



## 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 Khozeymehnezhad<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

#### Article type:

Research Paper

#### Article history

Received: 31 December 2023

Revised: 01 February 2024

Accepted: 04 February 2024

Published online: 06 June 2024

#### Keywords:

Reference evapotranspiration, neural network, artificial rabbit optimizer, precision agriculture.

### ABSTRACT

Reference evapotranspiration (ET<sub>0</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>0</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>0</sub> simulation. According to the results, the ANN-ARO model is highly recommended for estimating ET<sub>0</sub> in similar climate regions with limited climate data. This study proposes powerful models for accurate estimation of ET<sub>0</sub> with limited inputs in arid and semi-arid climates, which provide practical implications for the development of precision agriculture.

Citation: Tosan, M., Maroosi, A., & Khozeymehnezhad, H. (2024). Investigating the performance of a hybrid algorithm based on artificial rabbits optimization (ANN-ARO) in forecasting reference evapotranspiration with limited climatic parameters. *Iranian Journal of Rainwater Catchment Systems*, 12(1), 47-66.

DOR: 10.1001.1.24235970.1403.12.1.3.6

Publisher: Iranian Rainwater Catchment Systems Association

© Author(s)



\*Corresponding author: Hossein Khozeymehnezhad

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 Khozeymehnezhad<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.maroozi@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>0</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>0</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>0</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>0</sub> estimation points to the efficiency of IOA methods around the world. Although there is great potential in the field of ET<sub>0</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>0</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>0</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>0</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 Khozeymehnezhad

**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 ET<sub>0</sub> 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 ET<sub>0</sub>, 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 ET<sub>0</sub>, 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 ET<sub>0</sub> estimation in the investigated climates, while other parameters such as relative humidity, net radiation, and wind speed at inputs have less effect on ET<sub>0</sub> estimation. The ANN-ARO can be used to accurately estimate ET<sub>0</sub> rates based on minimal meteorological parameters, in different climates, especially in areas with scarce water. The prediction of ET<sub>0</sub> 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 Khozeymehnezhad 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 ماروosi<sup>۲</sup>، حسین خزیمه‌نژاد<sup>\*</sup>

۱. دانشجوی دکتری، گروه مهندسی منابع آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. [moein.tosan@birjand.ac.ir](mailto: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](mailto:ali.maroosi@torbath.ac.ir)
۳. دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند، بیرجند، ایران. [hkhoezeymeh@birjand.ac.ir](mailto:hkhoezeymeh@birjand.ac.ir)

مشخصات مقاله	چکیده
<p><b>نوع مقاله:</b> پژوهشی</p> <p><b>تاریخچه مقاله</b></p> <p><b>دریافت:</b> ۱۰ دی ۱۴۰۲</p> <p><b>بازنگری:</b> ۱۲ بهمن ۱۴۰۲</p> <p><b>پذیرش:</b> ۱۵ بهمن ۱۴۰۲</p> <p><b>انتشار برخط:</b> ۱۷ خرداد ۱۴۰۳</p> <p><b>واژه‌های کلیدی:</b> تبخیر و تعرق مرجع، شبکه عصبی، بهینه‌سازی 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 مدل سازی 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 (GA) و پنج مدل داده‌کاوی دیگر می‌پردازد. این مدل‌ها با استفاده داده‌های آبوهادی روزانه بلندمدت از سال ۲۰۰۰ تا ۲۰۲۳ در دو اقلیم متفاوت ارزیابی شدن. ایستگاه‌های مورد بررسی شامل بیرجند (با اقلیم خشک کویری) و مشهد (با اقلیم نیمه‌خشک سرد) بود. مقایسه آماری نشان داد که با درنظرگرفتن کلیه پارامترهای اقلیمی مدل هیبریدی ANN-ARO در شهر مشهد با <math>R^2=0.9986</math> و <math>MSE=0.0001</math> در شهر بیرجند با <math>R^2=0.9982</math> و <math>MSE=0.0001</math> تخمین‌های بهتری را نسبت به سایر روش‌ها داشت. همچنین الگوریتم بهینه‌سازی ANN-ARO با درنظرگرفتن حداقل پارامتر هواشناسی، بهترین "روطیت نسبی" بهترین تخمین را داشته و همچنین با درنظرگرفتن دو و سه پارامتر ورودی، عملکرد بهتری نسبت به سایر روش‌ها دارد. بطورکلی، الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت ابزارهای قوی برای افزایش عملکرد ANN در شبیه‌سازی ET<sub>0</sub> 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<sub>0</sub> با ورودی‌های محدود در اقلیم‌های خشک و نیمه‌خشک پیشنهاد می‌کند که مفاهیمی عملی برای توسعه کشاورزی دقیق ارائه می‌دهد.</p> <p>استناد: توسن، معین، ماروosi، 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. سامانه‌های سطوح آبگیر باران، ۱۱، (۳)، ۴۷-۶۶.</p> <p><b>DOR:</b> 20.1001.1.24235970.1403.12.1.3.6</p> <p>ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران</p>



© نویسنده‌گان

\* نویسنده مسئول: حسین خزیمه‌نژاد

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

تلفن: ۰۹۱۵۱۶۳۹۸۴۳

پست الکترونیکی: [Hkhozeymeh@birjand.ac.ir](mailto:Hkhozeymeh@birjand.ac.ir)

