



## Investigating the performance of a hybrid algorithm based on artificial rabbits optimization (ANN-ARO) in forecasting reference evapotranspiration with limited climatic parameters

Moein Tosan<sup>1</sup>, Ali Maroosi<sup>2</sup>, Hossein Khozaymehnezhad<sup>\*3</sup>

1. Ph.D. Student, Water Engineering Department, Faculty of Agriculture, University of Birjand, Birjand, Iran. Email: moein.tosan@birjand.ac.ir.
2. Assistant Professor, Department of Computer Engineering, Technical Faculty, University of Torbat Heydarieh, Torbat Heydarieh, Iran. Email: ali.maroosi@torbath.ac.ir.
3. Associate Professor, Water Engineering Department, University of Birjand, Birjand, Iran. Email: hkhozeymeh@birjand.ac.ir.

ARTICLE INFO	ABSTRACT
<p><b>Article type:</b> Research Paper</p> <p><b>Article history</b> <b>Received:</b> 31 December 2023 <b>Revised:</b> 01 February 2024 <b>Accepted:</b> 04 February 2024 <b>Published online:</b> 06 June 2024</p> <p><b>Keywords:</b> Reference evapotranspiration, neural network, artificial rabbit optimizer, precision agriculture.</p> <p><b>Citation:</b> Tosan, M., Maroosi, A., &amp; Khozaymehnezhad, H. (2024). Investigating the performance of a hybrid algorithm based on artificial rabbits optimization (ANN-ARO) in forecasting reference evapotranspiration with limited climatic parameters. <i>Iranian Journal of Rainwater Catchment Systems</i>, 12(1), 47-66. <b>DOR:</b> 20.1001.1.24235970.1403.12.1.3.6</p> <p><b>Publisher:</b> Iranian Rainwater Catchment Systems Association</p>	<p>Reference evapotranspiration (ET<sub>o</sub>) is considered one of the important variables in hydrology and agricultural science and is a determining factor in water resources management. This study investigates a hybrid model of an artificial neural network with an artificial rabbit optimization algorithm (ANN-ARO) for daily modeling of ET<sub>o</sub> with limited meteorological parameters. It compares it with other hybrid methods, i.e. ANN with a particle optimization algorithm (ANN-PSO). ANN with genetic algorithm (ANN-GA) and five different data mining models. These models were evaluated using long-term daily climate data from 2000 to 2023 in two climates. The investigated stations included Birjand (with a desert climate) and Mashhad (with a cold semi-arid climate). The statistical comparison showed that considering all climatic parameters, the hybrid ANN-ARO model in Mashhad city with R<sup>2</sup>=0.9986 and MSE=0.0001 and in Birjand city with R<sup>2</sup>=0.9986 and MSE=0.0001 gave better estimates than other methods. In addition, the ANN-ARO optimization algorithm has the best estimation with "temperature" and "relative humidity" by considering the minimum meteorological parameter, and also by considering two and three input parameters, it performs better than other methods. In general, nature-inspired optimization algorithms are powerful tools to enhance the performance of ANN in ET<sub>o</sub> simulation. According to the results, the ANN-ARO model is highly recommended for estimating ET<sub>o</sub> in similar climate regions with limited climate data. This study proposes powerful models for accurate estimation of ET<sub>o</sub> with limited inputs in arid and semi-arid climates, which provide practical implications for the development of precision agriculture.</p>



© Author(s)

**\*Corresponding author:** Hossein Khozaymehnezhad

**Address:** Associate Professor, Water Engineering Department, University of Birjand, Birjand, Iran.

**Tel:** +989151639843

**Email:** Hkhozeymeh@birjand.ac.ir



## Investigating the performance of a hybrid algorithm based on artificial rabbits optimization (ANN-ARO) in forecasting reference evapotranspiration with limited climatic parameters

Moein Tosan<sup>1</sup>, Ali Maroosi<sup>2</sup>, Hossein Khozaymehnezhad<sup>\*3</sup>

1. Ph.D. Student, Water Engineering Department, Faculty of Agriculture, University of Birjand. Iran. Email: moein.tosan@birjand.ac.ir.
2. Assistant Professor, Department of Computer Engineering, Technical Faculty, University of Torbat Heydarieh, Torbat Heydarieh, Iran. Email: ali.maroosi@torbath.ac.ir.
3. Associate Professor, Water Engineering Department, Faculty of Agriculture, University of Birjand, Iran. Email: hkhozeymeh@birjand.ac.ir.

### EXTENDED ABSTRACT

**Introduction:** Water scarcity is a global concern and affects various aspects of human life. Due to the excessive use of water in the agricultural sector, Iran is facing a sharp decrease in the water level, and many experts believe that water management in Iran is not good enough. Accurate estimation of reference evapotranspiration (ET<sub>o</sub>) is essential for agricultural water management, crop productivity, and irrigation systems. The Penman-Monteith equation (FAO 56) is widely recommended worldwide as the standard ET<sub>o</sub> estimation method. However, direct measurements of ET are severely limited by enormous costs and technical complexity, thus making it highly meaningful to explore alternative simpler models for acceptable ET<sub>o</sub> estimation. On the other hand, meteorological data may often be incomplete, which requires models with minimal inputs. With the development of computer technology, the application of the Intelligence Optimization Algorithm (IOA) has been greatly expanded in various fields. The successful use of optimization algorithms in the field of ET<sub>o</sub> estimation points to the efficiency of IOA methods around the world. Although there is great potential in the field of ET<sub>o</sub> estimation using the IOA technique, research shows that they show different performances mostly due to unique strategies. Therefore, it is necessary to compare and evaluate different IOA to achieve better results.

**Methodology:** In this study, the artificial rabbit optimization (ARO) algorithm is used to optimize the artificial neural network model for ET<sub>o</sub> estimation using the minimum climatic parameters. ARO evolutionary algorithm provides optimal solutions by identifying the best participants in the search region and fast convergence. To this end, an ANN with an aARO for predicting water productivity was optimized. The study area is Mashhad city, the capital of Razavi Khorasan province, with a cold semi-arid climate, and Birjand, the capital of South Khorasan province, with a desert climate. The FAO Penman-Monteith method was used as a standard method for calculating ET<sub>o</sub> due to its suitability for different climatic regions. The required meteorological data included temperature (minimum, maximum, and mean), wind speed, 24-hour precipitation, mean relative humidity, sunshine hours, received net radiation, mean station level pressure, and mean vapor pressure, daily. The artificial rabbit hybrid optimizer (ARO) algorithm was selected in combination with the neural network model and its efficiency in estimating ET<sub>o</sub> with minimal meteorological parameters was investigated. In addition, to evaluate the proposed ANN-ARO model, other data mining methods such as linear regression (LR), pure quadratic regression (PQ), interactive regression (IR), random forest regression (RFs), nearest neighbor regression (KNN) and models A combination of ANN with genetic algorithm (ANN-GA) and ANN with particle optimization algorithm (ANN-PSO). The input components to the model are a single parameter including temperature, relative humidity, wind speed, and net radiation; two parameters including temperature and net radiation; four parameters including temperature, net radiation, relative humidity, and wind speed were used and finally the complete parameters were used.

**\*Corresponding author:** Hossein Khozaymehnezhad

**Address:** Associate Professor, Water Engineering Department, University of Birjand, Birjand, Iran.

**Tel:** +989151639843

**Email:** Hkhozeymeh@birjand.ac.ir

**Results and Discussion:** Overall, similar results were obtained in both stations. The comparison between different models showed that the performance of hybrid artificial intelligence models was generally superior to other data mining models. Besides, among other data mining methods, pure quadratic regression models, random forest regression, and nearest neighbor regression had the best results, except for the C7 combination, where random forest regression and nearest neighbor regression models performed better. Among other hybrid models, ANN-GA and ANN-PSO models, which have been used by many researchers, both performed well in estimating ETo with full meteorological parameters, while the results of this research show that under conditions Faced with limited meteorological parameters, ANN-GA and ANN-PSO hybrid models have much weaker performance than ANN-ARO. In general, the ANN-ARO model used in this study showed a good performance in estimating ETo, especially with single meteorological data input (C1-C4), while for the conditions where only the temperature parameter was used (C1), this model showed higher accuracy in promising and more stable ability to estimate ETo, and the combination of C5 and C6 with the combination of meteorological parameters were more suitable input combinations in terms of model strength and limited model input.

**Conclusion:** The comparison of different climate inputs showed that the estimation accuracy of the models applied by including more input variables and four inputs (temperature, solar radiation, relative humidity, and wind speed) produced the best estimates for each method. The comparison also showed that temperature has a greater effect on ETo estimation in the investigated climates, while other parameters such as relative humidity, net radiation, and wind speed at inputs have less effect on ETo estimation. The ANN-ARO can be used to accurately estimate ETo rates based on minimal meteorological parameters, in different climates, especially in areas with scarce water. The prediction of ETo based on the division of input data based on the day of the year, which was used in the present study, is a new approach that has been investigated in a recent study. The possible reason behind this could be due to fluctuations in the range of weather variables during summer and winter compared to spring and autumn. This approach can be further investigated in future studies.

#### **Ethical Considerations**

**Data availability statement:** The datasets are available upon a reasonable request to the corresponding author.

**Authors' contribution:** Moein Tosan, Ali Maroosi, and Hossein Khozaymehnezhad as the authors of the paper, conducted all parts of the research and wrote the whole manuscript.

**Conflicts of interest:** The authors declared no conflict of interest regarding the authorship or publication of this article.

**Acknowledgment:** The authors are grateful to the Iran Meteorological Organization for providing the meteorological data.

