌بندی خودکار اشیاء، رویدادها یا نمونه‌ها به گروه‌های از پیش تعریف شده یا کشف الگوهای جدید در داده‌های ناشناخته است (Braga-Neto, 2020).

رگرسیون درجه دوم (QR²)


رگرسیون درجه دوم یک روش آماری است که برای مدل‌سازی روابط غیرخطی بین متغیرها به کار می‌رود. برخلاف رگرسیون خطی که تنها روابط خطی را مدل‌سازی می‌کند،

یعنی (2025). یک مدل ANN معمولی دارای سه لایه است، یعنی لایه‌های ورودی، پنهان و خروجی، با تعداد مشخصی گره در هر لایه. کومار و همکاران (Kumar et al., 2011) تأثیر تعداد گره‌ها در لایه پنهان و تعداد لایه‌های پنهان را بر عملکرد تخمین نیاز آبی مورد مطالعه قرار داد. توابع فعال‌سازی، لایه‌های پنهان و آموزش تکراری با هم کار می‌کنند تا ANN را قادر می‌سازد تا روابط پیچیده بین ورودی‌های هواشناسی و خروجی‌های نیاز آبی را بیاموزد (شکل ۲). در ادبیات اخیر، تعیین نیاز آبی روزانه با استفاده از شبکه عصبی مصنوعی رواج یافته است (Hedge et al., 2021; Abrishami et al., 2019).

عددی (مانند قیمت خانه، دمای هوا) هستند. برای ساخت این درخت، از معیارهای تقسیم‌بندی و معیارهای توقف اصلاح‌شده‌ای استفاده می‌شود که مناسب برای داده‌های پیوسته باشند.

شبکه عصبی مصنوعی (ANN)

رویکرد شبکه عصبی مصنوعی ANN مبتنی بر نحوه یادگیری مغز است که این کار با استفاده از چندین نورون در لایه‌های مختلف انجام می‌شود (Tosan & Maroosi, 2024; Alam et al., 2024). توسعه یک معماری ANN مستلزم ساخت توپولوژی‌های شبکه و آموزش شبکه تحت پیکربندی‌های مختلف گره‌های لایه (های) پنهان است (Tosan et al.,)



شکل ۲- رابط شبکه عصبی مورد استفاده برای تخمین نیاز آبی زعفران
Figure 2- Neural network interface used for saffron water requirement prediction.

به‌روزرسانی می‌کند. به این ترتیب، ذرات به سمت مناطق بهینه در فضای جستجو حرکت می‌کنند (Suriyan & Nagarajan, 2024). PSO به دلیل سادگی پیاده‌سازی و کارایی بالا در حل بسیاری از مسائل بهینه‌سازی، بسیار محبوب است.

الگوریتم ژنتیک (GA)

الگوریتم ژنتیک الهام گرفته از فرآیند تکامل زیستی است. در

الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم PSO الهام گرفته از رفتار اجتماعی پرندگان در دسته‌های بزرگ است. در این الگوریتم، هر ذره (حل) در فضا به دنبال بهترین موقعیت می‌گردد. موقعیت هر ذره توسط سرعت و موقعیت آن در فضا تعیین می‌شود. هر ذره در هر تکرار، سرعت و موقعیت خود را بر اساس بهترین موقعیتی که تاکنون تجربه کرده است و بهترین موقعیتی که کل گروه تجربه کرده است،

می‌کند. ایگوانای سبز غذای مورد علاقه کواتی‌ها است. برخی از کواتی‌ها از درختان بالا می‌روند و ایگوانا (مارمولک گیاهخوار) را می‌ترسانند. هنگامی که یک ایگوانا به زمین می‌افتد، سایر کواتی‌ها آن را شکار می‌کنند. شکارچیان ممکن است به کواتی‌ها حمله کنند. کواتی از استراتژی‌های هوشمند برای فرار از دست شکارچیان استفاده می‌کند (Dehghani et al., 2023). فرآیند بهینه‌سازی با جمعیت اولیه آغاز می‌شود. در سطح اول، مکان‌های Co_{ij} مقداردهی اولیه می‌شوند:

$$Co_{ij} = lo_j + ra(up_j - lo_j) \quad (3)$$

که در آن: Co_{ij} : موقعیت آمین کواتی، ra : مقدار تصادفی، lo_j و up_j : مقادیر بالا و پایین مربوط به آمین متغیر تصمیم می‌باشند. کواتی‌ها برای شکار ایگوانا از درخت بالا می‌روند. از آنجایی که ایگوانا می‌ترسد، به زمین می‌افتد. سپس کواتی‌های دیگر به ایگوانا حمله می‌کنند. موقعیت کواتی در حال صعود بر اساس معادله زیر محاسبه می‌شود:

$$Co_j^{p1} = Co_{ij} + r_0(iguana_j - I.Co_{ij}) \quad (4)$$

که در آن: Co_j^{p1} : موقعیت جدید آمین کواتی، Co_{ij} : موقعیت آمین کواتی در بعد i ، I : یک مقدار تصادفی، r_0 : مقدار تصادفی و $iguana_j$ موقعیت ایگوانا می‌باشد. کواتی‌ها مکان خود را بر اساس مکان تصادفی به روز می‌کنند:

$$Iguana^G = lb_j + r_0(up_j - lo_j) \quad (5)$$

$$Co_i^{p1} \quad (6)$$

که در آن: $Iguana^G$: موقعیت ایگوانا، F_{iguana} : مقدار تابع هدف ایگوانا و F_i : مقدار تابع هدف آمین کواتی می‌باشد. در این شرایط، موقعیت ایگوانا بهترین موقعیت را نشان می‌دهد. هنگامی که شکارچیان به کواتی‌ها حمله می‌کنند، از مکان خود

این الگوریتم، یک جمعیت اولیه از راه حل‌ها ایجاد می‌شود. سپس، از طریق عملیات‌هایی مانند انتخاب، ترکیب و جهش، نسل‌های جدیدی از راه حل‌ها تولید می‌شوند. در هر نسل، راه حل‌های بهتر انتخاب شده و برای تولید نسل بعدی استفاده می‌شوند. به مرور زمان، جمعیت به سمت راه حل‌های بهینه همگرا می‌شود (Alhijawi & Awajan, 2024). GA به دلیل توانایی در حل مسائل پیچیده و غیرخطی، به طور گسترده‌ای در زمینه‌های مختلف به کار می‌رود.

الگوریتم بهینه‌سازی شعله پروانه (MFO)

الگوریتم MFO الهام گرفته از رفتار پروانه‌های شب‌پره در پرواز به سمت شعله است. در این الگوریتم، پروانه‌ها (راه حل‌ها) به سمت شعله‌هایی که نمایانگر بهترین راه حل‌ها هستند، حرکت می‌کنند. پروانه‌ها با الهام از الگوی مارپیچی پرواز خود به سمت شعله‌ها حرکت می‌کنند و در عین حال، شعله‌ها نیز به صورت تصادفی در فضا حرکت می‌کنند (Zamani et al., 2024).

الگوریتم بهینه‌سازی کواتی

الگوریتم بهینه‌سازی کواتی (COA) با شبیه‌سازی رفتارهای طبیعی کواتی در هنگام حملات شکارچی به کفتارها و فرار از شکارچیان به هدف دستیابی به نتیجه مطلوب دست می‌یابد (Moayedi et al., 2024). برخلاف الگوریتم‌های بهینه‌سازی هوشمند کلاسیک، مانند الگوریتم ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO)، COA یک سری قوانین را برای ساخت یک مدل ریاضی فرموله می‌کند. مکانیسم جستجوی آن شامل هر دو مرحله اکتشاف و بهره‌برداری است که دارای قابلیت‌های جستجوی جهانی قوی و بهینه‌سازی محلی است و نیازی به تنظیمات اولیه پارامتر ندارد (Lei et al., 2024).