## مقدمه

تبخیر و تعرق (ET) به عنوان ترکیبی از تعرق از گیاه و تبخیر از سطوح غیر روزنایی، یک اصطلاح مهم در چرخه هیدرولوژیکی است (Adnan et al., 2021). تبخیر و تعرق نقش مهمی در مدیریت منابع آب، از جمله برنامه‌ریزی کشاورزی و مدل‌سازی فرآیندهای هیدرولوژیکی ایفا می‌کند (Yaqubi et al., 2024; Kim et al., 2023). روش‌های اندازه‌گیری متعددی از جمله لایسیمترها (Dong & Hansen, 2023)، کوواریانس گردابی نصب شده بر روی برج‌های شار (Jiang et al., 2020) و روش‌های تعادل انرژی نسبت بون (Xiong et al., 2022) وجود دارد که برای تعیین تبخیر و تعرق استفاده می‌شوند؛ با این حال، اجرای این تکنیک‌ها برای یک مکان خاص، گران قیمت بوده و نیاز به کالیبراسیون مدام دارند. بنابراین، این رویکردها در بسیاری از مناطق قبل اجرا نیستند (Dong et al., 2021). در سال‌های اخیر، مدل‌های مختلفی برای تخمین تبخیر و تعرق مرجع (ET<sub>0</sub>) - که به تبخیر و تعرق یک محصول مرجع در شرایط آبیاری ایده‌آل اشاره دارد - ایجاد شده است (Başakın et al., 2023). سازمان غذا و کشاورزی (FAO) معادله پنمن-مونتیث را برای مدل‌سازی تبخیر و تعرق معرفی کرد. رویکردی که به روشی رایج برای محاسبه ET در سراسر جهان تبدیل شده است (Allen et al., 2006). چندین ورودی آب و هوایی مانند دمای حداقل، حداقل و متوسط، سرعت باد، میانگین رطوبت نسبی و مدت زمان تابش آفتاب برای تخمین ET<sub>0</sub> توسط معادله فاؤن-پنمن-مونتیث مورد نیاز است. این تعداد زیاد داده‌های آب و هوایی همیشه در دسترس یا قابل اعتماد نیستند. از طرفی تأثیر متغیرهای اقلیمی ذکر شده بر ET آن را به ماهیت پیچیده‌ای تبدیل می‌کند (Hernandez et al., 2012)، لذا پیش‌بینی ET یکی از دشوارترین امور در مسائل منابع آب است. در چنین شرایطی، روش‌های محاسبات نرم (SC) که می‌توانند رفتار پیچیده بین ورودی و خروجی را با دقت مدل‌سازی کنند، به عنوان جایگزینی مناسب‌تر ظاهر می‌شوند. در سال‌های اخیر، روش‌های شبکه عصبی مصنوعی برای مدل‌سازی سیستم‌های پیچیده در زمینه هیدرولوژی استفاده شده‌اند (Adnan et al., 2020; Majhi et al., 2020; Adnan, Liang, Trajkovic, et al., 2019; Adnan, Liang, Yuan, et al., 2019; Wu et al., 2018).

(Muhammad Adnan et al., 2019).

رونقهای اخیر در تکنیک‌های هوش مصنوعی باعث پیشرفت مطالعات در بسیاری از زمینه‌ها شده است (Yasrebi & Tosan et al., 2023; Chia et al., 2017; Naeini et al., 2017; Feng et al., 2020; Ferreira et al., 2019; Chia et al., 2021; Feng et al., 2019). در سال‌های اخیر، بسیاری از مطالعات با موفقیت تکنیک‌های هوش مصنوعی، یعنی مدل‌های یادگیری ماشین (ML) را برای مدل‌سازی ET<sub>0</sub> پیاده‌سازی کرده‌اند. Kumar و همکاران (۲۰۱۱) ابتدا پتانسیل مدل ANN را بر روی محاسبات روزانه ET<sub>0</sub> مورد مطالعه قرار دادند. Traore و همکاران (۲۰۱۰) به منظور محاسبه ET<sub>0</sub> در بورکینافاسو نسبت به توسعه یک مدل ANN و مقایسه آن با مدل تجربی هارگریوز پرداختند. آن‌ها دریافتند که مدل ANN مبتنی بر دما از مدل هارگریوز بهتر عمل می‌کند و سرعت باد مؤثرترین متغیر آب و هوایی برای مدل‌سازی ET<sub>0</sub> است. Traore و همکاران (۲۰۱۰) از مدل‌های ANN برای محاسبه ET<sub>0</sub> با داده‌های آب و هوایی مختلف به عنوان ورودی استفاده و مدل‌های ANN را با ده مدل تجربی و نیمه تجربی در اسپانیا مقایسه نمودند. آن‌ها به این نتیجه رسیدند که مدل‌های ANN مبتنی بر دما، رطوبت نسبی و تشبع تخمین‌های بهتری را در مقایسه با مدل‌های تجربی و نیمه تجربی ارائه کردند. Traore و همکاران (۲۰۱۶) از مدل ANN برای پیش‌بینی اطلاعات ET<sub>0</sub> در آینده نزدیک با استفاده از داده‌های پیش‌بینی آب و هوایی عمومی برای برنامه‌ریزی آبیاری با عملکرد دقیق استفاده کردند. Reis و همکاران (۲۰۱۹) به مقایسه دو مدل شبکه عصبی و ماشین یادگیری با مدل‌های هارگریوز-سامانی و رگرسیون خطی چندگانه برای تخمین ET<sub>0</sub> فقط با داده‌های دما در برزیل پرداختند. آن‌ها نشان دادند که مدل ANN آموزش‌دیده محلی نتایج قابل اعتمادتری نسبت به بقیه ارائه می‌دهد.