## بررسی عملکرد الگوریتم هیبریدی بهینه‌سازی خرگوش مصنوعی (ANN-ARO) در پیش‌بینی تبخیر و تعرق مرجع با پارامترهای اقلیمی محدود

معین توسن<sup>۱</sup>، علی ماروسی<sup>۲</sup>، حسین خزیمه‌نژاد<sup>۳\*</sup>

۱. دانشجوی دکتری، گروه مهندسی منابع آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. moein.tosan@birjand.ac.ir

۲. استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه تربت حیدریه، تربت حیدریه، ایران. ali.maroosi@torbath.ac.ir

۳. دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. hkhozeymeh@birjand.ac.ir

مشخصات مقاله	چکیده
<p><b>نوع مقاله:</b> پژوهشی</p> <p><b>تاریخچه مقاله</b> <b>دریافت:</b> ۱۰ دی ۱۴۰۲ <b>بازنگری:</b> ۱۲ بهمن ۱۴۰۲ <b>پذیرش:</b> ۱۵ بهمن ۱۴۰۲ <b>انتشار برخط:</b> ۱۷ خرداد ۱۴۰۳</p> <p><b>واژه‌های کلیدی:</b> تبخیر و تعرق مرجع، شبکه عصبی، بهینه‌ساز خرگوش مصنوعی، کشاورزی دقیق</p>	<p>تبخیر و تعرق مرجع یکی از متغیرهای مهم در هیدرولوژی و علوم کشاورزی و عامل تعیین‌کننده در مدیریت منابع آب است. این مطالعه به بررسی مدل هیبریدی شبکه عصبی با الگوریتم بهینه‌ساز خرگوش مصنوعی (ANN-ARO) برای مدل‌سازی روزانه تبخیر و تعرق مرجع با پارامترهای هواشناسی محدود و مقایسه آن با سایر روش‌های هیبریدی یعنی شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی ذرات (ANN-PSO)، شبکه عصبی مصنوعی با الگوریتم ژنتیک گری (ANN-GA) و پنج مدل داده‌کاوی دیگر می‌پردازد. این مدل‌ها با استفاده داده‌های آب‌وهوایی روزانه بلندمدت از سال ۲۰۰۰ تا ۲۰۲۳ در دو اقلیم متفاوت ارزیابی شدند. ایستگاه‌های مورد بررسی شامل بیرجند (با اقلیم خشک کویری) و مشهد (با اقلیم نیمه‌خشک سرد) بود. مقایسه آماری نشان داد که با در نظر گرفتن کلیه پارامترهای اقلیمی مدل هیبریدی ANN-ARO در شهر مشهد با <math>R^2=0/9986</math> و <math>MSE=0/0001</math> و در شهر بیرجند با <math>R^2=0/9986</math> و <math>MSE=0/0001</math> در نظر گرفتن حداقل پارامتر هواشناسی، به ترتیب با "دما" و "رطوبت نسبی" بهترین تخمین را داشته و همچنین با در نظر گرفتن دو و سه پارامتر ورودی، عملکرد بهتری نسبت به سایر روش‌ها دارد. به‌طور کلی، الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت ابزارهای قوی برای افزایش عملکرد ANN در شبیه‌سازی ET هستند و مطابق یافته‌های این پژوهش، مدل ANN-ARO برای تخمین تبخیر و تعرق مرجع در مناطق اقلیمی مشابه با داده‌های اقلیمی محدود توصیه می‌شوند. این مطالعه مدل‌های قدرتمندی را برای تخمین دقیق ET با ورودی‌های محدود در اقلیم‌های خشک و نیمه‌خشک پیشنهاد می‌کند که مفاهیمی عملی برای توسعه کشاورزی دقیق ارائه می‌دهد.</p>
<p><b>استناد:</b> توسن، معین، ماروسی، علی، و خزیمه‌نژاد، حسین (۱۴۰۳). بررسی عملکرد الگوریتم هیبریدی بهینه‌سازی خرگوش مصنوعی (ANN-ARO) در پیش‌بینی تبخیر و تعرق مرجع با پارامترهای اقلیمی محدود، شهرستان تربت حیدریه. <i>سامانه‌های سطوح آبگیر باران</i>، ۱۱(۳)، ۴۷-۶۶. <b>DOR:</b> 20.1001.1.24235970.1403.12.1.3.6</p> <p>ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران</p>	
<p> نویسنده‌گان ©</p>	

\* نویسنده مسئول: حسین خزیمه‌نژاد

نشانی: گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران.

تلفن: ۰۹۱۵۱۶۳۹۸۴۳

پست الکترونیکی: Hkhozeymeh@birjand.ac.ir



همکاران (۲۰۱۵) چهار مدل ANN را مقایسه کردند: (۱) شبکه عصبی مصنوعی پرسپترون چندلایه (MLP-ANN)، (۲) شبکه عصبی مصنوعی پیش‌خور عمومی (GFF-ANN)، (۳) شبکه عصبی احتمالی (P-ANN) و (۴) مدل‌های شبکه عصبی مصنوعی رگرسیون خطی (LR-ANN) برای پیش‌بینی تبخیر و تعرق ایستگاه اقلیمی Gaoyou استان جیانگ سو در چین. نتایج این مطالعه ثابت کرد که شبکه‌های عصبی مصنوعی می‌توانند به‌طور مؤثر به‌عنوان یک ابزار مدل‌سازی ET قابل‌اعتماد استفاده شوند. همکاران (۲۰۱۹) از مدل‌های ANN برای پیش‌بینی ET نهر نیسوری در شهرستان آکسفورد، کانادا استفاده کرد. آن‌ها از دو نوع تابع فعال‌سازی از جمله واحد خطی اصلاح‌شده (ReLU) و سیگموئید استفاده کردند. نتایج نشان داد که ReLU عملکرد بهتری نسبت به تابع فعال‌سازی سیگموئید دارد.

بر اساس پژوهش‌های اخیر، مدل‌های محاسبات نرم ترکیبی دقت پیش‌بینی تبخیر و تعرق پتانسیل بهتری را در مقایسه با روش‌های محاسبات نرم مستقل ارائه می‌دهند. توجه اولیه محققان به سمت ترکیب چندین الگوریتم جستجوی ابتکاری جدید با روش‌های محاسباتی نرم برای بهینه‌سازی پارامترهای کنترلی و افزایش دقت پیش‌بینی آن‌ها است. Gocić و همکاران (۲۰۱۵) الگوریتم کرم شبتاب را با SVM (SVM-FFA) برای پیش‌بینی ET در صربستان ترکیب و با SVM، WT-SVM و ANN مقایسه نمودند. آن‌ها دریافتند که مدل‌های SVM-FFA و WT-SVM نتایج پیش‌بینی بهتری را در مقایسه با روش‌های محاسباتی مستقل ANN و SVM ارائه می‌کنند. Shamsirband و همکاران (۲۰۱۶) از یک روش اکتشافی جدید به نام الگوریتم جستجوی فاخته (CSA) برای بهینه‌سازی روش‌های ANN و ANFIS در تخمین ET در ایستگاه اقلیمی در صربستان استفاده کرد. نتایج پیش‌بینی روش‌های ترکیبی طراحی‌شده (ANN-CSA و ANFIS-CSA) با مدل‌های مستقل ANN و ANFIS و مدل‌های تجربی هارگریوز و پرستلی-تیلور مقایسه شد. Patil & Deka (۲۰۱۷) ترکیبی از تبدیل موجک را با روش‌های ANN و ANFIS برای مدل‌سازی تبخیر و تعرق در مناطق خشک هند به‌کار بردند. نتایج تأیید کرد که مدل‌های ترکیبی عملکرد بهتری نسبت به مدل‌های محاسباتی نرم مستقل در پیش‌بینی ET داشتند.

Feng و همکاران (۲۰۱۷) شبکه عصبی رگرسیون تعمیم‌یافته را با جنگل تصادفی برای تعیین کمیت ET روزانه در مناطق مرطوب جنوب غربی چین مقایسه کردند، نتایج نشان داد مدل شبکه عصبی رگرسیون تعمیم‌یافته دقت بهتری از جنگل تصادفی ارائه می‌دهد. Fan و همکاران (۲۰۱۹) عملکرد دستگاه تقویت‌گرادیان نور را برای کمی کردن ET با استفاده از داده‌های اقلیمی محدود ارزیابی کرد و آن را با دو مدل یادگیری ماشین (درخت مدل M5 مبتنی بر درخت و جنگل تصادفی) و چهار مدل تجربی (طبری، هارگریوز-سامانی، ترابرت و مکینک) مقایسه کرد. آن‌ها عملکرد بهتری از دستگاه تقویت‌گرادیان نور نسبت به مدل‌های دیگر پیدا کردند. Araghi و همکاران (۲۰۲۰) هم‌چنین مزایای WT (تبدیل موجک) همراه با مدل‌های WT-ANN، WT-ANFIS و WT-MLR را برای پیش‌بینی ET سه ایستگاه آب و هوایی انتخاب‌شده از سه اقلیم مختلف در ایران نشان دادند. با استفاده از داده‌های آب‌وهوای روزانه ایستگاه‌های انتخاب‌شده، آن‌ها دریافتند که WT-ANN از سایر مدل‌های هیبریدی مبتنی بر موجک (WT-ANFIS و WT-MLR) بهتر عمل می‌کند. Tikhamarine و همکاران (۲۰۲۰) برای مدل‌سازی تبخیر و تعرق مرجع در ایستگاه‌هایی در هند و الجزایر از بهینه‌سازهای مختلفی در ترکیب با شبکه عصبی مصنوعی استفاده کردند: گرگ خاکستری (ANN-GWO)، بهینه‌ساز چندوجهی (ANN-MVO)، بهینه‌ساز ازدحام ذرات (ANN-PSO)، الگوریتم بهینه‌سازی نهنگ (ANN-WOA) و بهینه‌ساز شیرمورچه (ANN-ALO). نتایج نشان داد الگوریتم ANN-GWO به‌طور قابل‌توجهی مقادیر RMSE و NSE را در مقایسه با سایر تکنیک‌های بهینه‌سازی بهبود بخشید. GWO هم‌چنین عملکرد بهتری از الگوریتم بهینه‌سازی ملخ (GOA)، PSO و الگوریتم ازدحام سالپ (SSA) داشت که با مدل KNEA برای پیش‌بینی ET در شرایط مختلف آب و هوایی در چین ترکیب شد (Dong et al., 2021). Chia و همکاران (۲۰۲۰) از سه روش بهینه‌سازی مبتنی بر ازدحام، یعنی بهینه‌سازی شعله پروانه (MFO)، بهینه‌سازی ازدحام ذرات (PSO) و الگوریتم بهینه‌سازی نهنگ (WOA) برای بهینه‌سازی ماشین‌های یادگیری شدید استفاده و سه مدل یادگیری ماشین ترکیبی را برای تخمین ET پیشنهاد نمودند. مقایسه نشان داد که الگوریتم بهینه‌سازی نهنگ بهتر از دو روش دیگر برای بهینه‌سازی ماشین‌های یادگیری افراطی است. جدول (۱) تعدادی از مهم‌ترین پژوهش‌های انجام شده در زمینه کاربرد شبکه‌های عصبی هیبریدی در تخمین تبخیر و تعرق مرجع را نشان می‌دهد.