الگوریتم بهینه‌سازی کواتی از زندگی کواتی الهام گرفته شده است. کواتی پستانداری است که در مناطق مختلف جهان زندگی

آفتابی (SS)، سرعت باد در ارتفاع ۲ متری (WS)، رطوبت نسبی میانگین (AP) و تشعشع خالص دریافتی (RS) به صورت روزانه به همراه روز از سال بود و داده‌های خروجی شامل نیاز آبی روزانه زعفران در طول دوره کشت بود. داده‌ها بدون به هم ریختگی به ۵ قسمت تقسیم شدند (چون باید توالی زمانی حفظ شود) و ۸۰ درصد (حدود ۲۰ سال) ابتدایی برای آموزش و ۲۰ درصد انتهایی (حدود ۴ سال) به عنوان صحت سنجی استفاده شد و از شبکه عصبی پیش‌خور استفاده شده است. البته حتی زمانی که قسمت‌های میانی نیز برای ارزیابی در نظر گرفته شد دقت در همین حد بود. تعداد لایه‌های مختلف امتحان شد که بهترین تعداد لایه پنهان برابر با دو لایه که لایه پنهان اول ۱۰ نرون و لایه پنهان دوم ۳ لایه در نظر گرفته شد. بهینه‌سازی لایه پنهان به روش سعی و خطا انجام گردید و پس از بررسی توابع انتقال مختلف، برای لایه‌های پنهان تابع انتقال لوگ سیگموئید و برای لایه خروجی، تابع انتقال خطی در نظر گرفته شد (Fang et al., 2024). برای آپدیت وزن‌ها در شبکه عصبی از الگوریتم لوببرگ-مارکوارت استفاده شد. تمامی این مراحل به کمک نرم‌افزار MATLAB(R2023a) انجام شده است.

ارزیابی مدل

به منظور ارزیابی مدل هیبریدی پیشنهادی، از شاخص‌های آماری مختلفی می‌توان استفاده کرد. شاخص‌های آماری مورد استفاده در این تحقیق شامل روش‌های میانگین مربع خطا (MSE)، مجذور ضریب همبستگی (R^2)، ضریب نش ساتکلیف (NSE) و میانگین خطای کل (BIAS) بود که بر اساس رابطه‌های زیر محاسبه می‌گردند:

$$MSE = \frac{\sum_{i=1}^N (O_i - P_i)^2}{N} \quad (11)$$

$$R^2 = \frac{\sum_{i=1}^N (O_i P_i)^2}{\sum_{i=1}^N O_i^2 \sum_{i=1}^N P_i^2} \quad (12)$$

فرار می‌کنند. معادلات ۱۷ و ۱۸ این رفتار را شبیه‌سازی می‌کنند:

$$Lo_j^{local} = \frac{lo_j}{t}, uo_j^{local} = \frac{uo_j}{t} \quad (7)$$

$$CO_i^{p2} = CO_{ij} + (1 - 2r) \cdot (lo_j^{local} + r_0 (up_j^{local} - lo_j^{local})) \quad (8)$$

که در آن: CO_i^{p2} : موقعیت جدید کواتی، lo_j^{local} : کران پایین محلی زمین متغیر تصمیم و کران بالای زمین متغیر تصمیم و t : تعداد تکرار است. اگر مقدار تابع هدف (OBFV) مکان جدید بهتر از مکان قبلی باشد، کواتی مکان خود را به روز می‌کند. الگوریتم بهینه‌سازی کواتی پیوسته است. برای انتخاب ورودی‌ها به یک نسخه باینری از الگوریتم بهینه‌سازی کواتی نیاز داریم. یک تابع انتقال یک نسخه پیوسته را به نسخه باینری تبدیل می‌کند.

$$Tanh(CO_j^i(t+1)) \quad (9)$$

$$= T(CO_j^i(t+1)) \\ = \frac{e^{(2CO_j^i(t+1))} - 1}{e^{(2CO_j^i(t+1))} + 1}$$

$$\Delta_j^i(t+1) = \begin{cases} 1 & \text{if } (Tanh(CO_j^i(t+1))) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

که در آن: $Tanh(CO_j^i(t+1))$: تابع انتقال، $\Delta_j^i(t+1)$

(1): مقدار باینری، و λ : مقداری تصادفی می‌باشد.

در این تحقیق کارایی مدل هیبریدی هوش مصنوعی الگوریتم بهینه‌ساز کواتی ANN-COA در مقایسه با مدل شبکه عصبی مصنوعی و الگوریتم‌های هیبریدی الگوریتم ژنتیک (ANN-GA) ازدحام ذرات (ANN-PSO) و شعله پروانه (ANN-MFO) و سایر روش‌های داده‌کاوی شامل رگرسیون مرتبه دوم (QR)، رگرسیون درختی (TR) و رگرسیون الگوی (Pattern) در تخمین نیاز آبی زعفران در طول دوره کشت بررسی شد. داده‌های ورودی به مدل شبکه عصبی و مدل‌های هیبریدی عبارت از دمای میانگین (AT)، دمای حداقل (T_{min}) و دمای حداکثر (T_{max}) برحسب درجه سانتی‌گراد، تعداد ساعات

پنهان به روش سعی و خطا انجام گردید و پس از بررسی توابع انتقال مختلف، برای لایه‌های پنهان تابع انتقال لوگ سیگموئید و برای لایه خروجی، تابع انتقال خطی در نظر گرفته شد (Fang et al., 2024). برای آپدیت وزن‌ها در شبکه عصبی از الگوریتم لونیگ-مارکوارت استفاده شد. تمامی این مراحل به کمک نرم‌افزار MATLAB(R2023a) انجام شده است.

آنالیز آماری با رتبه‌بندی بین شاخص‌ها انجام گردید. نتایج مدل‌سازی نیاز آبی زعفران با مدل شبکه عصبی مصنوعی و مدل هیبریدی شبکه عصبی مصنوعی ANN-COA و سایر روش‌های هیبریدی (جدول ۳ و ۴) نشان داد که مدل هیبریدی شبکه عصبی ANN-COA با $MSE=0/0001$ و $R^2=0/995$ برای ایستگاه مشهد و $MSE=0/0005$ و $R^2=0/973$ برای ایستگاه بیرجند، دقت قابل قبولی در تخمین نیاز آبی زعفران در این مناطق دارد. ژاو و همکاران (Zhao et al., 2024) با استفاده از داده‌های هواشناسی، خاک و گیاه، یک مدل شبکه عصبی هیبریدی برای پیش‌بینی نیاز آبی ذرت در شمال چین ایجاد کرد که در مقایسه با سایر مدل‌ها دقت بالاتری داشت.

در مجموع نتایج مشابهی در هر دو ایستگاه به دست آمد. ترکیبات ورودی چهار مدل اول شامل دمای حداکثر، حداقل و میانگین) و ترکیب آن به ترتیب با سرعت باد، رطوبت نسبی و تابش خالص به همراه روز از سال را با توجه به سطوح همبستگی آن‌ها در هر ایستگاه در نظر گرفتند. از بین این چهار نوع مختلف داده‌های هواشناسی ورودی، به نظر می‌رسد دما بیشترین تأثیر را بر نیاز آبی زعفران در هر دو ایستگاه دارد و به دنبال آن سرعت باد قرار دارد. بر این اساس، دو ترکیب بعدی از داده‌های ورودی، شامل سرعت باد به علاوه ترکیب آن با دمای حداکثر بودند. همان‌طور که در جداول ۱ و ۲ نشان داده شده است، استفاده تعداد بیشتری از متغیرهای ورودی هواشناسی به‌طور کلی مقادیر بالاتری از R^2 و مقادیر کمتری از MSE را ایجاد کردند. تمام مدل‌های ANN با داده‌های ورودی C7 تخمین‌هایی بسیار

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{P}_i)^2} \right] \quad (13)$$

$$BIAS = \frac{\sum_{i=1}^N (O_i - P_i)}{n} \quad (14)$$

در این روابط، O_i نیاز آبی زعفران بر اساس روش ضریب گیاهی، P_i نیاز آبی زعفران محاسبه شده به هر روش، \bar{P}_i میانگین نیاز آبی محاسبه شده به هر روش و N تعداد داده‌ها می‌باشند.

