



## Modeling of the evaporation process using the hybrid algorithm of the COOT bird and artificial neural network

Farnaz Alempour Rajabi<sup>1</sup> , Mohammad Ali Ghorbani<sup>2\*</sup> , Esmail Asadi<sup>3</sup> 

<sup>1</sup> M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

<sup>2</sup> Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

<sup>3</sup> Assistant Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

### Abstract

#### Introduction

Due to global warming, accurately estimating evaporation has become a key challenge in water resource management, and due to the important role it plays in the withdrawal of water from human reach, it has always attracted the attention of researchers. Therefore, modeling and awareness of the value of evaporation as one of the hydrological variables is of great importance in agricultural research and soil and water conservation. Gorgan was chosen for the study due to its proximity to the Caspian Sea with a humid climate and a higher rate of evaporation than other cities. On the other hand, Shiraz has a hot and dry climate, is located in central Iran far from water resources such as the sea, and has a lower evaporation rate. Kish also has a warm and humid climate due to its proximity to the sea, with a lower evaporation rate than Shiraz but higher than Gorgan. Several meteorological variables affect the process of evaporation and transpiration, and due to the complexity of the evaporation parameter, a method with high accuracy should be used to determine them. Recently, artificial neural network methods have become very popular among researchers due to their common use and the ease with which they can solve complex problems. Therefore, many intelligent algorithms have been suggested to find the best solution for complex engineering problems, as they can find optimal answers faster and more accurately.

#### Materials and Methods

Artificial neural networks are designed based on inspiration from the memory and learning mechanisms in the human brain. To train artificial neural networks, a set of valid input and output data is used based on the type of problem. The accuracy of the network output depends on the amount of training data and how the inputs and their features are processed. To design different scenarios for adjusting input data, the correlation values of the data with evaporation were used. In this study, three synoptic stations with different climates, including Gorgan, Shiraz, and Kish, were chosen. Three stations with different climates were used to better evaluate and repeat the steps of the method so that the efficiency of the method could be more accurately assessed. Considering the importance of the value of evaporation in nature, evaporation modeling with the ANN and its combination with the COOT algorithm, which mimics the natural life of a COOT bird, was performed using five meteorological parameters, including the minimum air temperature, maximum air temperature, wind speed, average relative humidity, and sunshine hours on a monthly between 2000 and 2022. The dataset was divided into two phases: training (70 % of the dataset) and testing (30% of the dataset). To evaluate the performance of developed models, statistical indices of these models such as correlation coefficient (R), root-mean-square error (RMSE), Nash-Sutcliffe coefficient (NS), and their graphical representations were compared with each other.

#### Results and Discussion

As mentioned, four models of ANN-COOT with varying input parameters were developed and compared to four conventional ANN models. Statistical performances were calculated, and comparison plots were made in the training and testing phases to find the most adequate model for the prediction of evaporation. Comparing of obtained results from statistical indices for the testing phase revealed that the COOT-ANN4 model had the best performance for Gorgan with the R, RMSE, and NS equal to 0.99, 8.19, and 0.99 respectively. Shiraz also obtained values of the R, RMSE, and NS equal to 0.99, 18.43, and 0.98 respectively. Similarly, for Kish, the values of the R, RMSE, and NS equal to 0.97, 19.36, and 0.93 respectively, have better performance than the

other models. Compared with the results of different input combinations, the hybrid ANN-COOT model (ANN-COOT4) at three stations was found superior with input combinations of Tmin, Tmax, SSH, RH, and WS. Additionally, to evaluate the accuracy of developed models, Scatter plots, Violin plots, Relative error percent plots (RE %), Taylor diagrams, and Histograms were drawn. By comparing the graphical representations, it can be determined that the hybrid COOT with ANN4, namely the COOT-ANN4 model, has improved the artificial neural network at Gorgan, Shiraz, and Kish stations.