جدول ۱- مدل‌های هیبریدی شبکه عصبی مصنوعی برای پیش‌بینی تبخیر و تعرق مرجع با در نظر گرفتن MSE و R<sup>2</sup>Table 2- Hybrid artificial neural network models for predicting reference evapotranspiration considering MSE and R<sup>2</sup>

نتیجه	R <sup>2</sup>	MSE	مدل هیبریدی	ایستگاه هواشناسی	منبع
مدل ANFIS-CSA در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.	0.956	0.108	ANN-CSA	جنوب شرقی اروپا، صربستان	Shamshirband و همکاران (۲۰۱۶)
MARS و SVMRBF بهتر از GEP عمل می‌کنند.	0.649	0.26	SVM-RBF	ایران	Mehdizadeh و همکاران (۲۰۱۷)
SVM-CA بهتر از GP، ANFIS عملکرد داشت.	0.863	0.51	SVM-CS	پانتنگا، هند	Ehteram و همکاران (۲۰۱۹)
GEP بهترین و سپس GEP، GRNN، RBNN، ANFIS-GP عملکرد را داشتند.	0.903	0.33	ANFIS-GP	آنتالیا، ترکیه	Sanikhani و همکاران (۲۰۱۹)
عملکرد مدل هیبریدی ANFIS-PSO در شرایط پارامتر ورودی محدود عملکرد بهتر بود.	0.986	0.06	ANFIS-PSO	آنتالیا، ترکیه	Alizamir و همکاران (۲۰۲۰)
مدل RBFN-DE در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.	0.995	0.43	RBFN-DE	امبیکاپور، هند	Majhi and Naidu (۲۰۲۱)
ترکیب هیبریدی ANFIS-WCA-MFO بهترین عملکرد را داشت.	0.946	0.058	ANFIS-MFO	داکا، بنگلادش	Adnan و همکاران (۲۰۲۱)
GA-ELM عملکرد بهتری داشت.	-	0.062	GA-ELM	چین	Gong و همکاران (۲۰۲۱)
RF، MLR، SVM، ANN-MLP بهترین عملکرد را داشت و سپس ANN-RBF قرار گرفتند.	0.999	0.490	ANN-MLP	آنتولی، ترکیه	Yurtseven and Serengil (۲۰۲۱)
عملکرد مدل هیبریدی ANFIS-WCA-MFO بهتر از مدل‌های ANFIS-MFO و ANFIS-WCA بود.	0.914	0.073	ANFIS-WCA-MFO	جنوب بنگلادش	Adnan و همکاران (۲۰۲۱)
مدل هیبریدی VMD-BC-SVM بهتر از بقیه مدل‌ها عمل کرد.	0.81	0.960	VMD-SVM	هیلونگ‌جیانگ، چین	Kang و همکاران (۲۰۲۲)
مدل هیبریدی پیشنهادی بهتر از ANFIS-PSO بود.	0.85	0.810	BC-SVM	شمال غربی بنگلادش	Cui و همکاران (۲۰۲۲)
مدل هیبریدی پیشنهادی در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.	0.76	0.449	VMD-BC-SVM	جنوب غربی بنگلادش	Ye و همکاران (۲۰۲۲)
	0.99	0.004	ANFIS-IA-GWO		
	0.9	0.185	DENFIS-WOA		

هرچند زمانی که تعداد معادلی از پارامترهای ورودی در هر مکان معین موجود باشد، عملکرد مدل‌های هوش مصنوعی با معادله فائو پنمن موتیث (فائو ۵۶) برابری می‌کند، اما باید در نظر داشت که حتی با در دسترس بودن تمام پارامترهای آب و هوا، استفاده از فائو پنمن موتیث برای محاسبه تبخیر و تعرق مرجع نیاز به محاسبه پارامترهای مشتق شده در یک ایستگاه معین دارد، که نیاز به دانش خاصی دارد. بنابراین، تکنیک‌های هوش مصنوعی جایگزین مناسبی برای این معادله شده‌اند، زیرا محاسبه مستقیم مقادیر تبخیر و تعرق مرجع، نیاز به محاسبه پارامترهای مشتق شده را از بین می‌برند، و از این‌رو برای مدیران آبیاری که دانش فنی زیادی ندارند، مفید هستند. اما در صورت کاهش در دسترس بودن پارامترهای اقلیمی، تکنیک‌های محاسباتی نرم مطمئناً برتری بیشتری نسبت به معادلات تجربی مرسوم دارند. تقریباً در همه مطالعات بررسی شده، تکنیک‌های هوش مصنوعی حتی در مواردی که مدل هوش مصنوعی با تعداد پارامترهای ورودی کاهش یافته تغذیه می‌شود، از عملکرد معادلات تجربی پیشی گرفته است. هدف از این پژوهش بررسی عملکرد مدل هیبریدی هوش مصنوعی با الگوریتم بهینه‌سازی خرگوش مصنوعی (ARO) تحت سناریوهای ورودی کاهش یافته جهت دستیابی به بهترین ترکیب‌های ممکن از پارامترهای ورودی است که می‌تواند در مکان‌هایی که ممکن است تمام داده‌های هواشناسی در دسترس نباشند، استفاده شود.

## مواد و روش تحقیق


### منطقه مورد مطالعه

شهر مشهد مرکز استان خراسان رضوی، در محدوده ۵۹ درجه و ۱۵ دقیقه تا ۶۰ درجه و ۳۶ دقیقه عرض جغرافیایی واقع شده است (Tosan et al., 2015). این شهر با ۳۵۱ کیلومتر مربع مساحت و بیش از سه میلیون نفر جمعیت، دومین شهر پهناور و پرجمعیت ایران پس از تهران است. بیشینه ارتفاع منطقه ۱۱۵۰ و کمینه آن ۹۵۰ متر از سطح دریا است (Rezvani Moghaddam et al., 2016). اقلیم مشهد با وجود تابستان‌های گرم و زمستان‌های سرد، بر اساس طبقه‌بندی اقلیمی کوپن-گایگر نیمه‌خشک سرد است (باقری‌فام و همکاران، ۱۴۰۱؛ Feizi et al., 2016). شهرستان بیرجند نیز مرکز استان خراسان جنوبی و در محدوده ۵۹ درجه و ۱۲ دقیقه طول جغرافیایی و ۵۲ درجه و ۳۲ دقیقه عرض جغرافیایی قرار گرفته است. میانگین کمینه و بیشینه دمای سالیانه بیرجند به ترتیب ۸ و ۲۴ درجه سانتی‌گراد، بارش سالانه ۱۲۰ میلی‌متر و میانگین تبخیر و تعرق پتانسیل ۲۷۰۰ میلی‌متر است. بر اساس شاخص‌های اقلیم دوماتن و اروانف، شهر بیرجند دارای اقلیم خشک-کوبیری است (Ramezani Moghadam et al., 2018). داده‌های هواشناسی مورد نیاز شامل دما (حداقل، حداکثر و میانگین)، سرعت باد، بارش ۲۴ ساعته، میانگین رطوبت نسبی، ساعت آفتابی، تابش خالص دریافتی، فشار میانگین سطح ایستگاه و میانگین فشار بخار به صورت روزانه و در بازه زمانی ۲۰۰۰ الی ۲۰۲۳ بود که از سازمان هواشناسی کشور اخذ شد. میانگین پارامترهای اقلیمی مورد استفاده در دوره آماری ۲۰۰۰-۲۰۲۳، در جدول (۲) ارائه شده است.

جدول ۲- میانگین پارامترهای هواشناسی مورد استفاده در مناطق مورد مطالعه

Table 2- Average meteorological parameters used in the study areas

ایستگاه	دما		سرعت باد	فشار میانگین سطح ایستگاه	میانگین فشار بخار	بارش ۲۴ ساعته	میانگین رطوبت نسبی	تعداد ساعت آفتابی
	حداقل	حداکثر						
مشهد	9.77	22.9	2.75	903	7.76	0.60	47.61	8.26
بیرجند	10.51	28.11	3.93	848	4.48	0.21	25.34	9.81



شکل ۱- نقشه موقعیت جغرافیایی مناطق مورد مطالعه

Figure 1- Map of the geographical location of the studied areas

### تبخیر و تعرق مرجع

فائو روش فائو پنمن مونتیث را به دلیل مناسب بودن آن برای مناطق مختلف اقلیمی به عنوان روش استاندارد برای محاسبه تبخیر و تعرق مرجع توصیه کرد (Bellido-Jiménez et al., 2021). در مطالعه حاضر، مقدار تبخیر و تعرق مرجع محاسبه شده با استفاده از این روش به عنوان مقدار استاندارد در نظر گرفته شد.  $ET_0$  به صورت رابطه (۱) 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 ( $\text{mm day}^{-1}$ )،  $e_s$  فشار بخار اشباع (kPa)،  $e_a$  فشار بخار واقعی (kPa)،  $\Delta$  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 ( $\text{MJm}^{-2} \text{ day}^{-1}$ )،  $\gamma$  ثابت سایکرومتری ( $\text{kPa } ^\circ\text{C}^{-1}$ )،  $U_2$  سرعت باد در ارتفاع دوم‌تری ( $\text{m s}^{-1}$ )،  $T$  میانگین دمای هوا ( $^\circ\text{C}$ ) و  $e_s - e_a$  کاهش فشار بخار (kPa) می‌باشد.

### شبکه عصبی مصنوعی

روش شبکه‌های عصبی مصنوعی که از سیستم عصبی زیستی الهام گرفته، توانایی تحلیل‌های پیچیده؛ مانند مدل‌های غیرخطی و پیش‌بینی را دارد (Yurtseven & Serengil, 2021). این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به هم پیوسته به نام نورون‌ها تشکیل شده است که برای حل یک مسئله هماهنگ با هم عمل می‌کنند.

### روش تحقیق

شبکه‌های عصبی مصنوعی از چندین عنصر پردازش انبوه تشکیل شده‌اند که در سیستم‌های موازی با استفاده از وزن‌های متغیر به هم متصل شده‌اند. هر لایه از طریق وزنه‌های اتصال ( $W$ ) به لایه‌های دیگر متصل می‌شود. عناصر پردازشی که شبکه‌های عصبی مصنوعی را تشکیل می‌دهند، نورون نامیده می‌شوند (Alizamir et al., 2020). متغیرهای ورودی به مدل شامل دمای حداقل ( $T_{\min}$ )، دمای حداکثر ( $T_{\max}$ )، دمای میانگین ( $AT$ )، فشار میانگین ایستگاه ( $AP$ )، میانگین فشار بخار ( $VP$ )، بارش ۲۴ ساعته ( $RF$ )، میانگین رطوبت نسبی ( $RH$ )، ساعت آفتابی ( $SS$ ) و میزان تابش کلی ۲۴ ساعته ( $Rs$ ) و روز از سال ( $n$ ) بودند که با ترکیب‌های مختلف ( $C1, C2, \dots, C7$ ) وارد مدل شدند. پیش‌بینی تبخیر و تعرق مرجع با به‌کارگیری پارامتر روز از سال ( $n$ ) به‌عنوان پارامتر ورودی، رویکرد جدیدی است که در مطالعات اخیر مورد بررسی قرار گرفته است (Ferreira et al., 2022). متغیر خروجی نیز تبخیر و تعرق مرجع محاسبه‌شده در ایستگاه‌های مورد مطالعه به روش فائو-پنمن-مونتیث بود. ساختار اصلی رابط شبکه عصبی مصنوعی مورد استفاده در این پژوهش، در شکل (۲) نشان داده شده است. لایه‌های شبکه عصبی ( $i$ )، ( $j$ ) و با وزن‌های  $W_{ij}$  و  $W_{jk}$  و بین لایه‌های نورون‌ها به هم مرتبط هستند.



شکل ۲- رابط شبکه عصبی مورد استفاده برای تخمین تبخیر و تعرق مرجع  
Figure 2- Neural network interface used to estimate reference evapotranspiration

### الگوریتم بهینه‌سازی خرگوش مصنوعی

الگوریتم بهینه‌سازی خرگوش مصنوعی (ARO) از تاکتیک‌های طبیعی خرگوش‌ها در حیات‌وحش تکامل یافته است. ARO در سال ۲۰۲۲ توسط وانگ و همکاران توسعه داده شده است (Wang et al., 2022). خرگوش‌ها با الهام گرفتن از دو ویژگی مهم شامل جستجو و پنهان شدن، یا به‌طور مشابه دور از لانه خود برای تهیه وعده‌های غذایی خود اقدام می‌کنند و یا به‌صورت دلخواه به انتخاب پناهگاه می‌پردازند. ARO

رویکردهای جستجو و پنهان‌شدن خرگوش‌های واقعی را به‌همراه انقباض انرژی آن‌ها درگیر می‌کند که منجر به استفاده از هر دو رویکرد می‌شود.