نتایج و بحث

در این تحقیق کارایی مدل هیبریدی هوش مصنوعی با الگوریتم بهینه‌ساز کواتی ANN-COA در مقایسه با مدل شبکه عصبی مصنوعی و الگوریتم‌های هیبریدی الگوریتم ژنتیک (ANN-GA) از دام ذرات (ANN-PSO) و شعله پروانه (ANN-MFO) و سایر روش‌های داده‌کاوی شامل رگرسیون مرتبه دوم (QR)، رگرسیون درختی (TR) و رگرسیون الگوی (Pattern) در تخمین نیاز آبی زعفران در طول دوره کشت بررسی شد. داده‌های ورودی به مدل شبکه عصبی و مدل‌های هیبریدی عبارت از دمای میانگین (AT)، دمای حداقل (T_{min}) و دمای حداکثر (T_{max}) برحسب درجه سانتی‌گراد، تعداد ساعات آفتابی (SS)، سرعت باد در ارتفاع ۲ متری (WS)، رطوبت نسبی میانگین (AP) و تشعشع خالص دریافتی (RS) به صورت روزانه به همراه روز از سال بود و داده‌های خروجی شامل نیاز آبی روزانه زعفران در طول دوره کشت بود. داده‌ها بدون به هم‌ریختگی به ۵ قسمت تقسیم شدند (چون باید توالی زمانی حفظ شود) و ۸۰ درصد (حدود ۲۰ سال) ابتدایی برای آموزش و ۲۰ درصد انتهایی (حدود ۴ سال) به عنوان صحت‌سنجی استفاده شد و از شبکه عصبی پیش‌خور استفاده شده است. البته حتی زمانی که قسمت‌های میانی نیز برای ارزیابی در نظر گرفته شد دقت در همین حد بود. تعداد لایه‌های مختلف امتحان شد که بهترین تعداد لایه پنهان برابر با دو لایه که لایه پنهان اول ۱۰ نورون و لایه پنهان دوم ۳ نورون در نظر گرفته شد. بهینه‌سازی لایه

COA تقریباً برابر با یک بود.

نزدیک به معادله FAO56-PM تولید کردند و مدل ANN-

COA حداقل MSE را ارائه کرد و مقدار R² برای مدل ANN-

جدول ۳- ارزیابی مدل‌های مختلف هیبریدی و داده‌کاوی در برآورد نیاز آبی زعفران با استفاده از داده‌های هواشناسی روزانه در ایستگاه مشهد
 Table 3- Evaluation of different hybrid models and data mining in estimation of Saffron water requirement using daily meteorological data in Mashhad station

| ترکیب Composition | متغیرهای ورودی Input variables | ارزیابی مدل Model evaluation | | | | | | | | | |
|----------------------|---|---------------------------------|----------------|--------|---------|---------|--------|--------|---------|---------|---------|
| | | MSE | R ² | QR | Pattern | RegTree | ANN | ANN-GA | ANN-PSO | ANN-MFO | ANN-COA |
| C1 | n, T _{min} , T _{max} , AT | 0.0043 | 0.0042 | 0.0053 | 0.0030 | 0.0046 | 0.0030 | 0.0030 | 0.0030 | 0.0020 | |
| | | 0.719 | 0.721 | 0.65 | 0.802 | 0.7 | 0.802 | 0.802 | 0.802 | 0.842 | |
| C2 | n, T _{min} , T _{max} , AT, WS | 0.0016 | 0.0010 | 0.0014 | 0.0004 | 0.0022 | 0.0030 | 0.0005 | 0.0005 | | |
| | | 0.897 | 0.935 | 0.91 | 0.97 | 0.859 | 0.801 | 0.969 | 0.976 | | |
| C3 | n, T _{min} , T _{max} , AT, RH | 0.0036 | 0.0032 | 0.0049 | 0.0026 | 0.0043 | 0.0002 | 0.0019 | | | |
| | | 0.792 | 0.787 | 0.679 | 0.831 | 0.716 | 0.693 | 0.834 | 0.878 | | |
| C4 | n, T _{min} , T _{max} , AT, Rs | 0.0043 | 0.0040 | 0.0055 | 0.0033 | 0.0049 | 0.0032 | 0.0032 | | | |
| | | 0.716 | 0.737 | 0.636 | 0.783 | 0.68 | 0.69 | 0.786 | 0.842 | | |
| C5 | n, WS | 0.0070 | 0.0070 | 0.0092 | 0.0067 | 0.0070 | 0.0072 | 0.0067 | | | |
| | | 0.541 | 0.544 | 0.405 | 0.564 | 0.541 | 0.531 | 0.567 | 0.6197 | | |
| C6 | n, T _{max} , WS | 0.0019 | 0.0013 | 0.0013 | 0.0005 | 0.0024 | 0.0020 | 0.0005 | | | |
| | | 0.875 | 0.917 | 0.916 | 0.966 | 0.842 | 0.869 | 0.965 | 0.972 | | |
| C7 | n, T _{min} , T _{max} , AT, WS, AP, VP, RF, RH, SS, Rs | 0.0011 | 0.0012 | 0.0014 | 0.0001 | 0.0023 | 0.0028 | 0.0001 | | | |
| | | 0.924 | 0.92 | 0.906 | 0.993 | 0.87 | 0.818 | 0.992 | 0.995 | | |

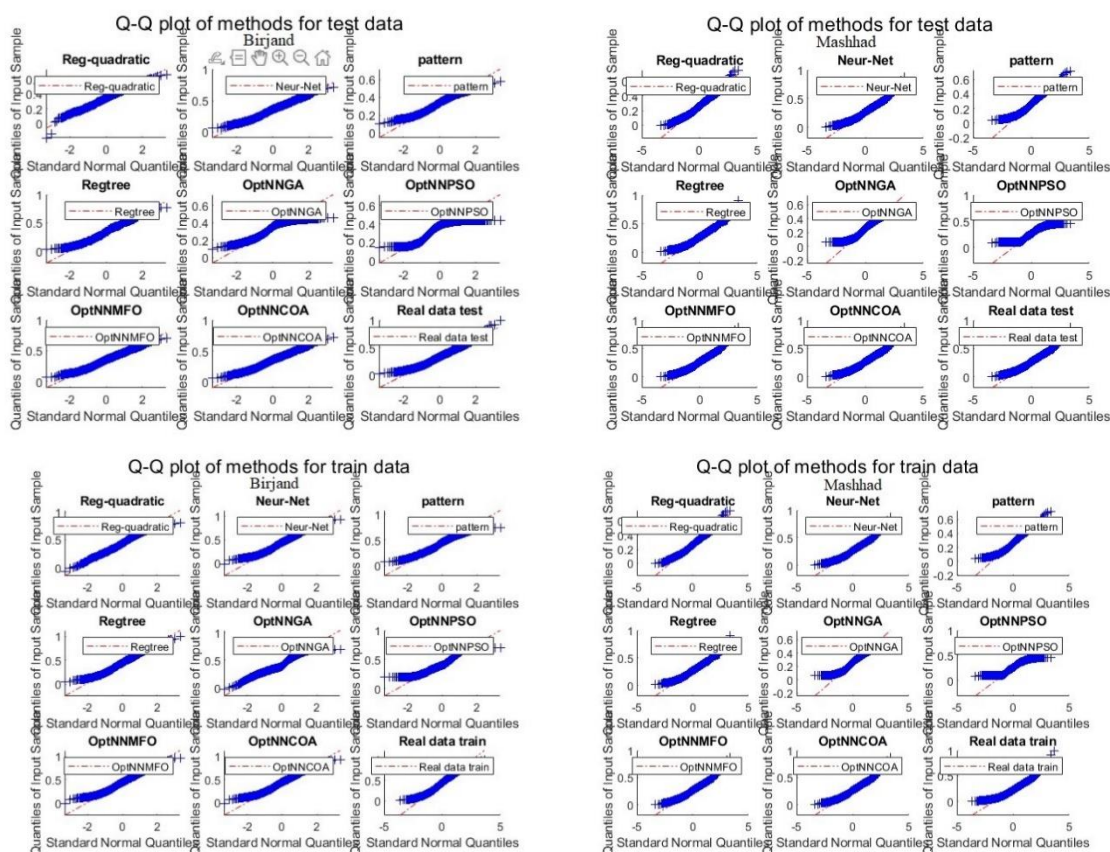
جدول ۴- ارزیابی مدل‌های مختلف هیبریدی و داده‌کاوی در برآورد نیاز آبی زعفران با استفاده از داده‌های هواشناسی روزانه در ایستگاه بیرجند