طبق مرور منابع، مدل‌های ترکیبی شبکه عصبی با موفقیت برای پیش‌بینی تبخیر و تعرق مورد استفاده قرار گرفتند (Ladlani et al., 2012; Kisi, 2015; Wen et al., 2015; Luo et al., 2019; Abrishami et al., 2020; Walls et al., 2020). برای نمونه، Ladlani و همکاران (۲۰۱۲) دو مدل ANN، یعنی روش شبکه عصبی مصنوعی رگرسیون تعمیم‌یافته (GR-ANN) و شبکه عصبی مصنوعی مبتنی بر شعاعی (RB-ANN) را برای مدل‌سازی ET با استفاده از پارامترهای آب و هوایی از دارالبیاد، الجزایر مقایسه کردند. به عنوان داده‌های اقلیمی، آن‌ها از داده‌های مدت تابش آفتاب، میانگین رطوبت نسبی، میانگین سرعت باد، حداقل، حداقل و میانگین دمای هوا استفاده کردند. آن‌ها دریافتند که GR-ANN بهتر از RB-ANN در پیش‌بینی تبخیر و تعرق عمل می‌کند. Wen و همکاران (۲۰۱۵) دقت پیش‌بینی ANN و روش‌های تجربی را در مقایسه با روش یادگیری ماشین، یعنی ماشین بردار پشتیبان (SVM) بررسی کرد. مدل‌های انتخاب شده برای پیش‌بینی ET منطقه خشک خوبه اجینا چین، با استفاده از حداقل دما و حداقل دما به عنوان ورودی استفاده شد. Luo و

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 به طور مؤثر به عنوان یک ابزار مدل‌سازی ET قابل اعتماد استفاده شوند. Abrishami و همکاران (۲۰۱۹) از مدل‌های ANN برای پیش‌بینی ET نهر نیسوری در شهرستان آسفورد، کانادا استفاده کرد. آن‌ها از دو نوع تابع فعال‌سازی از جمله واحد خطی اصلاح شده (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) برای پیش‌بینی ET در صربستان ترکیب و با SVM، WT-SVM و ANN مقایسه نمودند. آن‌ها دریافتند که مدل‌های FFA و SVM-FFA نتایج پیش‌بینی بهتری را در مقایسه با روش‌های محاسباتی مستقل ANN و Shamshirband و همکاران (۲۰۱۶) از یک روش اکتشافی جدید به نام الگوریتم جستجوی فاخته (CSA) برای بهینه‌سازی روش‌های ANN و ANFIS در تخمین ET در ۱۲ ایستگاه اقلیمی در صربستان استفاده کرد. نتایج پیش‌بینی روش‌های ترکیبی طراحی شده (ANFIS-CSA و ANN-CSA) با مدل‌های مستقل ANN و مدل‌های تجربی هارگریوز و پریستلی-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 به کار برdenد. 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 تعیین کمیت ET روزانه در مناطق مرطوب جنوب غربی چین مقایسه کردند، نتایج نشان داد مدل شبکه عصبی رگرسیون تعیین کمیت ET با استفاده از جنگل تصادفی ارائه می‌دهد. Fan و همکاران (۲۰۱۹) عملکرد دستگاه تقویت گرادیان 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 (طبی، هارگریوز-سامانی، تراابت و مکینک) مقایسه کرد. آن‌ها عملکرد بهتری از دستگاه تقویت گرادیان نور نسبت به مدل‌های دیگر پیدا کردند. Araghi و همکاران (۲۰۲۰) هم‌چنین مزایای WT (تبدیل موجک) همراه با مدل‌های WT-MLR، WT-ANN، WT-ANFIS و WT-ANFIS مبتنی بر موجک (WT-MLR و WT-ANN) را برای پیش‌بینی ET سه ایستگاه آب و هوایی انتخاب شده از سه اقلیم مختلف در ایران نشان دادند. با استفاده از داده‌های آب و هوایی روزانه ایستگاه‌های انتخاب شده، آن‌ها دریافتند که WT-ANN از مدل‌های هیبریدی مبتنی بر موجک (WT-MLR و WT-ANFIS) 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) و بهینه‌ساز شیرمورچه (ANN-ALO). نتایج نشان داد الگوریتم ANN-GWO به طور قابل توجهی 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 پژوهش‌هایی 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  $R^2$ Table 2- Hybrid artificial neural network models for predicting reference evapotranspiration considering MSE and  $R^2$ 