(۱) جستجوی انحرافی (اکتشاف): از آن‌جا که خرگوش‌ها دور از پناهگاه خود به‌دنبال غذا می‌گردند. بنابراین در ARO در نظر گرفته می‌شود که هر یک از خرگوش‌ها لانه مخصوص به خود را به‌همراه غذا و به تعداد  $d$  سوراخ دارد و هر خرگوش خودسرانه جهت تهیه غذا به سمت لانه‌های دیگر اعضا حرکت می‌کند. نمونه اولیه عددی اکتشاف هر خرگوش به شرح زیر است (Saha et al., 2023):

$$\begin{cases} v_i(t+1) = x_j(t) + R_0(x_i(t) - x_j(t)) + Y \\ Y = \text{round}(0.5 \cdot (0.05 + r_1))n_1 \\ i, j = 1, \dots, n \text{ and } i \neq j \end{cases} \quad (2)$$

که در آن  $v_i(t+1)$  مکان پیشنهادی است اگر خرگوش  $i$ ام، در زمان  $t+1$  باشد،  $x_i(t)$  مکان خرگوش  $i$ ام در زمان  $t$  اندازه جمعیت خرگوش،  $R$  عملگر در حال اجرا،  $Y$  تابع سقف است،  $\text{round}$  نشان‌دهنده گرد کردن به نزدیک‌ترین عدد صحیح،  $r_1$  عدد تصادفی بین  $(0,1)$  است،  $n_1$  تابع توزیع نرمال استاندارد است.

$$R = L \cdot c \quad (3)$$

که در آن  $L$  طول در حال اجرا و  $c$  بردار نقشه‌برداری است.

$$L = \left( e - e^{\left(\frac{t-1}{T}\right)^2} \right) \cdot \sin(2\pi r_2) \quad (4)$$

که در آن  $r_2$  عددی تصادفی بین  $0$  و  $1$  است.

$$c(k) = \begin{cases} 1 & \text{if } k = g(l) \\ 0 & \text{else} \end{cases} \quad (5)$$

where  $k = 1, \dots, d$   
and  $l = 1, \dots, [r_3gd]$

به‌طوری‌که در آن  $d$  بعد مسئله و  $r_3$  عددی تصادفی بین  $0$  و  $1$  است.

$$g = \text{randperm}(d) \quad (6)$$

که در آن  $\text{randperm}$  یک جایگشت تصادفی از اعداد صحیح بین  $1$  تا  $d$  است.

(۲) مخفی شدن خودسرانه (بهره‌برداری): در مدل خرگوش مصنوعی موردنظر، در تکرار فردی، خرگوش دائماً در امتداد ابعاد فردی منطقه شکار، مخفیگاه‌هایی را در اطراف خود ایجاد کرده و به‌طور مستمر و به‌صورت خودسرانه از بین همه حفره‌ها، یک واحد را برای مخفی شدن انتخاب می‌کند تا از احتمال شکار شدن بکاهد. در اینجا، حفره  $j$ ام مربوط به خرگوش  $i$ ام به‌صورت زیر ایجاد می‌شود:

$$b_{i,j}(t) = x_i(t) + H \cdot g \cdot x_i(t) \quad (7)$$

که در آن  $H$  پارامتر پنهان بوده و  $i = 1, \dots, n$  و  $j = 1, \dots, n$  می‌باشد.

$$H = \frac{T-t+1}{T} \cdot r_4 \quad (8)$$

جایی که  $r_4$  عددی تصادفی بین  $0$  و  $1$  است.

$$n_2: N(0, 1) \quad (9)$$

$$g(k) = \begin{cases} 1 & \text{if } k = j \\ 0 & \text{else} \end{cases}$$

به‌طوری‌که  $k = 1, \dots, d$ . معادلات مورد نیاز برای ایجاد یک نمونه اولیه عددی برای رویکرد پنهان‌سازی دلخواه به شرح زیر است:

$$v_i(t+1) = x_i(t) + R \cdot (r_4 \cdot b_{i,r}(t) - x_i(t)) \quad (10)$$

جایی که  $i = 1, \dots, n$ ،  $b_{i,r}(t)$  به‌طور تصادفی به‌عنوان لانه‌ای برای مخفی شدن از لانه  $d$  انتخاب شده است و  $r_4$  عدد تصادفی در بازه  $(0,1)$  است. پس از یک فرآیند کامل اکتشاف و بهره‌برداری، مکان خرگوش توسط رابطه زیر به‌روزرسانی می‌شود:

$$x_i(t+1) = \begin{cases} x_i(t) & f(x_i(t)) \leq f(v_i(t+1)) \\ v_i(t+1) & f(x_i(t)) > f(v_i(t+1)) \end{cases} \quad (11)$$

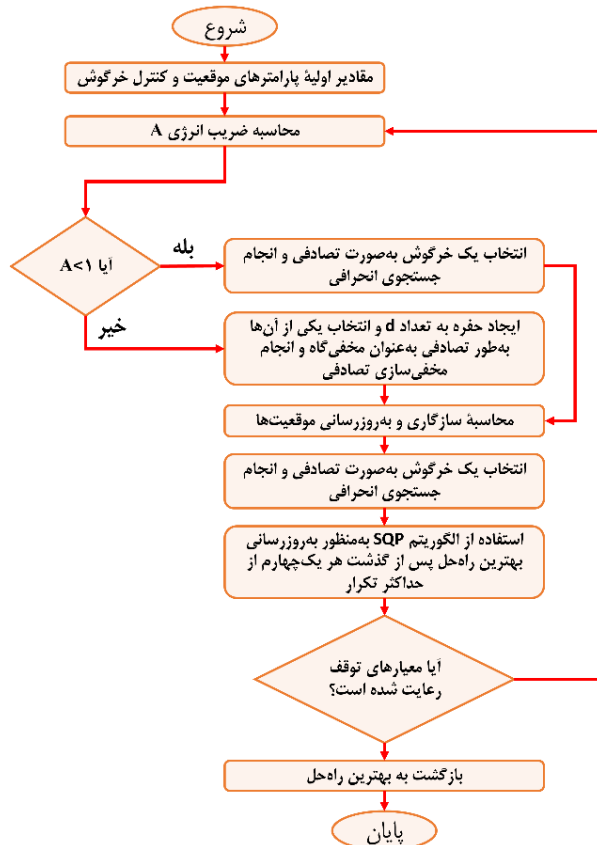
(۳) انقباض انرژی (تغییر از اکتشاف به بهره‌برداری): خرگوش‌ها قابلیت اکتشاف در مرحله اول و به دنبال آن بهره‌برداری در فاز بعدی را دارند. این تفاوت در جستجو به دلیل از دست دادن انرژی در خرگوش‌ها در زمان مناسب است. این ماده انرژی با عبارت زیر طراحی شده است (Saha et al., 2023):

$$A(t) = r \left(1 - \frac{t}{T}\right) \ln \frac{1}{r} \quad (12)$$

### ترکیب مدل برنامه‌نویسی درجه دوم متوالی با الگوریتم بهینه‌سازی خرگوش مصنوعی

روش برنامه‌نویسی درجه دوم متوالی (SQP) بهترین روش برنامه‌ریزی غیرخطی برای مسائل بهینه‌سازی محدود است (Radosavljević & Jevtić, 2016). SQP یک روش مستقیم است که در آن محدودیت‌ها به صورت صریح مدیریت می‌شوند. این روش از هر روش برنامه‌ریزی غیرخطی دیگر از نظر کارایی، دقت و درصد راه‌حل‌های موفقیت‌آمیز در تعداد زیادی از مسائل آزمایشی بهتر عمل می‌کند (Bedekar & Bhide, 2010; Sivasubramani & Swarup, 2011). این روش شباهت زیادی به روش نیوتن برای بهینه‌سازی محدود دارد که در هر تکرار، تقریبی از ماتریس هسین تابع لاگرانژی با استفاده از روش به‌روزرسانی شبه نیوتن برودن-فلچر-گلدفارب-شانو (BFGS) ساخته می‌شود. سپس از نتیجه تقریب برای ایجاد یک زیرمسئله برنامه‌نویسی درجه دوم (QP) استفاده می‌شود که راه‌حل آن برای تشکیل یک جهت جستجو برای رویه جستجوی خطی استفاده می‌شود. از آنجایی که OF مورد نظر که باید به حداقل برسد غیر محدب است، لذا SQP حداقل محلی را برای یک راه‌حل اولیه تضمین می‌کند. هر تکرار در الگوریتم SQP شامل سه مرحله اصلی است (Bedekar & Bhide, 2010) (Sivasubramani & Swarup, 2011): (الف) حل مسئله فرعی QP و به دست آوردن جهت جستجو، (ب) جستجوی خط و محاسبه تابع شایستگی، (پ) به‌روزرسانی ماتریس هسین تابع لاگرانژ، با استفاده از فرمول BFGS.

برای استفاده از مزیت روش‌های ARO و SQP و در عین حال برای رفع معایب این روش‌ها، یک ترکیبی با SQP در این مقاله پیشنهاد شده است. فرآیند SQP در ARO به عنوان ساز و کار جستجوی محلی برای بهبود همگرایی گنجانده شده است. ابتدا الگوریتم ARO به طور عادی اجرا می‌شود و بهترین تناسب در هر نسل در هر تکرار انتخاب می‌شود. از بهترین تناسب، عامل مربوطه به عنوان مقادیر اولیه متغیرها به روش SQP تنظیم می‌شود. سپس، روال SQP بسته به احتمال اتخاذ شده جستجوی محلی  $\alpha$ LS اجرا می‌شود و بهترین تناسب به دست آمده از GSA را در تکرار فعلی بهبود می‌بخشد. به این ترتیب، الگوریتم ترکیبی ARO-SQP راه‌حل بهینه جهانی را ارائه می‌دهد. نمودار جریان ARO-SQP در شکل (۳) است.



شکل ۳- فلوجارت بهینه‌سازی خرگوش مصنوعی در ترکیب با برنامه‌نویسی درجه دوم متوالی (ARO-SQP)

Figure 3- Artificial rabbit optimization flowchart in combination with sequential quadratic programming (ARO-SQP)

### 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) و مجذور ضریب همبستگی ( $R^2$ ) بود که بر اساس رابطه‌های زیر محاسبه می‌شوند:

$$MSE = \frac{\sum_{i=1}^N (O_i - P_i)^2}{N} \tag{13}$$

$$R^2 = \frac{\sum_{i=1}^N (O_i P_i)^2}{\sum_{i=1}^N O_i^2 \sum_{i=1}^N P_i^2} \tag{14}$$

در این روابط،  $O_i$  تبخیر و تعرق به روش پنمن موتیث فائو و  $P_i$  تبخیر و تعرق محاسبه شده به هر روش و  $N$  تعداد داده‌ها هستند. سه بهینه‌ساز فراابتکاری، یعنی PSO، GA، و ARO، برای تعیین مقادیر بهینه وزن‌ها ( $w_{ij}$ ) و بایاس‌ها ( $w_{jk}$ ) همان‌طور که در شکل (۲) نشان داده شده است، استفاده می‌شود. وزن‌ها و بایاس‌ها به‌عنوان افراد بهینه‌ساز در نظر گرفته می‌شوند که با به حداقل رساندن یک تابع هزینه با استفاده از بهینه‌سازهای مختلف تعیین می‌شوند.