Table 4- Evaluation of different hybrid models and data mining in estimation of Saffron water requirement using daily meteorological data in Birjand station

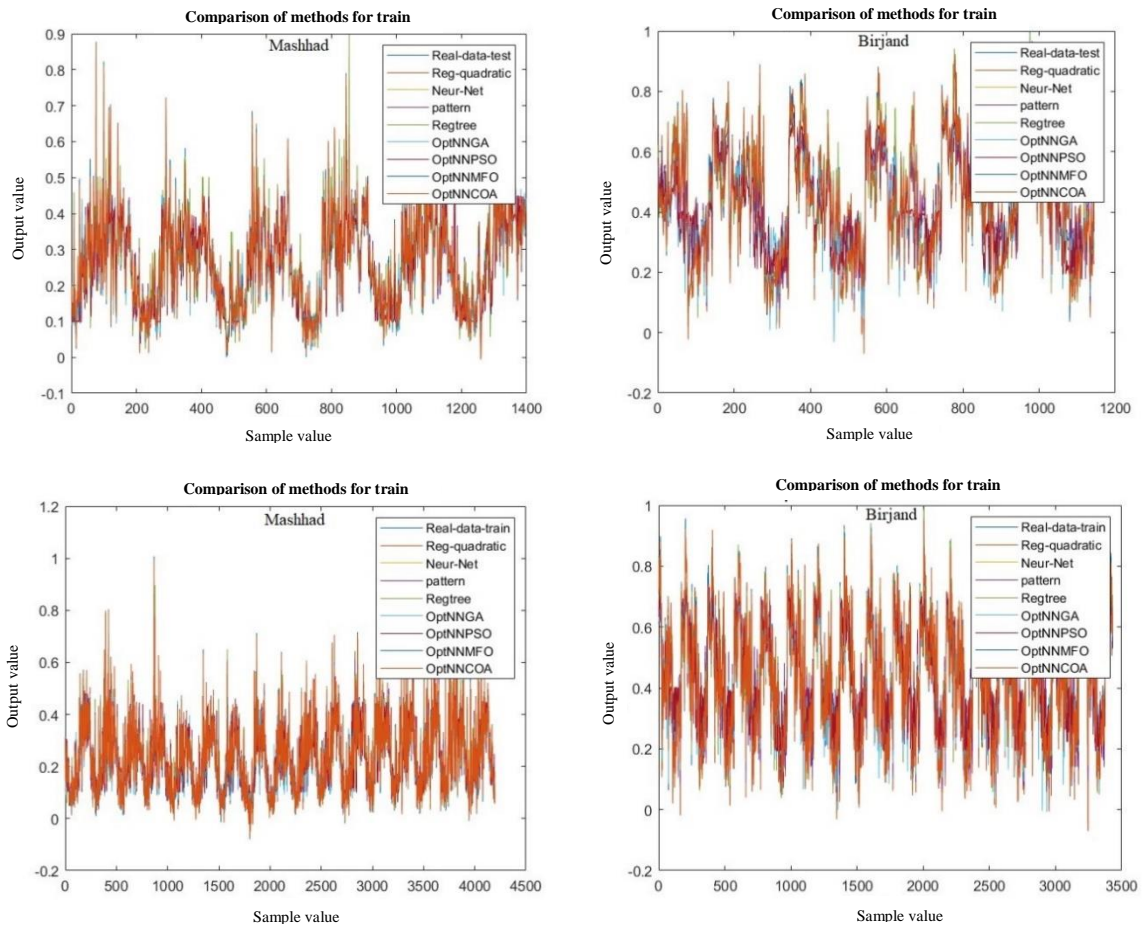
| ترکیب Composition | متغیرهای ورودی Input variables | ارزیابی مدل Model evaluation | | | | | | | | | |
|----------------------|---|---------------------------------|---------|---------|--------|--------|---------|---------|---------|--------|-------|
| | | QR | Pattern | RegTree | ANN | ANN-GA | ANN-PSO | ANN-MFO | ANN-COA | Model | Model |
| C1 | n, T _{min} , T _{max} , AT | MSE | 0.01355 | 0.0124 | 0.0133 | 0.0105 | 0.0146 | 0.0158 | 0.0103 | 0.0104 | |
| | | R ² | 0.179 | 0.246 | 0.157 | 0.326 | 0.475 | 0.430 | 0.338 | 0.717 | |
| C2 | n, T _{min} , T _{max} , AT, WS | MSE | 0.0064 | 0.0055 | 0.0016 | 0.0005 | 0.0091 | 0.0005 | 0.0005 | 0.0005 | |
| | | R ² | 0.659 | 0.723 | 0.912 | 0.971 | 0.543 | 0.506 | 0.969 | 0.972 | |
| C3 | n, T _{min} , T _{max} , AT, RH | MSE | 0.0110 | 0.0104 | 0.0100 | 0.0075 | 0.0130 | 0.0135 | 0.0077 | 0.0076 | |
| | | R ² | 0.357 | 0.348 | 0.352 | 0.513 | 0.222 | 0.233 | 0.497 | 0.774 | |
| C4 | n, T _{min} , T _{max} , AT, Rs | MSE | 0.0141 | 0.0111 | 0.0123 | 0.0130 | 0.0147 | 0.0150 | 0.0110 | 0.0113 | |
| | | R ² | 0.111 | 0.240 | 0.195 | 0.167 | 0.165 | 0.158 | 0.254 | 0.742 | |
| C5 | n, WS | MSE | 0.0125 | 0.0066 | 0.0049 | 0.0041 | 0.0097 | 0.0095 | 0.0042 | 0.0041 | |
| | | R ² | 0.342 | 0.65 | 0.75 | 0.79 | 0.493 | 0.51 | 0.784 | 0.791 | |
| C6 | n, T _{max} , WS | MSE | 0.0067 | 0.0037 | 0.0015 | 0.0008 | 0.0084 | 0.0087 | 0.0008 | 0.0007 | |
| | | R ² | 0.64 | 0.8 | 0.922 | 0.955 | 0.574 | 0.531 | 0.955 | 0.956 | |
| C7 | n, T _{min} , T _{max} , AT, WS, AP, VP, RF, RH, SS, Rs | MSE | 0.007 | 0.001 | 0.0056 | 0.0029 | 0.0091 | 0.0095 | 0.0011 | 0.0005 | |
| | | R ² | 0.747 | 0.793 | 0.848 | 0.973 | 0.613 | 0.59 | 0.971 | 0.973 | |

جدول ۵- ارزیابی مدل‌های مختلف هیبریدی و داده‌کاوی در برآورد نیاز آبی زعفران بر اساس معیارهای نش-ساتکلیف و بایاس
 Table 5- Evaluation of different hybrid models and data mining in estimating the water requirement of saffron based on Nash-Sutcliffe and Bias criteria.

| | QR | Pattern | RegTree | ANN | ANN-GA | ANN-PSO | ANN-MFO | ANN-COA |
|-----------------------|--------|---------|---------|--------|--------|---------|---------|---------|
| مشهد Mashhad | | | | | | | | |
| NSE-test | 0.9441 | 0.9564 | 0.9850 | 0.9961 | 0.8537 | 0.8005 | 0.9935 | 0.9961 |
| NSE-Train | 0.9241 | 0.9497 | 0.9064 | 0.9947 | 0.8310 | 0.7788 | 0.9915 | 0.9947 |
| BIAS-Train | 0.0000 | 0.0001 | 0.0000 | 0.0001 | 0.0017 | 0.0014 | 0.0001 | 0.0000 |
| BIAS-Test | 0.0001 | -0.0005 | -0.0010 | 0.0000 | 0.0007 | -0.0010 | -0.0004 | 0.0000 |
| بیرجند Birjand | | | | | | | | |
| NSE-test | 0.9441 | 0.8176 | 0.9939 | 0.9961 | 0.8537 | 0.8005 | 0.9935 | 0.9961 |
| NSE-Train | 0.9241 | 0.8023 | 0.9554 | 0.9947 | 0.8310 | 0.7788 | 0.9915 | 0.9947 |
| BIAS-Train | 0.0000 | -0.0002 | 0.0000 | 0.0001 | 0.0017 | 0.0014 | 0.0001 | 0.0000 |
| BIAS-Test | 0.0001 | -0.0004 | -0.0014 | 0.0000 | 0.0007 | -0.0010 | -0.0004 | 0.0000 |



شکل ۳- نمودارهای Q-Q برای مراحل واسنجی و صحت‌سنجی مدل‌های مورد مطالعه
 Figure 3 - Q-Q plots for calibration and validation phases of the studied models.