منبع	ایستگاه هواشناسی	مدل هیبریدی	MSE	$R^2$	نتیجه
Shamshirband و همکاران (۲۰۱۶)	جنوب شرقی اروپا، صریستان	ANN-CSA	0.108	0.956	مدل ANFIS-CSA در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.
Mehdizadeh و همکاران (۲۰۱۷)	ایران	ANFIS-CSA	0.070	0.969	0.26
Ehteram و همکاران (۲۰۱۹)	پاننگا، هند	SVM-RBF	0.649	0.978	SVMRBF و MARS بهتر از GEP عمل می‌کنند.
Sanikhani و همکاران (۲۰۱۹)	آنتالیا، ترکیه	SVM-poly	0.13	0.978	GEP بهتر از SVM-CA عملکرد داشت.
Alizamir و همکاران (۲۰۲۰)	آنتالیا، ترکیه	ANFIS-GP	0.33	0.903	ANFIS-GP، RBNN، GRNN، GEP بهترین و سپس عملکرد را داشتند.
Majhi and Naidu (۲۰۲۱)	امبیکاپور، هند	ANFIS-SC	0.244	0.901	ANFIS-PSO در شرایط پارامتر ورودی محدود عملکرد بهتر بود.
Adnan و همکاران (۲۰۲۱)	داکا، بنگلادش	ANFIS-PSO	0.06	0.986	RBFN-DE در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.
Gong و همکاران (۲۰۲۱)	چین	RBFN-DE	0.43	0.995	GA-ELM عملکرد بهتری داشت.
Yurtseven and Serengil (۲۰۲۱)	آناتولی، ترکیه	RBFN-PSO	1.16	0.986	-
Adnan و همکاران (۲۰۲۱)	جنوب بنگلادش	ANFIS-MFO	0.058	0.946	-
Kang و همکاران (۲۰۲۲)	هیلونگ‌جیانگ، چین	ANFIS-WCA	0.063	0.939	ANFIS-WCA-MFO بهترین عملکرد را داشت.
Cui و همکاران (۲۰۲۲)	شمال غربی بنگلادش	ANFIS-WCA-MFO	0.048	0.950	-
Ye و همکاران (۲۰۲۲)	جنوب غربی بنگلادش	VMD-SVM	0.960	0.81	ANFIS-WCA-MFO بهتر از بقیه مدل‌ها عمل کرد.
		BC-SVM	0.810	0.85	VMDBC-SVM بهتر از ANFIS-PSO بود.
		VMD-BC-SVM	0.449	0.76	-
		ANFIS-IA-GWO	0.004	0.99	مدل هیبریدی پیشنهادی بهتر از ANFIS-PSO بود.
		DENFIS-WOA	0.185	0.9	مدل هیبریدی پیشنهادی در شرایط پارامتر ورودی محدود عملکرد مناسب‌تری داشت.

هرچند زمانی که تعداد معادلی از پارامترهای ورودی در هر مکان معین موجود باشد، عملکرد مدل‌های هوش مصنوعی با معادله فائق پنمن مونتیث (فائق ۵۶) برابری می‌کند، اما باید درنظر داشت که حتی با در دسترس بودن تمام پارامترهای آب و هوا، استفاده از فائق پنمن مونتیث 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 تقدیم 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.

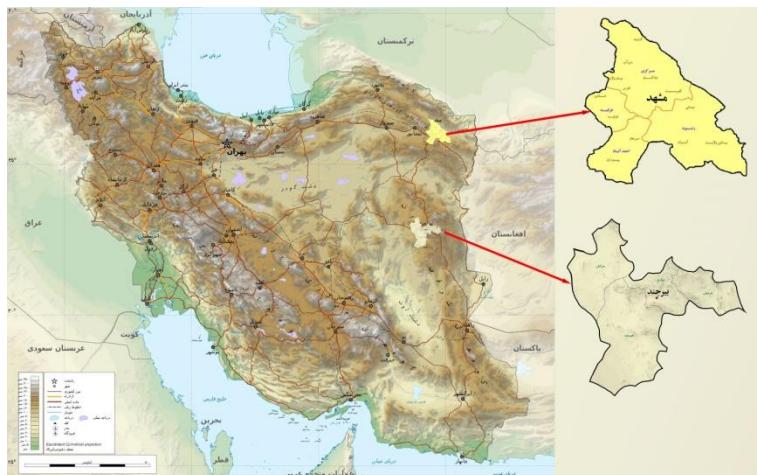
## مواد و روش تحقیق منطقه مورد مطالعه

شهر مشهد مرکز استان خراسان رضوی، در محدوده ۵۹ درجه و ۱۵ دقیقه عرض جغرافیایی واقع شده است (Tosan et al., 2015). این شهر با ۳۵۱ کیلومترمربع 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 (Bاقریفام و همکاران، ۱۴۰۱؛ Feizi et al., 2016). شهرستان بیرون‌جند 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 بیرون‌جند به ترتیب ۸ و ۲۴ درجه سانتی‌گراد، بارش سالانه ۱۲۰ میلی‌متر و میانگین تبخیر و تعرق پتانسیل ۲۷۰۰ میلی‌متر است. بر اساس شاخص‌های اقلیم دواماتن و اروانف، شهر بیرون‌جند دارای اقلیم خشک-کویری است (Ramezani Moghadam et al., 2018). داده‌های هواشناسی موردنیاز شامل دما (حداقل، حداکثر و میانگین)، سرعت باد، بارش ساعتی، میانگین رطوبت نسبی، ساعت آفتابی، تابش خالص دریافتی، فشار میانگین سطح ایستگاه و میانگین فشار بخار به صورت روزانه و در بازه زمانی ۲۰۲۳ الی ۲۰۰۰ 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	سطح ایستگاه	فشار ایستگاه	میانگین ساعته	بارش میانگین	۲۴ ساعته	میانگین رطوبت نسبی	تعداد ساعت	آفتابی	مشهد
	میانگین	حداکثر										بیرون‌جند
	22.9	9.77	2.75	903	7.76	0.60	47.61	8.26				
	16.09	10.51	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

فائق روش فائق پمن 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:

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

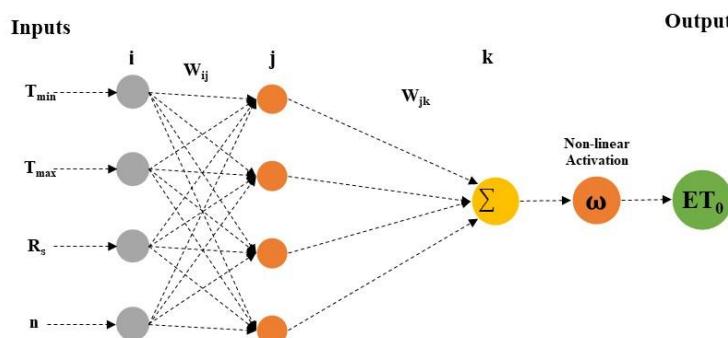
که در آن  $ET_0$  تبخیر و تعرق مرجع ( $\text{mm day}^{-1}$ ),  $e_s$  فشار بخار اشباع (kPa),  $e_a$  فشار بخار واقعی (kPa),  $\Delta$  شبیب منحنی فشار بخار اشباع ( $\text{kPa}^{\circ}\text{C}^{-1}$ ),  $R_n$  تابش خورشیدی روزانه رسیده به سطح گیاه ( $\text{MJ m}^{-2} \text{day}^{-1}$ ),  $G$  شار گرما به داخل خاک ( $\text{MJ m}^{-2} \text{day}^{-1}$ ),  $\gamma$  ثابت سایکرومتری ( $\text{kPa}^{\circ}\text{C}^{-1}$ ),  $U_2$  سرعت باد در ارتفاع دومتری ( $\text{m s}^{-1}$ ),  $T$  میانگین دمای هوای ( $^{\circ}\text{C}$ ) 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 فوق العاده بهم 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 انبیو 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, ..., C7) وارد مدل شدند. پیش‌بینی تبخیر و تعرق مرجع با به کارگیری پارامتر روز از سال (n) به عنوان 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 محاسبه شده در ایستگاه‌های مورد مطالعه به روش فائو-پنمون-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 حیات وحش 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 پنهان‌شدن، یا به طور مشابه دور از لانه خود برای تهیه وعده‌های غذایی خود اقدام می‌کنند و یا به صورت دلخواه به انتخاب پناهگاه می‌پردازند. ARO

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

(۱) جستجوی انحرافی (اکتشاف): از آن‌جاکه خرگوش‌ها دور از پناهگاه خود به دنبال غذا می‌گردند. بنابراین در ARO در نظر گرفته می‌شود که هر یک از خرگوش‌ها لانه مخصوص به خود را به همراه 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):

$$\begin{cases} v_i(t+1) = x_j(t) + R_0(x_i(t) - x_j(t)) + Y \\ Y = \text{round}(0.5 \cdot (0.05 + r_1))n_1 \\ i, j = 1, \dots, n \text{ and } i \neq j \end{cases} \quad (۲)$$

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  $t$ ،  $n$  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.

$$R = L \cdot c \quad (۳)$$

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

$$L = \left( e - e^{\left(\frac{t-1}{T}\right)^2} \right) \cdot \sin(2\pi r_2) \quad (۴)$$

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

$$c(k) = \begin{cases} 1 & \text{if } k = g(l) \\ 0 & \text{else} \\ \text{where } k = 1, \dots, d \\ \text{and } l = 1, \dots, [r_3 \cdot g] \end{cases} \quad (۵)$$

به طوری که در آن  $d$  بعد مسئله و  $r_3$  عددی تصادفی بین  $0$  و  $1$  است.

$$g = \text{randperm}(d) \quad (۶)$$

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 دائمًا در امتداد ابعاد فردی منطقه شکار، مخفیگاه‌هایی را در اطراف خود ایجاد کرده و به طور مستمر و به صورت 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 به صورت زیر ایجاد می‌شود:

$$b_{i,j}(t) = x_i(t) + H \cdot g \cdot x_i(t) \quad (۷)$$

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

$$H = \frac{T - t + 1}{T} \cdot r_4 \quad (۸)$$

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

$$n_2: N(0, 1) \quad (۹)$$

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

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

$$v_i(t+1) = x_i(t) + R \cdot (r_4 \cdot b_{i,r}(t) - x_i(t)) \quad (۱۰)$$

جایی که  $i = 1, \dots, n$  به طور تصادفی به عنوان 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 به روزرسانی می‌شود:

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

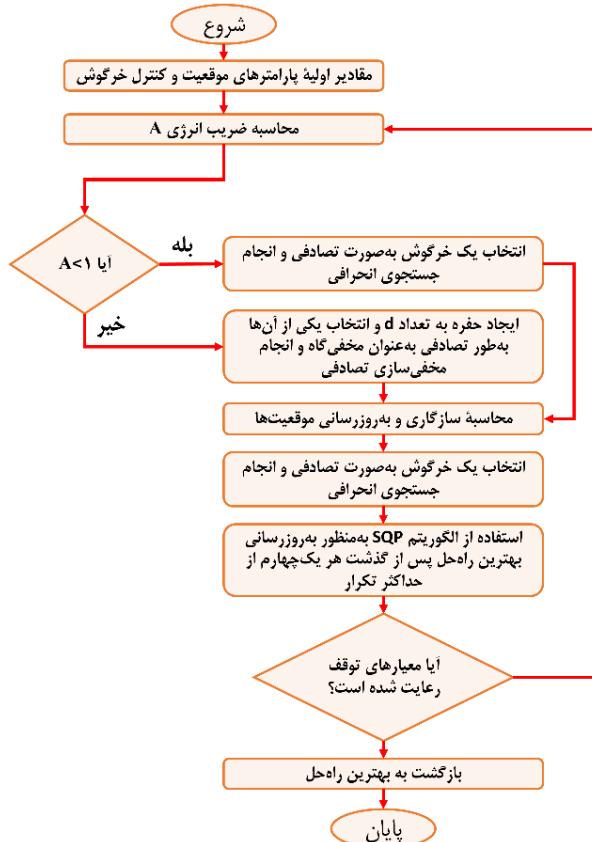
(۳) انقباض انرژی (تعییر از اکتشاف به بهره‌برداری): خرگوش‌ها قابلیت اکتشاف در مرحله اول و بدنبال آن بهره‌برداری در فاز بعدی را دارند. این تفاوت در جستجو بدلیل از دست دادن انرژی در خرگوش‌ها در زمان مناسب است. این ماده انرژی با عبارت زیر طراحی شده است (Saha et al., 2023):