هم‌چنین جهت ارزیابی کارایی مدل از سایر روش‌های داده‌کاوی هم‌چون رگرسیون خطی<sup>۱</sup> (LR)، رگرسیون درجه دوم محض<sup>۲</sup> (PQ)، رگرسیون تعاملی<sup>۳</sup> (IR)، رگرسیون جنگل تصادفی<sup>۴</sup> (RFs)، رگرسیون نزدیک‌ترین همسایگی<sup>۱</sup> (KNN) و هم‌چنین مدل‌های ترکیبی شبکه عصبی مصنوعی با الگوریتم ژنتیک (ANN-GA) و شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی ذرات (ANN-PSO) استفاده شد.

<sup>1</sup> Linear regression  
<sup>2</sup> Pure quadratic equation  
<sup>3</sup> Interaction regression  
<sup>4</sup> Random forest

## نتایج و بحث

در این تحقیق به ارزیابی مدل هیبریدی ANN-ARO و مقایسه آن با سایر الگوریتم‌های بهینه‌سازی PSO و GA و نیز مدل‌های داده‌کاوی رگرسیون خطی، رگرسیون درجه دوم محض، رگرسیون تعاملی، رگرسیون جنگل تصادفی و رگرسیون نزدیک‌ترین همسایگی در تخمین تبخیر و تعرق مرجع با استفاده از حداقل پارامترهای هواشناسی در دو اقلیم مختلف پرداخته شد؛ لذا عملکرد مدل‌های پیشنهادی با داده‌های ورودی بین ۲ الی ۱۰ پارامتر هواشناسی مورد بررسی قرار گرفت بود. همچنین مدل فائو پنمن موتیث به‌عنوان خروجی مدل‌ها در نظر گرفته شد. کدنویسی کلیه مدل‌های مورد بررسی در نرم‌افزار MATLAB نسخه (R2023a) انجام شد که مراحل اجرای مدل هیبریدی در شکل (۳) نشان داده شده است. داده‌ها بدون به‌هم‌ریختگی به ۵ قسمت تقسیم شدند (چون باید توالی زمانی حفظ شود) و چهار قسمت اول (۸۰ درصد) ابتدایی برای آموزش و ۲۰ درصد انتهایی (با توجه به اینکه دوره داده‌ها ۲۴ سال است، حدود ۴ سال و نیم) به‌عنوان 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 نرون و لایه پنهان دوم ۳ لایه در نظر گرفته شد. بهینه‌سازی لایه پنهان به روش سعی و خطا انجام شد (Jain et al., 2008) 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. برای آپدیت وزن‌ها در شبکه عصبی از الگوریتم لوبنبرگ-مارکوارت استفاده شد. چندین تکرار برای هر مدل انجام شد و معیارهای ارزیابی محاسبه‌شده برای هر دو ایستگاه بیرجند و مشهد، به‌ترتیب در جدول‌های (۳) و (۴) نشان داده شده است. شکل (۴) نیز میزان میانگین مربعات خطا برای داده‌های تبخیر و تعرق مرجع پیش‌بینی‌شده (خروجی) نسبت به تبخیر و تعرق واقعی می‌باشد که نشان‌دهنده برتری مدل ANN-ARO نسبت به سایر مدل‌های هیبریدی است.

<sup>1</sup> K-nearest neighbors

جدول ۳- ارزیابی مدل‌های مختلف هیبریدی و داده‌کاوی در برآورد تبخیر و تعرق مرجع با استفاده از داده‌های هواشناسی روزانه در ایستگاه بیرجند

Table 3- Evaluation of different hybrid models and data mining in estimation of reference evapotranspiration using daily meteorological data in Birjand station

مدل									ارزیابی مدل	متغیرهای ورودی	ترکیب
ANN-ARO	ANN-PSO	ANN-GA	KNN	RFs	ANN	IR	PQ	LR			
0.0015	0.0025	0.0027	0.0030	0.0010	0.0014	0.0045	0.0026	0.0049	MSE	T <sub>max</sub> , n	C1
0.9749	0.9578	0.9541	0.9499	0.9425	0.9749	0.9226	0.9558	0.0918	R <sup>2</sup>		
0.0034	0.0046	0.0046	0.0001	0.0012	0.0031	0.0272	0.0073	0.0276	MSE	RH, n	C2
0.9470	0.9156	0.9238	0.8903	0.8788	0.9434	0.5191	0.8714	0.5149	R <sup>2</sup>		
0.0058	0.0058	0.0061	0.0017	0.0022	0.0048	0.0506	0.0102	0.0517	MSE	WS, n	C3
0.9190	0.8930	0.8905	0.8252	0.8202	0.9105	0.0339	0.8227	0.2517	R <sup>2</sup>		
0.0060	0.0057	0.0064	0.0008	0.0040	0.0049	0.0429	0.0096	0.0445	MSE	R <sub>s</sub> , n	C4
0.9171	0.8900	0.8149	0.8027	0.8054	0.8964	0.6724	0.8055	0.4135	R <sup>2</sup>		
0.0001	0.0030	0.0028	0.0018	0.0030	0.0001	0.0071	0.0024	0.0072	MSE	T <sub>min</sub> , T <sub>max</sub> , R <sub>s</sub> , n	C5
0.9980	0.9493	0.9527	0.9691	0.9492	0.9980	0.8802	0.9600	0.8778	R <sup>2</sup>		
0.0001	0.0037	0.0035	0.0033	0.0045	0.0001	0.0054	0.0023	0.0076	MSE	T <sub>min</sub> , T <sub>max</sub> , WS, RH, R <sub>s</sub> , n	C6
0.9978	0.9376	0.9422	0.9448	0.9256	0.9969	0.902	0.9616	0.8721	R <sup>2</sup>		
0.0001	0.0033	0.0026	0.0031	0.0043	0.0001	0.0011	0.0011	0.0027	MSE	T <sub>min</sub> , T <sub>max</sub> , AT, AP, VP, RF, RH, SS, R <sub>s</sub> , n	C7
0.9996	0.9439	0.9554	0.9480	0.9269	0.9995	0.9817	0.9812	0.9548	R <sup>2</sup>		


T<sub>min</sub>: دمای حداقل، T<sub>max</sub>: دمای حداکثر، AT: دمای میانگین، AP: فشار میانگین ایستگاه، VP: میانگین فشار بخار، RF: بارش ۲۴ ساعته، RH: میانگین رطوبت نسبی، SS: ساعت آفتابی، SR: میزان تابش کلی ۲۴ ساعته و n: روز از سال.

جدول ۴- ارزیابی مدل‌های مختلف هیبریدی و داده‌کاوی در برآورد تبخیر و تعرق مرجع با استفاده از داده‌های هواشناسی روزانه در ایستگاه مشهد

Table 4- Evaluation of different hybrid models and data mining in estimation of reference evapotranspiration using daily meteorological data in Mashhad station

مدل									ارزیابی مدل	متغیرهای ورودی	ترکیب
ANN-ARO	ANN-PSO	ANN-GA	KNN	RFs	ANN	IR	PQ	LR			
0.0011	0.0022	0.0023	0.0023	0.0032	0.0012	0.0051	0.0024	0.0054	MSE	T <sub>max</sub> , n	C1
0.9815	0.9623	0.9607	0.9613	0.9461	0.9805	0.9144	0.9600	0.9104	R <sup>2</sup>		
0.0035	0.0044	0.0044	0.0074	0.0081	0.0037	0.0211	0.0079	0.0216	MSE	RH, n	C2
0.9405	0.9269	0.9264	0.8762	0.8656	0.9377	0.6492	0.8693	0.6406	R <sup>2</sup>		
0.0065	0.0082	0.0076	0.013	0.0143	0.0069	0.0526	0.0139	0.0544	MSE	WS, n	C3
0.8910	0.8631	0.8744	0.7786	0.7628	0.8858	0.1269	0.0767	0.0936	R <sup>2</sup>		
0.0075	0.0075	0.0083	0.0123	0.0135	0.0071	0.0421	0.0130	0.0401	MSE	R <sub>s</sub> , n	C4
0.8998	0.8761	0.8619	0.7947	0.7750	0.8813	0.2965	0.7836	0.3299	R <sup>2</sup>		
0.0001	0.0032	0.0031	0.0015	0.0033	0.0001	0.0025	0.0020	0.0051	MSE	T <sub>min</sub> , T <sub>max</sub> , R <sub>s</sub> , n	C5
0.9983	0.9465	0.9479	0.9754	0.9447	0.9982	0.9587	0.9660	0.9144	R <sup>2</sup>		
0.0001	0.0039	0.0027	0.0028	0.0047	93.3615	0.0022	0.0021	0.0051	MSE	T <sub>min</sub> , T <sub>max</sub> , WS, RH, R <sub>s</sub> , n	C6
0.9985	0.9348	0.9548	0.9536	0.9221	0.9980	0.9629	0.9657	0.9143	R <sup>2</sup>		
0.0001	0.0034	0.0027	0.0031	0.0044	0.0001	0.0010	0.0012	0.0033	MSE	T <sub>min</sub> , T <sub>max</sub> , AT, AP, VP, RF, RH, SS, R <sub>s</sub> , n	C7
0.9986	0.9440	0.9555	0.9480	0.9270	0.9993	0.9827	0.9788	0.9441	R <sup>2</sup>		

T<sub>min</sub>: دمای حداقل، T<sub>max</sub>: دمای حداکثر، AT: دمای میانگین، AP: فشار میانگین ایستگاه، VP: میانگین فشار بخار، RF: بارش ۲۴ ساعته، RH: میانگین رطوبت نسبی، SS: ساعت آفتابی، SR: میزان تابش کلی ۲۴ ساعته و n: روز از سال.