شکل ۴- نمودارهای سری زمانی برای مراحل واسنجی و صحت‌سنجی مدل‌های مورد مطالعه
Figure 4- Time series plots for calibration and validation phases of the studied models.

سرعت باد به‌همراه روز از سال، به‌ترتیب ۰/۹۷۳ و ۰/۰۰۰۵ در ایستگاه مشهد و ۰/۹۵۶ و ۰/۰۰۰۷ در ایستگاه بیرجند بودند. نتایج آنالیز آماری مدل‌های ANN-GA و ANN-PSO، ANN-MFO در جدول ۳ و ۴ درج شده است. برای مدل ANN-COA شاخص‌های آماری R^2 و MSE برای ایستگاه مشهد و بیرجند محاسبه گردید که نسبت به روش‌های ANN-GA، ANN-PSO و ANN-MFO عملکرد به‌مراتب بهتری دارد، اما در مجموع بر اساس نتایج این پژوهش، مدل‌های شبکه عصبی هیبریدی عملکرد بهتری از سایر روش‌های داده‌کاوی دارند. البتاقی و همکاران (Elbeltagi et al., 2020) برای محاسبه نیاز آبی محصول ذرت در مصر از مدل‌های شبکه عصبی مصنوعی بهره برد و نتایج نشان داد استفاده از مدل‌های

پس از اضافه شدن سرعت باد به‌عنوان ورودی مدل (C2)، دقت مدل نسبت به زمانی که صرفاً دما (C1) به‌عنوان ورودی مدل در نظر گرفته شد، به شدت بهبود یافت، از طرفی مقایسه نتایج ترکیب C3 و C4 با C1 نشان می‌دهد دقت مدل با اضافه شدن تشعشع خالص و یا رطوبت نسبی به دما، به مقدار نسبتاً کمتری بهبود یافت. دلیل آن می‌تواند این باشد که تابش خالص یک رابطه قوی با متغیرهای دما (T_{min} و T_{max}) دارد (Tosan et al., 2024). به‌همین ترتیب، افزودن رطوبت نسبی و تشعشع خالص منجر به افزایش اندکی در R^2 شد (C3 و C4). با توجه به استفاده از ورودی داده‌های هواشناسی محدود و دقت تخمین، بهترین مدل ANN مدل ANN-ARO با C6 بود که در آن مقادیر R^2 ، MSE با استفاده از پارامتر دمای حداکثر و

بین مدل‌های هیبریدی مورد بررسی در این پژوهش، مدل‌های ANN-GA و ANN-PSO که توسط محققان بسیاری مورد استفاده قرار گرفته‌اند، نسبت به مدل‌های ANN-COA و ANN-MFO عملکرد ضعیف‌تری داشتند؛ درحالی‌که نتایج این پژوهش نشان می‌دهد در شرایطی که با پارامترهای هواشناسی محدود مواجهیم، مدل هیبریدی ANN-COA عملکرد به مراتب بهتری نسبت به سایر روش‌ها دارد. به‌طور کلی، مدل ANN-COA مورد استفاده در این مطالعه عملکرد مناسبی را در تخمین نیاز آبی زعفران نشان داد، درحالی‌که برای شرایطی که صرفاً از پارامترهای دما (حداقل، حداکثر و متوسط) یا سرعت باد استفاده شد (C1 و C5)، این مدل دقت بالاتری با قابلیت امیدوارکننده‌ای برای تخمین نیاز آبی زعفران نشان داد و ترکیب C6 نیز با ترکیب این دو پارامتر هواشناسی، ترکیب‌های ورودی مناسب‌تری از نظر استحکام مدل و ورودی مدل محدود بودند. از طریق این بررسی، می‌توان تعمیم داد که اگر قرار است پیش‌بینی با استفاده از یک پارامتر ورودی انجام شود، یکی از پارامترهای ورودی یعنی دما (T_{min} ، T_{max} ، AT) یا سرعت باد (WS) باید برای رسیدن به سطح قابل قبول صحت پیش‌بینی در دسترس باشد. همچنین در شرایط استفاده از پارامترهای کامل هواشناسی نیز مدل هیبریدی ANN-COA در هر دو ایستگاه بیرجند و مشهد هر دو بهترین عملکرد را در تخمین نیاز آبی زعفران داشتند.

سپاسگزاری

این تحقیق در قالب طرح پژوهشی به شماره ابلاغیه ۱۴۰۲/د/۲۴۰۷۲ مورخ ۱۴۰۲/۱۲/۱۹ و با استفاده از اعتبارات پژوهشی دانشگاه بیرجند انجام شده است که بدینوسیله تشکر و قدردانی می‌شود.

هیبریدی نتایج بهتری ایجاد کرده و می‌توانند به ارتقای تصمیم‌گیری برای مدیران آب و برنامه‌ریزان توسعه کمک کنند. زارع ابیانه و همکاران (Abyaneh et al., 2011) نیز برای تعیین نیاز آبی محصول سیر در منطقه همدان از مدل شبکه عصبی مصنوعی با موفقیت استفاده کرد. جدول ۵ ضرایب نش ساتکلیف و بایاس محاسبه شده و شکل ۳ و ۴ نمودارهای Q-Q و سری زمانی را برای مراحل واسنجی و صحت‌سنجی مدل‌های مورد مطالعه را نشان می‌دهد.

نتیجه‌گیری

این مطالعه یک رویکرد بهینه‌سازی جدید مبتنی بر الگوریتم بهینه‌سازی کواتی (COA) را معرفی می‌کند که یادگیری مبتنی بر مخالفت و نظریه آشوب را ادغام می‌کند. در این پژوهش جهت پیش‌بینی نیاز آبی زعفران از الگوریتم هیبریدی COA بهره‌گرفته شد که دلیل این انتخاب، مزایای پرشمار آن می‌باشد. الگوریتم بهینه‌سازی کواتی را می‌توان در زمینه‌های مختلفی مانند مهندسی، اقتصاد و تجارت استفاده کرد. بنابراین الگوریتم بهینه‌سازی کواتی از انعطاف‌پذیری بالایی برخوردار است. برخلاف روش‌های موجود، هدف COA به حداکثر رساندن دقت پیش‌بینی نیاز آبی با ادغام مؤثر پارامترهای اقلیمی است. این استراتژی نشان‌دهنده پیشرفت قابل توجهی نسبت به الگوریتم‌های سنتی است، همان‌طور که با یافته‌های تجربی نشان‌دهنده بهبود دقت تنظیم پارامتر و افزایش قابل توجه در رتبه‌بندی فریدمن است. مقایسه بین مدل‌های مختلف نشان داد که عملکرد مدل‌های هیبریدی هوش مصنوعی به‌طور کلی نسبت به سایر مدل‌های داده‌کاوی برتر بود. همچنین در بین سایر روش‌های داده‌کاوی، مدل رگرسیون درختی بهترین عملکرد را داشت. این مدل‌ها، روابط ساده‌ای برای برآورد نیاز آبی زعفران اراده می‌کند که هرکدام از این روابط برای شرایط خاصی از دما، رطوبت، ساعات آفتابی، سرعت باد و غیره صادق می‌باشند. در