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

### 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 راه حل‌های موفقیت‌آمیز در تعداد زیادی از مسائل آزمایشی بهتر عمل می‌کند (Bedekar & Bhide, 2010). این روش شباهت زیادی به روش نیوتن برای بهینه‌سازی محدود دارد که در هر تکرار، تقریبی از ماتریس هسین تابع لاغرانژی با استفاده از روش بهروزرسانی شبه نیوتن بروdon-فلچر-گلدفارب-شانو (BFGS) ساخته می‌شود. سپس از نتیجه تقریب برای ایجاد یک زیرمسئله برنامه‌نویسی درجه دوم (QP) استفاده می‌شود که راه حل آن برای تشکیل یک جهت جستجو برای رویه جستجوی خطی استفاده می‌شود. از آنجایی که OF موردنظر که باید به حداقل برسد غیر محدب است، لذا SQP حداقل محلی را برای یک راه حل اولیه تضمین می‌کند. هر تکرار در الگوریتم SQP شامل سه مرحله اصلی است (Bedekar & Bhide, 2010) (الف) حل مسئله فرعی QP و به دست آوردن جهت جستجو، (ب) جستجوی خط و محاسبه تابع شایستگی، (پ) بهروزرسانی ماتریس هسین تابع لاغرانژ، با استفاده از فرمول BFGS.

برای استفاده از مزیت روش‌های ARO و SQP و در عین حال برای رفع معایب این روش‌ها، یک ARO 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 LS اجرا می‌شود و بهترین تناسب به دست آمده از GSA را در تکرار فعلی بهبود می‌بخشد. به این ترتیب، الگوریتم ترکیبی ARO-SQP جریان ARO در شکل (۳) است.



شکل ۳- فلوچارت 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

بهمنظور ارزیابی مدل هیبریدی پیشنهادی، از شاخص‌های آماری مختلفی می‌توان استفاده کرد. شاخص‌های آماری مورداستفاده در این تحقیق شامل روش‌های میانگین مربع خطأ (MSE) و مجذور ضریب همبستگی ( $R^2$ ) بود که بر اساس رابطه‌های زیر محاسبه می‌شوند:

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

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

در این روابط،  $O_i$  تبخیر و تعرق به روش پنمن مونتیث فاؤ و  $P_i$  تبخیر و تعرق محاسبه شده به هر روش و  $N$  تعداد داده‌ها هستند. سه بهینه‌ساز فرالبتکاری، 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 به عنوان افراد بهینه‌ساز در نظر گرفته می‌شوند که با به حداقل رساندن یکتابع هزینه با استفاده از بهینه‌سازهای مختلف تعیین می‌شوند.

همچنین جهت ارزیابی کارآیی 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 تعریق 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 فائق پمنم مونتیث به عنوان 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 بهره‌ریختگی 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) 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 شد (Jain et al., 2008) و پس از بررسی توابع انتقال مختلف، برای لایه‌های پنهانتابع انتقال لوگ سیگموید و برای لایه خروجی، تابع انتقال خطی در نظر گرفته شد. برای آپدیت وزن‌ها در شبکه عصبی از الگوریتم لونبرگ-مارکوارت استفاده شد. چندین تکرار برای هر مدل انجام شد و معیارهای ارزیابی محاسبه شده برای هر دو ایستگاه بیرونی و مشهد، به ترتیب در جدول‌های (۳) و (۴) نشان داده شده است. شکل (۴) نیز میزان میانگین مربعات خطأ برای داده‌های تبخیر و تعریق مرجع پیش‌بینی شده (خروجی) نسبت به تبخیر و تعریق واقعی می‌باشد که نشان‌دهنده برتری مدل ANN-ARO نسبت به سایر مدل‌های هیبریدی است.

<sup>۱</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										متغیرهای ورودی	ترکیب
ANN-ARO	ANN-PSO	ANN-GA	KNN	RFs	ANN	IR	PQ	LR	ارزیابی مدل		
0.0015	0.0025	0.0027	0.0030	0.0010	0.0014	0.0045	0.0026	0.0049	MSE	$T_{\max}, n$	C1
0.9749	0.9578	0.9541	0.9499	0.9425	0.9749	0.9226	0.9558	0.0918	$R^2$		
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	$R^2$		
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	$R^2$		
0.0060	0.0057	0.0064	0.0008	0.0040	0.0049	0.0429	0.0096	0.0445	MSE	$R_s, n$	C4
0.9171	0.8900	0.8149	0.8027	0.8054	0.8964	0.6724	0.8055	0.4135	$R^2$		
0.0001	0.0030	0.0028	0.0018	0.0030	0.0001	0.0071	0.0024	0.0072	MSE	$T_{\min}, T_{\max}, R_s, n$	C5
0.9980	0.9493	0.9527	0.9691	0.9492	0.9980	0.8802	0.9600	0.8778	$R^2$		
0.0001	0.0037	0.0035	0.0033	0.0045	0.0001	0.0054	0.0023	0.0076	MSE	$T_{\min}, T_{\max}, WS, RH, R_s, n$	C6
0.9978	0.9376	0.9422	0.9448	0.9256	0.9969	0.902	0.9616	0.8721	$R^2$		
0.0001	0.0033	0.0026	0.0031	0.0043	0.0001	0.0011	0.0011	0.0027	MSE	$T_{\min}, T_{\max}, AT, AP, VP, RF, RH, SS, R_s, n$	C7
0.9996	0.9439	0.9554	0.9480	0.9269	0.9995	0.9817	0.9812	0.9548	$R^2$		