شکل ۴- میانگین مربعات خطا برای داده‌های تبخیر و تعرق مرجع پیش‌بینی شده (خروجی) نسبت به تبخیر و تعرق واقعی  
Figure 4- Mean squared error for predicted reference evapotranspiration data (output) compared to actual evapotranspiration

در مجموع نتایج مشابهی در هر دو ایستگاه به‌دست آمد. ترکیبات ورودی چهار مدل اول به‌ترتیب دما (حداکثر)، رطوبت نسبی، سرعت باد و تابش خالص به‌همراه 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 تبخیر و تعرق مرجع در هر دو ایستگاه دارد و به‌دنبال آن میانگین رطوبت نسبی قرار دارد. بر این اساس، دو ترکیب بعدی از داده‌های ورودی، شامل دما به‌علاوه دو نوع دیگر از متغیرهای هواشناسی بر اساس عملکرد مدل آن‌ها بودند. همان‌طور که در جدول‌های ۱ و ۲ نشان داده شده است، استفاده از 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 نزدیک به معادله FAO56-PM تولید کردند و مدل ANN-ARO حداقل MSE را ارائه کرد و مقدار  $R^2$  برای مدل ANN-ARO تقریباً برابر با یک بود. پس از اضافه‌شدن دما به‌عنوان ورودی مدل (C5)، دقت مدل نسبت به زمانی که تنها تشعشع خالص (C1) به‌عنوان ورودی مدل در نظر گرفته شد، به‌شدت بهبود یافت، از طرفی مقایسه نتایج ترکیب C5 با C1 نشان می‌دهد دقت مدل با اضافه‌شدن تشعشع خالص 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. به‌همین ترتیب، افزودن رطوبت نسبی و سرعت باد منجر به افزایش اندکی در  $R^2$  شد (C6). با این‌حال، با تعداد بیش‌تر متغیرهای ورودی، قابلیت این مدل‌ها برای تخمین تبخیر و تعرق مرجع، قطعاً بهبود یافته است. با توجه به استفاده از ورودی داده‌های هواشناسی محدود و دقت تخمین، بهترین مدل ANN مدل ANN-ARO با C1 بود که در آن مقادیر  $R^2$ ، MSE با استفاده از پارامتر دما به‌همراه روز از سال، به‌ترتیب  $0/9749$  و  $0/0015$  در ایستگاه بیرجند و  $0/9815$  و  $0/0011$  در ایستگاه مشهد بودند. هم‌چنین در شرایط استفاده از پارامترهای کامل هواشناسی نیز مدل هیبریدی ANN-ARO در هر دو ایستگاه بیرجند و مشهد هر دو با  $R^2=0/9986$  و  $MSE=0/0001$  بهترین عملکرد را در تخمین تبخیر و تعرق مرجع داشت.

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، مدل‌های رگرسیون درجه دوم محض، رگرسیون جنگل تصادفی و رگرسیون نزدیک‌ترین همسایگی، بهترین نتایج را داشتند، به‌جز ترکیب C7 که مدل‌های رگرسیون جنگل تصادفی و رگرسیون نزدیک‌ترین همسایگی عملکرد مناسب‌تری داشت. در بین سایر مدل‌های هیبریدی نیز، مدل‌های ANN-GA و ANN-PSO که توسط محققان بسیاری مورد استفاده قرار گرفته‌اند، هر دو از نظر تخمین تبخیر و تعرق مرجع با پارامترهای کامل هواشناسی خوب عمل کردند، درحالی‌که نتایج این پژوهش نشان می‌دهد در شرایطی که با پارامترهای هواشناسی محدود مواجهیم، مدل‌های هیبریدی ANN-GA و ANN-PSO عملکرد به‌مراتب ضعیف‌تری نسبت به ANN-ARO دارند.

به‌طور کلی، مدل ANN-ARO مورد استفاده در این مطالعه عملکرد مناسبی را در تخمین تبخیر و تعرق مرجع به‌خصوص با ورودی داده‌های هواشناسی منفرد (C1-C4) نشان داد، درحالی‌که برای شرایطی که تنها از پارامتر دما استفاده شد (C1)، این مدل دقت بالاتری با قابلیت امیدوارکننده و ثابت‌تر برای تخمین تبخیر و تعرق مرجع نشان داد و ترکیب C5 و C6 نیز با ترکیب پارامترهای 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 رطوبت نسبی ( $RH$ ) باید برای رسیدن به سطح قابل قبول صحت پیش‌بینی در دسترس باشد که با نتایج Long و همکاران (۲۰۲۲) هم‌خوانی دارد. در اکثر مطالعات سناریوهایی با داده‌های دما یا رطوبت نسبی را به‌عنوان حداقل متغیر برای پیش‌بینی تبخیر و تعرق مرجع با استفاده از مدل‌های هوش مصنوعی در نظر گرفته‌اند و به نتایج خوبی دست‌یافته‌اند. Shiri (۲۰۱۸) و Long و همکاران (۲۰۲۲) دریافتند که ترکیب روش‌های هوش مصنوعی با الگوریتم‌های بهینه‌سازی دقت پیش‌بینی  $ET_0$  را تا حد زیادی در مورد متغیر هواشناسی تک‌ورودی بهبود می‌بخشد. نتایج این پژوهش نشان می‌دهد با ترکیب دو پارامتر دما و تشعشع خالص، نتایج پیش‌بینی تا حدی بهبود می‌یابد، همان‌طور که Goyal و همکاران (۲۰۲۳) نشان دادند ترکیب دو پارامتر ( $R_s$ ,  $T$ ) برای پیش‌بینی تبخیر و تعرق مرجع در مناطق خشک یا نیمه‌خشک به‌خوبی کار می‌کند. نتایج نشان می‌دهد در ایستگاه مشهد، سرعت باد کم‌ترین پارامتر مرتبط با  $ET_0$  است، درحالی‌که در ایستگاه بیرجند، سرعت باد عملکرد مؤثرتری نسبت به تشعشع خالص داشت که هردو نتیجه با نتایج Goyal و همکاران (۲۰۲۳) هم‌خوانی دارد. Wang و همکاران (۲۰۱۹) در یک تجزیه و تحلیل حساسیت که برای درک تأثیر متغیرهای مختلف هواشناسی بر مدل‌سازی  $ET_0$  انجام شد، به این نتیجه رسیدند که ترتیب پارامترهای تکی که بر  $ET_0$  تأثیر می‌گذارند  $n > T_{max} > RH > u_2 > T_{min} > R_s$  است.

### نتیجه‌گیری

برآورد دقیق نرخ تبخیر و تعرق مرجع ( $ET_0$ ) برای مدیریت منابع آب و به حداکثر رساندن بهره‌وری کشاورزی بسیار مهم است. با این حال، روش فائو پنمن مونتیث را نمی‌توان در مناطق با داده‌های هواشناسی محدود اعمال کرد. برخی از مدل‌های تجربی می‌تواند در این زمینه استفاده شود. با این وجود، فقدان مبانی فیزیکی و محدودیت تغییرپذیری مکانی پارامترها، آن را برای تخمین تبخیر و تعرق مرجع در مناطق مختلف آب‌وهوایی نامناسب کرده است؛ بنابراین، این مقاله روش جدیدی برای تخمین تبخیر و تعرق مرجع در مناطق با کمبود داده پیشنهاد می‌کند. در این مقاله، مدلی برای تخمین نرخ تبخیر و تعرق مرجع در اقلیم‌های مختلف و با استفاده از حداقل پارامترهای هواشناسی بررسی شد. نتایج این پژوهش نشان می‌دهد که در کلیه موارد، روش ترکیبی خرگوش مصنوعی (ANN-ARO) از سایر روش‌ها بهتر عمل می‌کند. در این پژوهش مدل هیبریدی بهینه‌سازی خرگوش مصنوعی ANN-ARO با استفاده از داده‌های آب‌وهوایی اندازه‌گیری شده از شهرهای مشهد و بیرجند برای تخمین تبخیر و تعرق مرجع در شرایط پارامترهای هواشناسی محدود پیاده‌سازی شد و نتایج آن با سایر مدل‌های هیبریدی ANN-GA و ANN-PSO و همچنین روش‌های داده‌کاوی رگرسیون خطی (LR)، رگرسیون درجه دوم محض (PQ)، رگرسیون تعاملی (IR)، درخت کلاس رگرسیون (CT)، رگرسیون جنگل تصادفی (RFs) و رگرسیون نزدیک‌ترین همسایگی (KNN) مقایسه شد. معادله فائو پنمن مونتیث (FAO-56) به‌عنوان معادله مرجع انتخاب شد. مدل‌های کاربردی با استفاده از نرم‌افزار MATLAB توسعه یافته و توسط MSE و  $R^2$  مقایسه شدند. نتایج نشان می‌دهد مدل بهینه‌سازی خرگوش مصنوعی ANN-ARO در تمام مراحل بهترین نتایج را داشته است. نتایج به‌دست‌آمده نشان می‌دهد که مدل ANN-ARO پیشنهادی می‌تواند برای تخمین تبخیر و تعرق مرجع با پارامترهای اقلیمی محدود، با قابلیت اطمینان بالا استفاده شود. مقایسه ورودی‌های مختلف آب‌وهوایی نشان داد که دقت تخمین مدل‌های اعمال‌شده با گنجاندن متغیرهای ورودی بیش‌تر و چهار ورودی (دما، تابش خورشیدی، رطوبت نسبی و سرعت باد) بهترین تخمین‌ها را برای هر روش ایجاد می‌کند. همچنین، نتایج نشان داد که دما تأثیر بیش‌تری بر تخمین  $ET_0$  در اقلیم‌های مورد بررسی دارد درحالی‌که سایر پارامترها از جمله رطوبت نسبی، تشعشع خالص و سرعت باد در ورودی‌ها، تأثیر کم‌تری در تخمین  $ET_0$  دارند. یافته‌های این مطالعه نشان می‌دهد که می‌توان از ANN-ARO برای تخمین دقیق نرخ تبخیر و تعرق مرجع بر اساس حداقل پارامترهای هواشناسی استفاده کرد. علاوه بر این، ANN-ARO می‌تواند در اقلیم‌های مختلف، به‌ویژه در مناطقی که با کم‌آبی مواجه‌اند، استفاده شود. پیش‌بینی  $ET_0$  بر اساس تقسیم داده‌های ورودی بر اساس روز از سال که در پژوهش حاضر به‌کارگرفته شد، رویکرد جدیدی است که در مطالعه اخیر مورد بررسی قرار گرفته است. دلیل احتمالی پشت این موضوع می‌تواند به‌دلیل نوسانات در محدوده متغیرهای آب‌وهوا در طول تابستان و زمستان نسبت به فصل بهار و پاییز باشد. این رویکرد را می‌توان در مطالعات آتی بیش‌تر مورد بررسی قرار داد.

### ملاحظات اخلاقی

**دسترسی به داده‌ها:** داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

**مشارکت نویسندگان:** معین توسن، علی ماروسی و حسین خزیمه‌نژاد؛ بخش‌های مختلف مقاله توسط نام‌برندگان انجام و نگاشته شده است.