### Conclusion

The algorithm of COOT is an optimization algorithm that is generally used to solve optimization problems. As observed from the overall performance of the results of the hybrid model in predicting evaporation, the objective function was minimized. The results indicated that scenario four of the COOT-ANN4 hybrid model with input parameters of minimum temperature, maximum temperature, sunshine hours, relative humidity, and wind speed has better accuracy and performance at all three stations. In general, the findings of this study revealed that the COOT algorithm can improve the artificial neural network (ANN) structure in any climate and provide a hybrid model with higher accuracy and less error for modeling the evaporation parameter. Considering that the COOT algorithm is powerful and efficient, it is better to use it in various fields to improve the performance and accuracy of models. The testing results revealed that the lowest Root Mean Square Error RMSE (18.43, 19.36 and 8.19) and highest coefficient of correlation R (0.99, 0.97, and 0.99), and the highest Nash–Sutcliffe Efficiency Coefficient (N-S) (0.98, 0.93 and 0.99) attained by the ANN-COOT4 hybrid model (relative to other ANN and ANN-COOT models) tested for three selected stations in Shiraz, Kish and Gorgan sites. Concerning the predictive efficiency, the developed ANN-COOT hybrid model, improved the modeling performance at extreme points, which outperforms the ANN model, indicating its capability in the prediction of monthly evaporation.

**Keywords:** Artificial neural network, Coot bird algorithm, COOT-ANN hybrid algorithm, Evaporation, Modeling

**Article Type:** Research Article

### Acknowledgment

The present study is a part of a thesis and the information used in this article was prepared in cooperation with the National Meteorological Organization. All the authors of the article are grateful to the respected authorities of that organization.

### Conflicts of interest

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

### Data availability statement

All data generated during the manuscript analysis are included in the article. Further datasets are available upon a reasonable request to the corresponding author.

### Authors' contribution

**Farnaz Alampour Rajabi:** Performing software/statistical analysis, writing the first version of the article; **Mohammad Ali Ghorbani:** Conceptualization, guidance, review of the article, control of the results; **Ismail Esadi:** consulting, guidance, editing, and revising the text of the article.

\*Corresponding Author, E-mail: m\_ali\_ghorbani@ymail.com

**Citation:** Alempour Rajabi, F., Ghorbani, M.A., & Asadi, E. (2024). Modeling of the evaporation process using the hybrid algorithm of the COOT bird and artificial neural network. *Water and Soil Management and Modeling*, 4(2), 279- 294. DOI: 10.22098/mmws.2023.12692.1266

Received: 13 April 2023, Received in revised form: 29 April 2023, Accepted: 03 May 2023, Published online: 03 May 2023  
*Water and Soil Management and Modeling*, Year 2024, Vol. 4, No. 2, pp. 279-294

Publisher: University of Mohaghegh Ardabili

© Author(s)





## مدل‌سازی فرآیند تبخیر با استفاده از الگوریتم هیبریدی پرنده کوت و شبکه عصبی مصنوعی

فرناز عالم‌پور رجبی<sup>۱</sup>، محمدعلی قربانی<sup>۲\*</sup>، اسماعیل اسدی<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۲</sup> استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۳</sup> استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