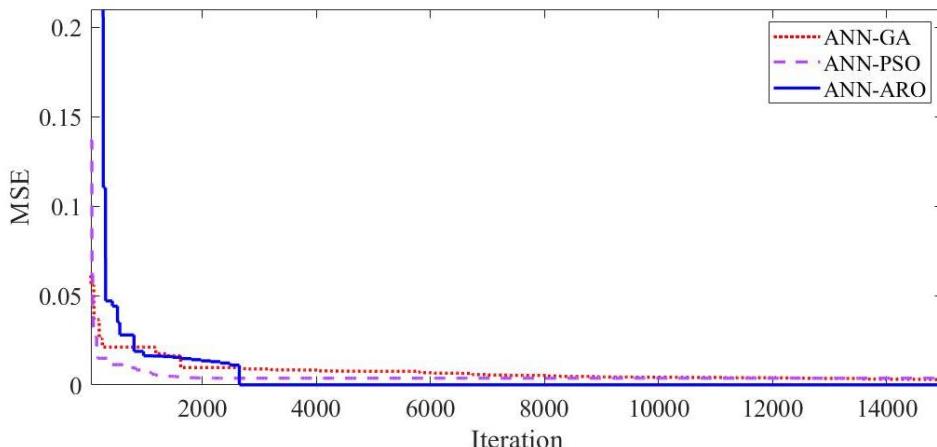
T: دمای حداقل،  $T_{\max}$ : دمای حداکثر، AT: دمای میانگین، AP: فشار میانگین ایستگاه، VP: میانگین فشار بخار، RF: بارش ۲۴ ساعته، RH: میانگین رطوبت نسبی، SS: ساعت آفتابی، SR: میزان تابش کلی ۲۴ ساعته و n: روز از سال.

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										متغیرهای ورودی	ترکیب
ANN-ARO	ANN-PSO	ANN-GA	KNN	RFs	ANN	IR	PQ	LR	ارزیابی مدل		
0.0011	0.0022	0.0023	0.0023	0.0032	0.0012	0.0051	0.0024	0.0054	MSE	$T_{max}, n$	C1
0.9815	0.9623	0.9607	0.9613	0.9461	0.9805	0.9144	0.9600	0.9104	$R^2$		
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	$R^2$		
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	$R^2$		
0.0075	0.0075	0.0083	0.0123	0.0135	0.0071	0.0421	0.0130	0.0401	MSE	$R_s, n$	C4
0.8998	0.8761	0.8619	0.7947	0.7750	0.8813	0.2965	0.7836	0.3299	$R^2$		
0.0001	0.0032	0.0031	0.0015	0.0033	0.0001	0.0025	0.0020	0.0051	MSE	$T_{min}, T_{max}, RS, n$	C5
0.9983	0.9465	0.9479	0.9754	0.9447	0.9982	0.9587	0.9660	0.9144	$R^2$		
0.0001	0.0039	0.0027	0.0028	0.0047	93.3615	0.0022	0.0021	0.0051	MSE	$T_{min}, T_{max}, WS, RH, RS, n$	C6
0.9985	0.9348	0.9548	0.9536	0.9221	0.9980	0.9629	0.9657	0.9143	$R^2$		
0.0001	0.0034	0.0027	0.0031	0.0044	0.0001	0.0010	0.0012	0.0033	MSE	$T_{min}, T_{max}, AT, AP, VP, RF, RH, SS, RS, n$	C7
0.9986	0.9440	0.9555	0.9480	0.9270	0.9993	0.9827	0.9788	0.9441	$R^2$		

: دمای حداقل،  $T_{min}$ : دمای حداکثر، AT: دمای میانگین، AP: دمای میانگین ایستگاه، VP: فشار میانگین ایستگاه، RF: میانگین فشار بخار، RH: بارش ۲۴ ساعته، RS: میانگین رطوبت نسبی، SS: ساعت آفتابی، SR: میزان تابش کلی ۲۴ ساعته و n: روز از سال.



شکل ۴- میانگین مربعات خطای 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 به دست آمد. ترکیبات ورودی چهار مدل اول به ترتیب دما (حداکثر)، رطوبت نسبی، سرعت باد و تابش خالص به همراه روز از سال را با توجه به سطوح همبستگی آن‌ها در هر ایستگاه در نظر گرفتند. ازین‌آین چهار نوع مختلف داده‌های هواشناسی ورودی، به نظر می‌رسد دما بیشترین تأثیر را بر تبخیر و تعرق مرجع در هر دو ایستگاه دارد و به دنبال آن میانگین رطوبت نسبی قرار دارد. بر این اساس، دو ترکیب بعدی از داده‌های ورودی، شامل دما به علاوه 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 C7 هواشناسی به‌طور کلی مقادیر بالاتری از  $R^2$  و مقادیر کمتری از MSE را ایجاد کردند. تمام مدل‌های ANN با داده‌های ورودی FAO56-PM تخمین‌هایی بسیار نزدیک به معادله ANN-ARO حداقل MSE را ارائه کرد و مقدار  $R^2$  برای مدل ANN-ARO تقریباً برابر با یک بود. پس از اضافه شدن دما به عنوان ورودی مدل (C5)، دقت مدل نسبت به زمانی که تنها تشبع خالص (C1) به عنوان ورودی مدل در نظر گرفته شد، بهشت بهبود یافت، از طرفی مقایسه نتایج ترکیب C5 با C1 نشان می‌دهد دقت مدل با اضافه شدن تشبع 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 این حال، با تعداد بیشتر متغیرهای ورودی، قابلیت این مدل‌ها برای تخمین تبخیر و تعرق مرجع، قطعاً بهبود یافته است. با توجه به استفاده از داده‌های هواشناسی محدود و دقت تخمین، بهترین مدل ANN با C1 بود که در آن مقادیر  $R^2$  و MSE با استفاده از پارامتر دما به همراه روز از سال، به ترتیب  $0.9749$  و  $0.0015$  در ایستگاه بیرجند و  $0.9815$  و  $0.0011$  در ایستگاه مشهد بودند. همچنان 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. همچنان در بین سایر روش‌های داده‌کاوی، مدل‌های رگرسیون درجه دوم محض، رگرسیون جنگل تصادفی و رگرسیون نزدیک‌ترین همسایگی، بهترین نتایج را داشتند، به جز 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، درحالی که نتایج این پژوهش نشان می‌دهد در شرایطی که با پارامترهای هواشناسی محدود مواجه‌بیم، مدل‌های هیبریدی ANN-GA و ANN-PSO عملکرد به مرتب ضعیف‌تری نسبت به ANN-ARO دارند.