منابع

- Abou Houran, M., Bukhari, S. M. S., Zafar, M. H., Mansoor, M., & Chen, W. (2023). COA-CNN-LSTM: Coati optimization algorithm-based hybrid deep learning model for PV/wind power forecasting in smart grid applications. *Applied Energy*, 349, 121638. <https://doi.org/10.1016/j.apenergy.2023.121638>
- Abrishami, N., Sepaskhah, A. R., & Shahrokhnia, M. H. (2019). Estimating wheat and maize daily evapotranspiration using artificial neural network. *Theoretical & Applied Climatology*, 135, 945-958. <https://doi.org/10.1007/s00704-018-2418-4>
- Abualigah, L., Almotairi, K. H., & Elaziz, M. A. (2023). Multilevel thresholding image segmentation using meta-heuristic optimization algorithms: Comparative analysis, open challenges and new trends. *Applied Intelligence*, 53 (10), 11654-11704. <https://doi.org/10.1007/s10489-022-04064-4>
- Abyaneh, H. Z., Nia, A. M., Varkeshi, M. B., Marofi, S., & Kisi, O. (2011). Performance evaluation of ANN and ANFIS models for estimating garlic crop evapotranspiration. *Journal of Irrigation & Drainage Engineering*, 137 (5), 280-286. [https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0000298](https://doi.org/10.1061/(ASCE)IR.1943-4774.0000298)
- Ahmadee, M., Khashei Siuki, A., & Sayyari, M. (2016). Comparison of efficiency of different equations to estimate the water requirement in saffron (*Crocus sativus* L.) (Case study: Birjand plain, Iran). *Journal of Agroecology*, 8 (4), 505-520. (In Persian with English abstract). <https://doi.org/10.22067/JAG.V8I4.40517>
- Ahmed, F. (2018). An IoT-big data based machine learning technique for forecasting water requirement in irrigation field. Research and Practical Issues of Enterprise Information Systems: 11th IFIP WG 8.9 Working Conference, CONFENIS 2017, Shanghai, China, October 18-20, 2017, Revised Selected Papers 11, https://doi.org/10.1007/978-3-319-94845-4_7
- Akbari, A., Ziaei, A. N., Naghedifar, S. M., Moghaddam, P. R., & Sharafkhane, M. G. (2024). Simulation of saffron growth using AquaCrop model with high-resolution measured data. *Scientia Horticulturae*, 324, 112569. <https://doi.org/10.1016/j.scienta.2023.112569>
- Al-Zahrani, M. A., & Abo-Monasar, A. (2015). Urban residential water demand prediction based on artificial neural networks and time series models. *Water Resources Management*, 29, 3651-3662. <https://doi.org/10.1007/s11269-015-1021-z>
- Alam, M. M., Akter, M. Y., Islam, A. R. M. T., Mallick, J., Kabir, Z., Chu, R., Arabameri, A., Pal, S. C., Al Masud, M. A., & Costache, R. (2024). A review of recent advances and future prospects in calculation of reference evapotranspiration in Bangladesh using soft computing models. *Journal of Environmental Management*, 351, 119714. <https://doi.org/10.1016/j.jenvman.2023.119714>
- Alhijawi, B., & Awajan, A. (2024). Genetic algorithms: Theory, genetic operators, solutions, and applications. *Evolutionary Intelligence*, 17 (3), 1245-1256. <https://doi.org/10.1007/s12065-023-00822-6>
- Aliakbari, P., Salari, A., & KhasheiSiuki, A. (2018). Determine of the actual and potential evapotranspiration and appropriate model for determining water requirement of saffron (Case study: Torbat Heydarieh). *Iranian Journal of Ecohydrology*, 5 (3), 1051-1061. (In Persian with English abstract). <https://doi.org/10.22059/IJE.2018.252321.830>
- Anele, A. O., Hamam, Y., Abu-Mahfouz, A. M., & Todini, E. (2017). Overview, comparative

- assessment and recommendations of forecasting models for short-term water demand prediction. *Water*, 9 (11), 887. <https://doi.org/10.3390/w9110887>
- Azari, P., Sobhanardakani, S., Cheraghi, M., Lorestani, B., & Goodarzi, A. (2024). A fuzzy interval dynamic optimization model for surface and groundwater resources allocation under water shortage conditions, the case of West Azerbaijan Province, Iran. *Environmental Science & Pollution Research*, 1-14. <https://doi.org/10.1007/s11356-024-32919-5>
- Bian, J., Hu, X., Shi, L., Min, L., Zhang, Y., Shen, Y., Zhao, F., Zha, Y., Lian, X., & Huang, J. (2024). Improving the evapotranspiration estimation by considering the effect of flux footprint climatology. *Journal of Hydrology*, 631, 130769. <https://doi.org/10.1016/j.jhydrol.2024.130769>
- Braga-Neto, U. (2020). *Fundamentals of Pattern Recognition and Machine Learning*. Springer.
- Carrizosa, E., Molero-Río, C., & Romero Morales, D. (2021). Mathematical optimization in classification and regression trees. *Top*, 29 (1), 5-33. <https://doi.org/10.1007/s11750-021-00594-1>
- Dehghani, M., Montazeri, Z., Trojovská, E., & Trojovský, P. (2023). Coati optimization algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems. *Knowledge-Based Systems*, 259, 110011. <https://doi.org/10.1016/j.knosys.2022.110011>
- Elbeltagi, A., Deng, J., Wang, K., & Hong, Y. (2020). Crop water footprint estimation and modeling using an artificial neural network approach in the Nile Delta, Egypt. *Agricultural Water Management*, 235, 106080. <https://doi.org/10.1016/j.agwat.2020.106080>
- Elshara, R., Hançerlioğullari, A., Rahebi, J., & Lopez-Guede, J. M. (2024). PV cells and modules parameter estimation using coati optimization algorithm. *Energies*, 17 (7), 1716. <https://doi.org/10.3390/en17071716>
- Ewaid, S. H., Abed, S. A., & Al-Ansari, N. (2019). Crop water requirements and irrigation schedules for some major crops in Southern Iraq. *Water*, 11 (4), 756. <https://doi.org/10.3390/w11040756>
- Fallahi, H.-r., & Mahmoodi, S. (2018). Influence of organic and chemical fertilization on growth and flowering of saffron under two irrigation regimes. *Saffron Agronomy & Technology*, 6 (2), 147-166 (In Persian with English abstract). <https://doi.org/10.22048/jsat.2017.71511.1207>
- Fallahi, H. R., Zamani, G., Aghhavana Shajari, M., Samadzadeh, A., Branca, F., & Mehrabani, M. (2017). Saffron flower and stigma yield changes in response to application of different levels of super absorbent polymer. *Journal of Medicinal Plants & By-Product*, 6 (2), 145-151. <https://doi.org/10.22092/JMPB.2017.113537>
- Fang, S. L., Lin, Y. S., Chang, S. C., Chang, Y. L., Tsai, B. Y., & Kuo, B. J. (2024). Using artificial intelligence algorithms to estimate and short-term forecast the daily reference evapotranspiration with limited meteorological variables. *Agriculture*, 14 (4), 510. <https://doi.org/10.3390/agriculture14040510>
- Feizi, H., & Tosan, M. (2016). Saffron yield variability by climatic factors in the northeast of Iran. In V International Symposium on Saffron Biology and Technology: Advances in Biology, Technologies, Uses and Market 1184 (pp. 109-114). <https://doi.org/10.17660/ActaHortic.2017.1184.15>
- Gandomkar, A., Ezzatian, V., Behyar, M., Ghayoor, H., & Rajabi, Z. (2015). Estimation evapotranspiration by Penman Monteith method and its water require in Isfahan province. *Geographical Research*, 30 (116), 239-252.
- Ghavamsaeidi Noghabi, S., Khashei-Siuki, A., Hammami, H., Shahidi, A., & Yaghoobzadeh, M. (2020). Determination of evapotranspiration and crop coefficient of saffron (*Crocus sativus* L.) by lysimetric method in the dry-desert