### چکیده

تبخیر یکی از مؤلفه‌های اساسی در چرخه هیدرولوژی است. با توجه به اهمیت خروج آب از دسترس بشر، برآورد صحیح تبخیر بیش‌تر مورد توجه پژوهش‌گران قرار گرفته است. در این پژوهش، به‌منظور مدل‌سازی تبخیر، از هیبرید الگوریتم بهینه‌ساز کوت با شبکه عصبی مصنوعی استفاده شد. به‌منظور اجرای مدل، از داده‌های هواشناسی سه ایستگاه سینوپتیک گرگان، شیراز و کیش با توجه به اقلیم‌های مختلف استفاده شد. داده‌های هواشناسی شامل میانگین دمای هوای کمینه، میانگین دمای هوای بیشینه، سرعت باد، میانگین رطوبت نسبی و ساعات آفتابی در طول دوره آماری ۲۰۰۰ تا ۲۰۲۲ در مقیاس ماهانه بوده است. برای انتخاب ترکیب داده‌های ورودی به هر مدل از چهار سناریو استفاده شد. برای ارزیابی عملکرد نتایج حاصل از دو مدل، شاخص‌های آماری ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش-ساتکلیف (NS) مورد استفاده قرار گرفت. به‌منظور تأیید نتایج از نمودارهای گرافیکی تیلور، پراکنش، هیستوگرام، خطای نسبی و ویولنی نیز استفاده شد. نتایج مرحله صحت‌سنجی مربوط به سناریوی چهارم از مدل هیبریدی در گرگان با مقادیر  $(R=0/99)$ ،  $(RMSE=8/19)$  و  $(NS=0/99)$ ، در شیراز با  $(R=0/99)$ ،  $(RMSE=18/43)$  و  $(NS=0/98)$  و در کیش با  $(R=0/97)$ ،  $(RMSE=19/36)$  و  $(NS=0/93)$  عملکرد بهتری نسبت به سایر مدل‌ها از خود نشان داد. همچنین، نتایج حاکی از آن است که هیبرید الگوریتم بهینه‌ساز کوت توانست دقت شبکه عصبی مصنوعی را در تمام سناریوها با هر ترکیبی از داده‌ها افزایش دهد. در نهایت، نتایج نشان داد که عملکرد سناریوی چهارم الگوریتم هیبریدی (COOT-ANN4) که شامل هر پنج داده هواشناسی بوده است در هر سه ایستگاه دقیق‌ترین نتایج را نشان داده است.

**واژه‌های کلیدی:** الگوریتم پرنده کوت، الگوریتم هیبریدی COOT-ANN، تبخیر، شبکه عصبی مصنوعی، مدل‌سازی

### نوع مقاله: پژوهشی

\*مسئول مکاتبات، پست الکترونیکی: m\_ali\_ghorbani@ymail.com

**استناد:** عالم‌پور رجبی، فرناز، قربانی، محمدعلی، و اسدی، اسماعیل (۱۴۰۳). مدل‌سازی فرآیند تبخیر با استفاده از الگوریتم هیبریدی پرنده کوت و شبکه عصبی مصنوعی. *مدل‌سازی و مدیریت آب و خاک*، ۴(۲)، ۲۷۹-۲۹۴.  
DOI: 10.22098/mmws.2023.12692.1266

تاریخ دریافت: ۱۴۰۲/۰۱/۲۴، تاریخ بازنگری: ۱۴۰۲/۰۲/۰۹، تاریخ پذیرش: ۱۴۰۲/۰۲/۱۳، تاریخ انتشار: ۱۴۰۲/۰۲/۱۳

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۳، دوره ۴، شماره ۲، صفحه ۲۷۹ تا ۲۹۴  
ناشر: دانشگاه محقق اردبیلی © نویسندگان