**تضاد منافع نویسندگان:** نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

**سپاس‌گزاری:** نویسندگان این مقاله، از سازمان هواشناسی کشور برای در اختیار دادن داده‌های هواشناسی سپاس‌گزاری می‌نمایند.

## منابع

۱. باقری‌فام، صبا، دلاور، کشاورز، محمد امیر، کشاورز، پیمان، و کرمی، پرویز. (۱۴۰۱). اثر تغییرات اقلیمی بر مقادیر ذخایر کربن آلی خاک اقلیم نیمه‌خشک مشهد با استفاده از مدل RothC. *تحقیقات آب و خاک ایران*. ۵۳(۱۰). doi: 10.22067/JSW.2022.78752.1202
۲. رضوانی‌مقدم، جواد، یعقوب‌زاده، مصطفی، جعفرزاده، احمد. (۱۳۹۷). ارزیابی عملکرد روش‌های انتخاب متغیر در ریزمقیاس‌نمایی بارش روزانه دو اقلیم متفاوت. *آب و خاک*. ۳۲(۴): ۸۴۷-۸۳۱. doi: 10.22067/JSW.V32I4.72732
۳. توسن، معین، علیزاده، امین، انصاری، حسین، رضوانی‌مقدم، پرویز. (۱۳۹۴). ارزیابی عملکرد و شناسایی مناطق مستعد کشت زعفران (*Crocus sativus* L.) در استان خراسان رضوی بر اساس شاخص‌های دمایی. *زراعت و فناوری زعفران*. ۳(۱): ۱-۱۲. doi: 10.22048/josat.2014.9605

## References

1. Abrishami, N., Sepaskhah, A. R., & Shahrokhnia, M. H. (2019). Estimating wheat and maize daily evapotranspiration using artificial neural network. *Theoretical and Applied Climatology*, 135, 945-958. doi: 10.1007/s00704-018-2418-4.
2. Adnan, R. M., Liang, Z., Trajkovic, S., Zounemat-Kermani, M., Li, B., & Kisi, O. (2019). Daily streamflow prediction using optimally pruned extreme learning machine. *Journal of Hydrology*, 577, 123981. doi: 10.1016/j.jhydrol.2019.123981.
3. Adnan, R. M., Liang, Z., Yuan, X., Kisi, O., Akhlaq, M., & Li, B. (2019). Comparison of LSSVR, M5RT, NF-GP, and NF-SC models for predictions of hourly wind speed and wind power based on cross-validation. *Energies*, 12(2), 329. doi: 10.3390/en12020329.
4. Adnan, R. M., Mostafa, R. R., Islam, A. R. M. T., Kisi, O., Kuriqi, A., & Heddami, S. (2021). Estimating reference evapotranspiration using hybrid adaptive fuzzy inferencing coupled with heuristic algorithms. *Computers and Electronics in Agriculture*, 191, 106541. doi: 10.1016/j.compag.2021.106541.
5. Adnan, R. M., Mostafa, R. R., Kisi, O., Yaseen, Z. M., Shahid, S., & Zounemat-Kermani, M. (2021). Improving streamflow prediction using a new hybrid ELM model combined with hybrid particle swarm optimization and grey wolf optimization. *Knowledge-Based Systems*, 230, 107379. doi: 10.1016/j.knsys.2021.107379.
6. Adnan, R. M., Yuan, X., Kisi, O., Adnan, M., & Mehmood, A. (2018). Stream flow forecasting of poorly gauged mountainous watershed by least square support vector machine, fuzzy genetic algorithm and M5 model tree using climatic data from nearby station. *Water Resources Management*, 32, 4469-4486. doi: 10.1007/s11269-018-2033-2.
7. Alizamir, M., Kisi, O., Muhammad Adnan, R., & Kuriqi, A. (2020). Modelling reference evapotranspiration by combining neuro-fuzzy and evolutionary strategies. *Acta Geophysica*, 68, 1113-1126. doi: 10.1007/s11600-020-00446-9.
8. Allen, R. G., Pruitt, W. O., Wright, J. L., Howell, T. A., Ventura, F., Snyder, R., Itenfisu, D., Steduto, P., Berengena, J., & Yrisarry, J. B. (2006). A recommendation on standardized surface resistance for hourly calculation of reference ET<sub>o</sub> by the FAO56 Penman-Monteith method. *Agricultural Water Management*, 81(1-2), 1-22. doi: 10.1016/j.agwat.2005.03.007.
9. Alsaiani, A. O., Moustafa, E. B., Alhumade, H., Abulkhair, H., & Elsheikh, A. (2023). A coupled artificial neural network with artificial rabbits optimizer for predicting water productivity of different designs of solar stills. *Advances in Engineering Software*, 175, 103315. doi: 10.1016/j.advengsoft.2022.103315.
10. Araghi, A., Adamowski, J., & Martinez, C. J. (2020). Comparison of wavelet-based hybrid models for the estimation of daily reference evapotranspiration in different climates. *Journal of Water and Climate Change*, 11(1), 39-53. doi: 10.2166/wcc.2018.113.
11. Bagherifam, S., Delavar, M. A., Keshavarz, P., & Karami, P. (2022). Application of the RothC Model in Simulating Effect of Climate Change on CO<sub>2</sub> Emissions and Soil Organic Carbon Stocks in Semi-arid Climate of Khorasan-e-Razavi. *Water and Soil*, 36(5), 611-628. doi: 10.22067/JSW.2022.78752.1202. [In Persian]
12. Başakın, E. E., Ekmekcioğlu, Ö., Stoy, P. C., & Özger, M. (2023). Estimation of daily reference evapotranspiration by hybrid singular spectrum analysis-based stochastic gradient boosting. *MethodsX*, 10, 102163. doi: 10.1016/j.mex.2023.102163.
13. Bedekar, P. P., & Bhide, S. R. (2010). Optimum coordination of directional overcurrent relays using the hybrid GA-NLP approach. *IEEE Transactions on Power Delivery*, 26(1), 109-119. doi: 10.1109/TPWRD.2010.2080289.
14. Bellido-Jiménez, J. A., Estévez, J., & García-Marín, A. P. (2021). New machine learning approaches to improve reference evapotranspiration estimates using intra-daily temperature-based variables in a semi-arid region of Spain. *Agricultural Water Management*, 245, 106558. doi: 10.1016/j.agwat.2020.106558.
15. Chia, M. Y., Huang, Y. F., & Koo, C. H. (2021). Swarm-based optimization as stochastic training strategy for estimation of reference evapotranspiration using extreme learning machine. *Agricultural Water Management*, 243, 106447. doi: 10.1016/j.agwat.2020.106447.
16. Cui, L., Cui, J., Hao, Z., Li, L., Ding, Z., & Liu, Y. (2022). An empirical study of vulnerability discovery methods over the past ten years. *Computers & Security*, 120, 102817. doi: 10.1016/j.cose.2022.102817.
17. Dong, J., Liu, X., Huang, G., Fan, J., Wu, L., & Wu, J. (2021). Comparison of four bio-inspired algorithms to optimize KNEA for predicting monthly reference evapotranspiration in different climate zones of China. *Computers and Electronics in Agriculture*, 186, 106211. doi: 10.1016/j.compag.2021.106211.
18. Dong, Y., & Hansen, H. (2023). Development and design of an affordable field scale weighing lysimeter using a microcontroller system. *Smart Agricultural Technology*, 4, 100147. doi: 10.1016/j.atech.2022.100147.
19. Ehteram, M., Singh, V. P., Ferdowsi, A., Mousavi, S. F., Farzin, S., Karami, H., Mohd, N. S., Afan, H. A., Lai, S. H., & Kisi, O. (2019). An improved model based on the support vector machine and cuckoo algorithm for simulating reference evapotranspiration. *PloS one*, 14(5), e0217499. doi: 10.1016/j.atech.2022.100147.
20. Fan, J., Ma, X., Wu, L., Zhang, F., Yu, X., & Zeng, W. (2019). Light Gradient Boosting Machine: An efficient soft computing model for estimating daily reference evapotranspiration with local and external meteorological data. *Agricultural Water Management*, 225, 105758. doi: 10.1016/j.agwat.2019.105758.

21. Feizi, H., & Tosan, M. (2016, November). 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). doi: [10.17660/ActaHortic.2017.1184.15](https://doi.org/10.17660/ActaHortic.2017.1184.15).
22. Feng, T., Su, T., Zhi, R., Tu, G., & Ji, F. (2019). Assessment of actual evapotranspiration variability over global land derived from seven reanalysis datasets. *International Journal of Climatology*, 39(6), 2919-2932. doi: [10.1002/joc.5992](https://doi.org/10.1002/joc.5992).
23. Feng, Y., Hao, W., Li, H., Cui, N., Gong, D., & Gao, L. (2020). Machine learning models to quantify and map daily global solar radiation and photovoltaic power. *Renewable and Sustainable Energy Reviews*, 118, 109393. doi: [10.1016/j.rser.2019.109393](https://doi.org/10.1016/j.rser.2019.109393).
24. Feng, Y., Jia, Y., Cui, N., Zhao, L., Li, C., & Gong, D. (2017). Calibration of Hargreaves model for reference evapotranspiration estimation in Sichuan basin of southwest China. *Agricultural Water Management*, 181, 1-9. doi: [10.1016/j.agwat.2016.11.010](https://doi.org/10.1016/j.agwat.2016.11.010).
25. Ferreira, L. B., da Cunha, F. F., de Oliveira, R. A., & Fernandes Filho, E. I. (2019). Estimation of reference evapotranspiration in Brazil with limited meteorological data using ANN and SVM—A new approach. *Journal of Hydrology*, 572, 556-570. doi: [10.1016/j.jhydrol.2019.03.028](https://doi.org/10.1016/j.jhydrol.2019.03.028).
26. Ferreira, L. B., da Cunha, F. F., & Fernandes Filho, E. I. (2022). Exploring machine learning and multi-task learning to estimate meteorological data and reference evapotranspiration across Brazil. *Agricultural Water Management*, 259, 107281. doi: [10.1016/j.agwat.2021.107281](https://doi.org/10.1016/j.agwat.2021.107281).
27. Gocić, M., Motamedi, S., Shamshirband, S., Petković, D., Ch, S., Hashim, R., & Arif, M. (2015). Soft computing approaches for forecasting reference evapotranspiration. *Computers and Electronics in Agriculture*, 113, 164-173. doi: [10.1016/j.compag.2015.02.010](https://doi.org/10.1016/j.compag.2015.02.010).
28. Gong, D., Hao, W., Gao, L., Feng, Y., & Cui, N. (2021). Extreme learning machine for reference crop evapotranspiration estimation: Model optimization and spatiotemporal assessment across different climates in China. *Computers and Electronics in Agriculture*, 187, 106294. doi: [10.1016/j.compag.2021.106294](https://doi.org/10.1016/j.compag.2021.106294).
29. 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 and Electronics in Agriculture*, 209, 107836. doi: [10.1016/j.compag.2023.107836](https://doi.org/10.1016/j.compag.2023.107836).
30. Hernandez, F. B. T., Neale, C., de C. Teixeira, A., & Taghvaeian, S. (2012). DETERMINING LARGE SCALE ACTUAL EVAPOTRANSPIRATION USING AGRO- METEOROLOGICAL AND REMOTE SENSING DATA IN THE NORTHWEST OF SAO PAULO STATE, BRAZIL. VII International Symposium on Irrigation of Horticultural Crops 1038. doi: [10.17660/ActaHortic.2014.1038.31](https://doi.org/10.17660/ActaHortic.2014.1038.31).
31. Jain, S., Nayak, P., & Sudheer, K. (2008). Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. *Hydrological Processes: An International Journal*, 22(13), 2225-2234. doi: <https://doi.org/10.1002/hyp.6819>.
32. Jiang, Z.-Y., Yang, Z.-G., Zhang, S.-Y., Liao, C.-M., Hu, Z.-M., Cao, R.-C., & Wu, H.-W. (2020). Revealing the spatio-temporal variability of evapotranspiration and its components based on an improved Shuttleworth-Wallace model in the Yellow River Basin. *Journal of Environmental Management*, 262, 110310. doi: [10.1002/hyp.6819](https://doi.org/10.1002/hyp.6819).
33. Kang, Y., Chen, P., Cheng, X., Zhang, S., & Song, S. (2022). Novel hybrid machine learning framework with decomposition–transformation and identification of key modes for estimating reference evapotranspiration. *Agricultural Water Management*, 273, 107882. doi: [10.1016/j.agwat.2022.107882](https://doi.org/10.1016/j.agwat.2022.107882).
34. Kim, H.-J., Chandrasekara, S., Kwon, H.-H., Lima, C., & Kim, T.-W. (2023). A novel multi-scale parameter estimation approach to the Hargreaves-Samani equation for estimation of Penman-Monteith reference evapotranspiration. *Agricultural Water Management*, 275, 108038. doi: [10.1016/j.agwat.2022.108038](https://doi.org/10.1016/j.agwat.2022.108038).
35. Kisi, O. (2015). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528, 312-320. doi: [10.1016/j.jhydrol.2015.06.052](https://doi.org/10.1016/j.jhydrol.2015.06.052).
36. Kumar, M., Raghuvanshi, N., & Singh, R. (2011). Artificial neural networks approach in evapotranspiration modeling: a review. *Irrigation science*, 29, 11-25. doi: [10.1007/s00271-010-0230-8](https://doi.org/10.1007/s00271-010-0230-8).
37. Ladhani, I., Houichi, L., Djemili, L., Heddad, S., & Belouz, K. (2012). Modeling daily reference evapotranspiration (ET<sub>0</sub>) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): A comparative study. *Meteorology and Atmospheric Physics*, 118, 163-178. doi: [10.1007/s00703-012-0205-9](https://doi.org/10.1007/s00703-012-0205-9).
38. Long, X., Wang, J., Gong, S., Li, G., & Ju, H. (2022). Reference evapotranspiration estimation using long short- term memory network and wavelet- coupled long short- term memory network. *Irrigation and Drainage*, 71(4), 855-881. doi: [10.1002/ird.2699](https://doi.org/10.1002/ird.2699).
39. Luo, Y., Traore, S., Lyu, X., Wang, W., Wang, Y., Xie, Y., Jiao, X., & Fipps, G. (2015). Medium range daily reference evapotranspiration forecasting by using ANN and public weather forecasts. *Water Resources Management*, 29, 3863-3876. doi: [10.1007/s11269-015-1033-8](https://doi.org/10.1007/s11269-015-1033-8).
40. Majhi, B., & Naidu, D. (2021). Differential evolution based radial basis function neural network model for reference evapotranspiration estimation. *SN Applied Sciences*, 3, 1-19. doi: [10.1007/s42452-020-04069-z](https://doi.org/10.1007/s42452-020-04069-z).
41. Majhi, B., Naidu, D., Mishra, A. P., & Satapathy, S. C. (2020). Improved prediction of daily pan evaporation using Deep-LSTM model. *Neural Computing and Applications*, 32, 7823-7838. doi: [10.1007/s00521-019-04127-7](https://doi.org/10.1007/s00521-019-04127-7).
42. Muhammad Adnan, R., Yuan, X., Kisi, O., Yuan, Y., Tayyab, M., & Lei, X. (2019). Application of soft computing models in streamflow forecasting. Proceedings of the Institution of civil Engineers-Water Management, doi: [10.1680/jwama.16.00075](https://doi.org/10.1680/jwama.16.00075).
43. Patil, A. P., & Deka, P. C. (2017). Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications*, 28, 275-285. doi: [10.1007/s00521-015-2055-0](https://doi.org/10.1007/s00521-015-2055-0).
44. Radosavljević, J., & Jevtić, M. (2016). Hybrid GSA- SQP algorithm for optimal coordination of directional overcurrent relays. *IET Generation, Transmission & Distribution*, 10(8), 1928-1937. doi: [10.1049/iet-gtd.2015.1223](https://doi.org/10.1049/iet-gtd.2015.1223).