- climate of Birjand. *Journal of Saffron Research*, 8 (1), 161-172. (In Persian with English abstract).
<https://doi.org/10.22077/jsr.2019.2515.1101>
- Goyal, P., Kumar, S., & Sharda, R. (2023). A review of the Artificial Intelligence (AI) based techniques for estimating reference evapotranspiration: Current trends and future perspectives. *Computers & Electronics in Agriculture*, 209, 107836.
<https://doi.org/10.1016/j.compag.2023.107836>
- Guo, X., Sun, X., & Ma, J. (2011). Prediction of daily crop reference evapotranspiration (ET0) values through a least-squares support vector machine model. *Hydrology Research*, 42 (4), 268-274.
<https://doi.org/10.1016/j.aej.2020.03.020>
- Han, S., Cao, Y., Wu, X., Xu, J., Nie, Z., & Qiu, Y. (2024). New horizons for the study of saffron (*Crocus sativus* L.) and its active ingredients in the management of neurological and psychiatric disorders: A systematic review of clinical evidence and mechanisms. *Phytotherapy Research*, 38 (5), 2276-2302
<https://doi.org/10.1002/ptr.8110>
- Hegde, M. A., Naik, M. S., Chaitra, S., Madhavi, M., & Ravichandra, A. (2021). Prediction and analysis of water requirement in automated irrigation system using artificial neural network (ANN) and lora technology. 2021 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER).
<https://doi.org/10.1109/DISCOVER52564.2021.9663706>
- Houssein, E. H., Hammad, A., Emam, M. M., & Ali, A. A. (2024). An enhanced Coati Optimization Algorithm for global optimization and feature selection in EEG emotion recognition. *Computers in Biology & Medicine*, 173, 108329.
<https://doi.org/10.1016/j.compbio.2024.108329>
- Hu, P., Tong, J., Wang, J., Yang, Y., & de Oliveira Turci, L. (2019). A hybrid model based on CNN and Bi-LSTM for urban water demand prediction. 2019 IEEE Congress on Evolutionary Computation (CEC),
<https://doi.org/10.1109/CEC.2019.8790060>
- Jafarzadeh, A., Khashei-Siuki, A., & Shahidi, A. (2015). Modeling of climate change effects on saffron water requirement in south Khorasan province by GIS. *Journal of Saffron Research*, 3 (2), 163-174. (In Persian with English abstract).
<https://doi.org/https://doi.org/10.22077/jsr.2015.292>
- Jafarzadeh, A., Khashei Siuki, A., & Shahidi, A. (2023). Applicability of ensemble modeling techniques in water requirement simulations. *Saffron Agronomy & Technology*, 11 (2), 163-182. (In Persian with English abstract).
<https://doi.org/10.22048/jsat.2023.394323.1486>
- Ji, B. X., Liu, H. H., Cheng, P., Ren, X. Y., Pi, H. D., & Li, L. L. (2024). Phased optimization of active distribution networks incorporating distributed photovoltaic storage system: A multi-objective coati optimization algorithm. *Journal of Energy Storage*, 91, 112093.
<https://doi.org/10.1016/j.est.2024.112093>
- KhasheiSiuki, A., Shahidi, A., Dastorani, M., Fallahi, H. R., & Shirzadi, F. (2023). Yield and quality of sesame (*Sesamum indicum* L.) improve by water preservative materials under normal and deficit irrigation in Birjand. *Agrotechniques in Industrial Crops*, 3 (3), 121-132.
<https://doi.org/10.22126/ATIC.2023.9167.1098>
- Kolahi, M., Davary, K., & Omranian Khorasani, H. (2024). Integrated approach to water resource management in Mashhad plain, Iran: actor analysis, cognitive mapping, and roadmap development. *Scientific Reports*, 14 (1), 162.
<https://doi.org/10.1038/s41598-023-50697-x>
- Koocheki, A., Ebrahimian, E., & Seyyedi, S. M. (2016). How irrigation rounds and mother corm size control saffron yield, quality, daughter corms behavior and phosphorus uptake. *Scientia*

- Horticulturae*, 213, 132-143.
<https://doi.org/10.1016/j.scienta.2016.10.028>
- Koocheki, A., Fallahi, H. R., & Jami-Al-Ahmadi, M. (2020). Saffron water requirements. In *Saffron* (pp. 67-92). Elsevier.
<https://doi.org/10.1016/B978-0-12-818638-1.00006-X>
- Koocheki, A., Moghaddam, P. R., Aghavani-Shajari, M., & Fallahi, H. R. (2019). Corm weight or number per unit of land: Which one is more effective when planting corm, based on the age of the field from which corms were selected? *Industrial Crops & Products*, 131, 78-84.
<https://doi.org/10.1016/j.indcrop.2019.01.026>
- Kumar, M., Raghuwanshi, N., & Singh, R. (2011). Artificial neural networks approach in evapotranspiration modeling: A review. *Irrigation Science*, 29, 11-25.
<https://doi.org/10.1007/s00271-010-0230-8>
- Lei, W., Wang, G., Wan, B., Min, Y., Wu, J., & Li, B. (2024). High voltage shunt reactor acoustic signal denoising based on the combination of VMD parameters optimized by coati optimization algorithm and wavelet threshold. *Measurement*, 224, 113854.
<https://doi.org/10.1016/j.measurement.2023.113854>
- Mahdian Moghadam, N., & Tosan, M. (1394/2015). Study of Socio-Economic Effects of Saffron Cultivation in Torbat Heydarieh and Neyshabur. International Conference on Management, Culture and Economic Development, (p. 1-7), Mashhad, Fayyad Research Institute. [In Persian]
- Maleki, M., Ebrahimzade, H., Gholami, M., & Niknam, V. (2011). The effect of drought stress and exogenous abscisic acid on growth, protein content and antioxidative enzyme activity in saffron (*Crocus sativus* L.). *African Journal of Biotechnology*, 10 (45), 9068-9075.
<https://doi.org/10.5897/AJB10.676>
- Matsui, H. (2020). Quadratic regression for functional response models. *Econometrics & Statistics*, 13, 125-136.
<https://doi.org/10.1016/j.ecosta.2018.12.003>
- Mehmeti, A., Candido, V., Canaj, K., Castronuovo, D., Perniola, M., D'Antonio, P., & Cardone, L. (2024). Energy, environmental, and economic sustainability of saffron cultivation: Insights from the first European (Italian) Case study. *Sustainability*, 16 (3), 1179.
<https://doi.org/10.3390/su16031179>
- Moayedi, H., Foong, L. K., & Le, B. N. (2024). Three intelligent computational models to predict the high-performance concrete mixture. *Neural Computing & Applications*, 36 (7), 3479-3498.
<https://doi.org/10.1007/s00521-023-09233-1>
- Moshizi, Z. G. N., Bazrafshan, O., Etedali, H. R., Esmaeilpour, Y., & Collins, B. (2023). Application of inclusive multiple model for the prediction of saffron water footprint. *Agricultural Water Management*, 277, 108125.
<https://doi.org/10.1016/j.agwat.2022.108125>
- Niroomandfad, F., Khashei Siuki, A., Hashemi, S. R., & Ghorbani, K. (2023). Investigating the water footprint of saffron production in Birjand Plain under climate change conditions. *Saffron Agronomy & Technology*, 11 (3), 301-320. (In Persian with English abstract).
<https://doi.org/10.22048/jsat.2023.413847.1506>
- Peng, Y., Xiao, Y., Fu, Z., Dong, Y., Zheng, Y., Yan, H., & Li, X. (2019). Precision irrigation perspectives on the sustainable water-saving of field crop production in China: Water demand prediction and irrigation scheme optimization. *Journal of Cleaner Production*, 230, 365-377.
<https://doi.org/10.1016/j.jclepro.2019.04.347>
- Pereira, L., Paredes, P., & Jovanovic, N. (2020). Soil water balance models for determining crop water and irrigation requirements and irrigation scheduling focusing on the FAO56 method and the dual Kc approach. *Agricultural Water Management*, 241, 106357.
<https://doi.org/10.1016/j.agwat.2020.106357>
- Ramos, T. B., Darouich, H., & Pereira, L. S. (2024).