به‌طور کلی، مدل ANN-ARO مورداستفاده در این مطالعه عملکرد مناسبی را در تخمین تبخیر و تعرق مرجع به خصوص با ورودی داده‌های هواشناسی منفرد (C1-C4) نشان داد، درحالی که 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 ستاریوهایی با داده‌های دما یا رطوبت نسبی را بعنوان حداقل متغیر برای پیش‌بینی تبخیر و تعرق مرجع با استفاده از مدل‌های هوش مصنوعی در نظر گرفته‌اند و به نتایج خوبی دست یافته‌اند. 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 تکروودی بهبود می‌بخشد. نتایج این پژوهش نشان می‌دهد با ترکیب دو پارامتر دما و تشبع خالص، نتایج پیش‌بینی تا حدی بهبود می‌یابد، همان‌طور که Goyal و همکاران (۲۰۲۳) نشان دادند ترکیب دو پارامتر ( $T_n$ ) برای پیش‌بینی تبخیر و تعرق مرجع در مناطق خشک یا نیمه‌خشک به خوبی کار می‌کند. نتایج نشان می‌دهد در ایستگاه مشهد، سرعت باد کمترین پارامتر مرتبط با  $ET_0$  است، درحالی که در ایستگاه بیرون، سرعت باد عملکرد مؤثرتری نسبت به تشبع 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  $ET_0 = n > T_{\max} > RH > u_2 > T_{\min} > R_s$  تأثیر می‌گذارند 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 فائق پنمن مونتیت 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 آب‌وهواهای 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 آب‌وهواهی اندازه‌گیری شده از شهرهای مشهد و بیرون از شرایط پارامترهای هواشناسی محدود پیاده‌سازی شد و نتایج آن با سایر مدل‌های هیبریدی ANN-GA و ANN-PSO و همچنین روش‌های داده کاوی 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 فائق پنمن مونتیت (FAO-56) به عنوان 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 به دست آمده 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 آب‌وهواهای نشان داد که دقت تخمین مدل‌های اعمال شده 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 در حالی که سایر پارامترها از جمله رطوبت نسبی، تشبع 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. علاوه‌بر 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 به کار گرفته شد، رویکرد جدیدی است که در مطالعه اخیر مورد بررسی قرار گرفته است. دلیل احتمالی پشت این موضوع می‌تواند به دلیل 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 نویسنده‌گان:** معین تومن، علی ماروسی و حسین خزیمه‌نژاد: بخش‌های مختلف مقاله توسط نامبرده‌گان انجام و نگاشته شده است.

**تضاد منافع نویسنده‌گان:** نویسنده‌گان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص نگارش و انتشار مطالعه و نتایج این پژوهش ندارند.

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

## منابع

۱. باقریفام، صبا، دلور، 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. *Tحقیقات آب و خاک ایران*, ۱۰(۵۳)، ۱۰-۱۴. doi: 10.22067/JSW.2022.78752.1202.
۲. رمضانی مقدم، جواد، یعقوب‌زاده، مصطفی، جعفرزاده، احمد. (۱۳۹۷). ارزیابی عملکرد روش‌های انتخاب متغیر در ریزمقیاس نمایی بارش روزانه دو اقلیم متفاوت. *آب و خاک*, ۳۲(۴)، ۸۴۷-۸۳۱. doi: 10.22067/JSW.V32I4.72732
۳. تومن، معین، علیزاده، امین، انصاری، حسین، رضوانی مقدم، پرویز. (۱۳۹۴). ارزیابی عملکرد و شناسایی مناطق مستعد کشت زعفران (*Crocus sativus*). *در استان خراسان رضوی بر اساس شاخص‌های دمایی، زراعت و فناوری زعفران*, ۱۲(۱)، ۱-۱۲. doi: 10.22048/jsat.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., Kurraqi, A., & Heddam, 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.knosys.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., & Kurraqi, 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>0</sub> by the FAO56 Penman-Monteith method. *Agricultural Water Management*, 81(1-2), 1-22. doi: 10.1016/j.agwat.2005.03.007.
9. Alsaiari, 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., Motamed, 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., Raghuwanshi, 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. Ladiani, I., Houichi, L., Djemili, L., Heddam, 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., Yaghoubzadeh, 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., Amirmojahedi, 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 conviences 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).