45. Ramezani Moghadam, J., Yaghoobzadeh, M., & Jafarzadeh, A. (2018). Examination of Feature Selection Methods for Downscaling of Daily Precipitation in Two Different Climates. *Water and Soil*, 32(4), 831-848. doi: [10.22067/JSW.V32I4.72732](https://doi.org/10.22067/JSW.V32I4.72732). [In Persian]
46. Reis, M. M., da Silva, A. J., Junior, J. Z., Santos, L. D. T., Azevedo, A. M., & Lopes, É. M. G. (2019). Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data. *Computers and Electronics in Agriculture*, 165, 104937. doi: [10.1016/j.compag.2019.104937](https://doi.org/10.1016/j.compag.2019.104937).
47. 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 and technology*, 4(SUPPLEMENT), 1-78. <https://doi.org/10.22048/jsat.2016.39250>. doi: [10.22048/jsat.2016.39250](https://doi.org/10.22048/jsat.2016.39250).
48. Saha, A., Babu, N. R., Dash, P., Acharya, B., Bhaskar, M. S., & Khan, B. (2023). Dynamic stability assessment of interconnected thermal- SsGT- solar photovoltaic- EV power system with ARO optimized IDN- FOID amalgamated controller. *IET Renewable Power Generation*. doi: [10.1049/rpg2.12771](https://doi.org/10.1049/rpg2.12771).
49. Sanikhani, H., Kisi, O., Maroufpoor, E., & Yaseen, Z. M. (2019). Temperature-based modeling of reference evapotranspiration using several artificial intelligence models: application of different modeling scenarios. *Theoretical and Applied Climatology*, 135, 449-462. doi: [10.1007/s00704-018-2390-z](https://doi.org/10.1007/s00704-018-2390-z).
50. Shamshirband, S., Amirmoghaddam, M., Gocić, M., Akib, S., Petković, D., Piri, J., & Trajkovic, S. (2016). Estimation of reference evapotranspiration using neural networks and cuckoo search algorithm. *Journal of Irrigation and Drainage Engineering*, 142(2), 04015044. doi: [10.1061/\(ASCE\)IR.1943-4774.0000949](https://doi.org/10.1061/(ASCE)IR.1943-4774.0000949).
51. Shiri, J. (2018). Improving the performance of the mass transfer-based reference evapotranspiration estimation approaches through a coupled wavelet-random forest methodology. *Journal of Hydrology*, 561, 737-750. doi: [10.1016/j.jhydrol.2018.04.042](https://doi.org/10.1016/j.jhydrol.2018.04.042).
52. Sivasubramani, S., & Swarup, K. S. (2011). Hybrid DE-SQP algorithm for non-convex short term hydrothermal scheduling problem. *Energy Conversion and Management*, 52(1), 757-761. doi: [10.1016/j.enconman.2010.07.056](https://doi.org/10.1016/j.enconman.2010.07.056).
53. Tikhamarine, Y., Malik, A., Pandey, K., Sammen, S. S., Souag-Gamane, D., Heddam, S., & Kisi, O. (2020). Monthly evapotranspiration estimation using optimal climatic parameters: efficacy of hybrid support vector regression integrated with whale optimization algorithm. *Environmental Monitoring and Assessment*, 192, 1-19. doi: [10.1007/s10661-020-08659-7](https://doi.org/10.1007/s10661-020-08659-7).
54. Tosan, M., Khashei-Siuki, A., Maroosi, A., & Gharib, M. R. (2023). Review of Smart Water Management for Sustainable Agriculture Based on the Internet of Things. *Water Management in Agriculture*.
55. 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. doi: [10.22048/jsat.2014.9605](https://doi.org/10.22048/jsat.2014.9605).
56. Traore, S., Luo, Y., & Fipps, G. (2016). Deployment of artificial neural network for short-term forecasting of evapotranspiration using public weather forecast restricted messages. *Agricultural Water Management*, 163, 363-379. doi: [10.1016/j.agwat.2015.10.009](https://doi.org/10.1016/j.agwat.2015.10.009).
57. Traore, S., Wang, Y.-M., & Kerh, T. (2010). Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. *Agricultural Water Management*, 97(5), 707-714. doi: [10.1016/j.agwat.2010.01.002](https://doi.org/10.1016/j.agwat.2010.01.002).
58. Walls, S., Binns, A. D., Levison, J., & MacRitchie, S. (2020). Prediction of actual evapotranspiration by artificial neural network models using data from a Bowen ratio energy balance station. *Neural Computing and Applications*, 32, 14001-14018. doi: [10.1007/s00521-020-04800-2](https://doi.org/10.1007/s00521-020-04800-2).
59. Wang, L., Cao, Q., Zhang, Z., Mirjalili, S., & Zhao, W. (2022). Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems. *Engineering Applications of Artificial Intelligence*, 114, 105082. doi: [10.1016/j.engappai.2022.105082](https://doi.org/10.1016/j.engappai.2022.105082).
60. Wang, S., Lian, J., Peng, Y., Hu, B., & Chen, H. (2019). Generalized reference evapotranspiration models with limited climatic data based on random forest and gene expression programming in Guangxi, China. *Agricultural Water Management*, 221, 220-230. doi: [10.1016/j.agwat.2019.03.027](https://doi.org/10.1016/j.agwat.2019.03.027).
61. Wen, X., Si, J., He, Z., Wu, J., Shao, H., & Yu, H. (2015). Support-vector-machine-based models for modeling daily reference evapotranspiration with limited climatic data in extreme arid regions. *Water Resources Management*, 29, 3195-3209. doi: [10.1007/s11269-015-0990-2](https://doi.org/10.1007/s11269-015-0990-2).
62. Wu, L., Huang, G., Fan, J., Ma, X., Zhou, H., & Zeng, W. (2020). Hybrid extreme learning machine with meta-heuristic algorithms for monthly pan evaporation prediction. *Computers and Electronics in Agriculture*, 168, 105115. doi: [10.1016/j.compag.2019.105115](https://doi.org/10.1016/j.compag.2019.105115).
63. Xiong, Y., Chen, X., Tang, L., & Wang, H. (2022). Comparison of surface renewal and Bowen ratio derived evapotranspiration measurements in an arid vineyard. *Journal of Hydrology*, 613, 128474. doi: [10.1016/j.jhydrol.2022.128474](https://doi.org/10.1016/j.jhydrol.2022.128474).
64. Naeini, S. Y., Mianroudi, S. M., & Tosan, M. (2017). A survey on saffron status of Khorasan Razavi and South Khorasan provinces in Iran. *Acta Horticulturae*, (1184), 25-30. doi: [10.17660/actahortic.2017.1184.4](https://doi.org/10.17660/actahortic.2017.1184.4).
65. Yaqubi, M., Yaghoobzadeh, M., & Tosan, M. (2024). Factor analysis and ranking of saffron production, processing and market challenges in Torbat Heydarieh, Iran. *Saffron Agronomy and Technology*. [In Persian]
66. Ye, L., Zahra, M. M. A., Al-Bedyry, N. K., & Yaseen, Z. M. (2022). Daily scale evapotranspiration prediction over the coastal region of southwest Bangladesh: new development of artificial intelligence model. *Stochastic Environmental Research and Risk Assessment*, 1-21. doi: [10.1007/s00477-021-02055-4](https://doi.org/10.1007/s00477-021-02055-4).
67. Yurtseven, I., & Serengil, Y. (2021). Comparison of different empirical methods and data-driven models for estimating reference evapotranspiration in semi-arid Central Anatolian Region of Turkey. *Arabian Journal of Geosciences*, 14, 1-28. doi: [10.1007/s12517-021-08150-8](https://doi.org/10.1007/s12517-021-08150-8).