- Mulching effects on soil evaporation, crop evapotranspiration and crop coefficients: a review aimed at improved irrigation management. *Irrigation Science*, 1-15. <https://doi.org/10.1007/s00271-024-00924-8>
- Razmavaran, M. H., Sepaskhah, A. R., & Ahmadi, S. H. (2024a). Revisiting reference evapotranspiration calculation under regional advection and its effect on single and dual crop coefficients: An empirical approach for quinoa crop. *Meteorological Applications*, 31 (2), e2189. <https://doi.org/10.1002/met.2189>
- Razmavaran, M. H., Sepaskhah, A. R., & Ahmadi, S. H. (2024b). Water footprint and production of rain-fed saffron under different planting methods with ridge plastic mulch and pre-flowering irrigation in a semi-arid region. *Agricultural Water Management*, 291, 108632. <https://doi.org/10.1016/j.agwat.2023.108632>
- Rezvani Moghaddam, P., Karbasi, A., Tosan, M., Gharari, F., Feizi, H., & Mohtashami, T. (2016). Saffron Agronomy and Technology (Book of Abstracts: 2013-2016). *Saffron Agronomy & Technology*, 4 (SUPPLEMENT), 1-78. [In Persian]. <https://doi.org/10.22048/jsat.2016.39250>
- Saini, A. K., Bhatnagar, R., & Srivastava, D. K. (2024). SADCNN-ORBM: a hybrid deep learning model based citrus disease detection and classification. *International Journal of Electrical & Computer Engineering (IJECE)*, 14 (2), 2191-2201. <http://doi.org/10.11591/ijece.v14i2.pp2191-2201>
- Sammen, S. S., Ehteram, M., Sheikh Khozani, Z., & Sidek, L. M. (2023). Binary coati optimization algorithm-Multi-Kernel least square support vector machine-extreme learning machine model (BCOA-MKLSSVM-ELM): A New hybrid machine learning model for predicting reservoir water level. *Water*, 15 (8), 1593. <https://doi.org/10.3390/w15081593>
- Sepaskhah, A. R., & KAMGAR, H. A. (2009). Saffron irrigation regime. *International Journal of Plant Production*, 3 (1), 1-16. <https://doi.org/10.22069/IJPP.2012.627>
- Shamsabadi, V., Far, A. M., Tohidi, R., & Mirzaei, S. (2016). Evaluation of water consumption productivity of saffron in Iran (Case study: the province of Khorasan Razavi). *International Journal of Agriculture & Biosciences*, 5 (3), 102-104. <https://doi.org/10.22077/jwhr.2023.6663.1101>
- Suriyan, K., & Nagarajan, R. (2024). Particle swarm optimization in biomedical technologies: innovations, challenges, and opportunities. *Emerging Technologies for Health Literacy & Medical Practice*, 220-238. <https://doi.org/10.4018/979-8-3693-1214-8.ch011>
- Tian, Z. (2020). A combined prediction approach based on wavelet transform for crop water requirement. *Water Supply*, 20 (3), 1016-1034. <https://doi.org/10.2166/ws.2020.024>
- Tosan, M., Alizadeh, A., Ansari, H., & Rezvani Moghaddam, P. (2015). Evaluation of yield and identifying potential regions for Saffron (*Crocus sativus* L.) cultivation in Khorasan Razavi province according to temperature parameters. *Saffron agronomy and technology*, 3(1), 1-12. (In Persian with English abstract). <https://doi.org/10.22048/jsat.2014.9605>
- Tosan, M., Gharib, M. R., Attar, N. F., & Maroosi, A. (2025). Enhancing Evapotranspiration Estimation: A Bibliometric and Systematic Review of Hybrid Neural Networks in Water Resource Management. *Computer Modeling in Engineering & Sciences (CMES)*, 142(2). <https://doi.org/10.32604/cmcs.2025.058595>
- Tosan, M., Khashei Siuki, A., Sangari, M., & Rezvani Moghaddam, P. (2024). Analysis of the

- global research trend of saffron (*Crocus sativus* L.) between 2000-2023. *Saffron Agronomy and Technology*, 12(2), 115-138. (In Persian with English abstract).
<https://doi.org/10.22048/jsat.2024.443037.1524>
- Tosan, M., & Maroosi, A. (2024). Investigating the performance of artificial rabbit optimization hybrid algorithm (ANN-ARO) in forecasting reference evapotranspiration with limited climatic parameters. *Iranian Journal of Rainwater Catchment Systems*, 12 (1), 47-66. (In Persian with English abstract).
<https://dor.isc.ac/dor/20.1001.1.24235970.1403.12.1.3.6>
- Veysi, S., Nouri, M., & Jabbari, A. (2024). Reference evapotranspiration estimation using reanalysis and WaPOR products in dryland Croplands. *Heliyon*, 10, e26531.
<https://doi.org/10.1016/j.heliyon.2024.e26531>
- Wang, C., Lin, H., Hu, H., Yang, M., & Ma, L. (2024). A hybrid model with combined feature selection based on optimized VMD and improved multi-objective coati optimization algorithm for short-term wind power prediction. *Energy*, 130684.
<https://doi.org/10.1016/j.energy.2024.130684>
- Yarami, N., & Sepaskhah, A. (2016). Effect of irrigation water salinity, manure application and planting method on soil ions variation and ions uptake by saffron (*Crocus sativus* L.). *International Journal of Plant Production*, 10 (2). <https://doi.org/10.22069/IJPP.2016.2788>
- Yarami, N., & Sepaskhah, A. R. (2015). Saffron response to irrigation water salinity, cow manure and planting method. *Agricultural Water Management*, 150, 57-66.
<https://doi.org/10.1016/j.agwat.2014.12.004>
- Yaseen, Z. M., Sulaiman, S. O., Deo, R. C., & Chau, K. W. (2019). An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology*, 569, 387-408.
<https://doi.org/10.1016/j.jhydrol.2018.11.069>
- Yin, S., Du, H., Mao, F., Li, X., Zhou, G., Xu, C., & Sun, J. (2024). Spatiotemporal patterns of net primary productivity of subtropical forests in China and its response to drought. *Science of the Total Environment*, 913, 169439.
<https://doi.org/10.1016/j.scitotenv.2023.169439>
- Zamani, H., Nadimi-Shahraki, M. H., Mirjalili, S., Soleimanian Gharehchopogh, F., & Oliva, D. (2024). A critical review of moth-flame optimization algorithm and its variants: structural reviewing, performance evaluation, and statistical analysis. *Archives of Computational Methods in Engineering*, 1-49.
<https://doi.org/10.1007/s11831-023-10037-8>
- Zhang, J., Zhu, Y., & Chen, F. (2008). Forecast research of crop water requirements based on fuzzy rules. Computer and computing technologies in agriculture. Volume II: First IFIP TC 12 International Conference on Computer and Computing Technologies in Agriculture (CCTA 2007), Wuyishan, China, August 18-20, 2007 1. https://doi.org/10.1007/978-0-387-77253-0_61
- Zhao, L., Qing, S., Li, H., Qiu, Z., Niu, X., Shi, Y., Chen, S., & Xing, X. (2024). Estimating maize evapotranspiration based on hybrid back-propagation neural network models and meteorological, soil, and crop data. *International Journal of Biometeorology*, 1-15.
<https://doi.org/10.1007/s00484-023-02608-y>
- Zhao, N., Chen, X., Su, Y., Jiang, Y., & Wang, X. (2024). Wind pressure field reconstruction using a variance-extended KSI method: Both deterministic and probabilistic applications. *Probabilistic Engineering Mechanics*, 75, 103557. <https://doi.org/10.1007/s00484-023-02608-y>
- Zhou, Y., Huang, R., Lin, Q., Chai, Q., & Wang, W. (2024). Probabilistic optimization based adaptive neural network for short-term wind power forecasting with climate uncertainty.