## ۱- مقدمه

به فرآیند تبدیل مایع به بخار، تبخیر می‌گویند که یک پدیده طبیعی در چرخه هیدرولوژیکی و منعکس‌کننده تعامل بین دریا و هواست. با توجه به گرم‌شدن کره زمین، برآورد صحیح تبخیر تبدیل به یک چالش مهم در مدیریت منابع آب شده است. بنابراین، مدل‌سازی و آگاه شدن از میزان تبخیر به‌عنوان یکی از متغیرهای هیدرولوژیکی در پژوهش‌های کشاورزی و حفاظت آب و خاک از اهمیت زیادی برخوردار است. تعدادی از داده‌های هواشناسی بر فرآیند تبخیر-تعرق تأثیر می‌گذارند و به دلیل پیچیده بودن پارامتر تبخیر، برای تعیین دقیق آن باید از روشی استفاده کرد که با دقت بالا متغیر تبخیر را مدل‌سازی کند (Talebi et al., 2023). امروزه روش شبکه‌های عصبی مصنوعی<sup>۱</sup> (ANN) به دلیل کاربرد گسترده و آسان می‌توانند مشکلات پیچیده را حتی در حالی که داده‌ها مبهم باشند حل کنند و به همین دلیلی در بین پژوهش‌گران بسیار محبوب شده است (Mirzania et al., 2021). از این‌رو، جدیداً الگوریتم‌های هوشمند بسیار زیادی در جهت به‌دست آوردن بهترین راه‌حل برای مسائل پیچیده مهندسی پیشنهاد شده است. زیرا آن‌ها می‌توانند پاسخ‌های بهینه را سریع‌تر و دقیق‌تر پیدا کنند (Khari et al., 2023). در این راستا، Goyal et al. (2014) توانایی‌های شبکه عصبی مصنوعی (ANN)، حداقل مربعات-رگرسیون بردار پشتیبان (LS-SVR)، منطق فازی و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) را برای بهبود دقت تخمین تبخیر تحت روزانه را در اقلیم گرمسیری حوزه آبخیز کارسو در هند با داده‌های هواشناسی روزانه از سال ۲۰۰۰ تا ۲۰۱۰، مورد بررسی قرار دادند. مدل‌های ANN شامل مدل‌های پسانتشار به جلو (FFBP) با تنظیم بیزی (BR)، همراه با الگوریتم لونیبرگ-مارکوورت (LM) توسط شش داده ورودی بررسی شد. سپس نتایج به‌دست آمده از مدل‌های ANN، LS-SVR، Fuzzy Logic و ANFIS با متغیرهای ارزیابی مقایسه شدند. طبق نتایج به‌دست آمده رویکردهای منطق فازی و LS-SVR می‌تواند با موفقیت در مدل‌سازی تبخیر اجرا شود و مدل‌های یادگیری ماشین از روش‌های تجربی سنتی HGS و SS عملکرد بالاتری داشتند. در ادامه، Ghorbani et al. (2018) به‌منظور پیش‌بینی و تخمین تبخیر روزانه ایستگاه هواشناسی تالش طی بازه زمانی ۲۰۱۴-۲۰۱۲ از سه مدل MLP و مدل هیبریدی MLP-PSO و MLP-QPSO استفاده کردند. سپس دقت هر سه مدل پیشنهادی توسط معیارهای ارزیابی میانگین خطای مطلق، ریشه میانگین مربعات خطا، ویلموت ایندکس و نش-ساتکلیف بررسی و طبق نتایج ارائه شده بر اساس معیارهای ارزیابی مذکور، مدل هیبریدی MLP-

QPSO دقت و نتایج قابل‌قبولی نسبت به مدل هیبریدی MLP-PSO و مدل مستقل MLP دارد.

از سایر پژوهش‌ها، Moazen-zadeh et al. (2018) هواشناسی را از سال ۱۳۸۵ تا ۱۳۹۵ در ایستگاه‌های رشت و لاهیجان که بیش‌ترین تأثیر را بر پیش‌بینی تبخیر روزانه داشتند را با استفاده از ضریب همبستگی پیرسون انتخاب کردند. این متغیرها به‌عنوان ورودی برای پشتیبانی از رگرسیون برداری (SVR) و مدل SVR همراه با الگوریتم کرم شب‌تاب (SVR-FA) به‌منظور شبیه‌سازی مقادیر تبخیر به‌کار گرفته شد. سپس مقادیر ریشه میانگین مربعات خطای پیش‌بینی تبخیر در مرحله آزمایش SVR و SVR-FA ارزیابی شدند. نتایج مطالعه آن‌ها نشان داد برای مجموعه داده‌های پیش‌بینی‌نشده، تأثیر افزایش تعداد متغیرهای ورودی در SVR و SVR-FA برای کاهش خطای پیش‌بینی تبخیر به‌ترتیب در ایستگاه‌های لاهیجان و رشت بیش‌تر است. در پژوهش دیگری، Ashrafzadeh et al. (2019) مدل یکپارچه‌ای را برای تخمین تبخیر روزانه تحت بر اساس پرسپترون چندلایه (MLP) و الگوریتم بهینه‌سازی دسته میگوها (MLP-KH) ارائه کردند. به این منظور از اطلاعات اقلیمی دو ایستگاه هواشناسی آستارا و بندرانزلی استفاده شد. مدل‌های تلفیقی و کلاسیک طبق نتایج به‌دست آمده از معیارهای خطا مقایسه شدند و نتایج نشان داد که در منطقه مورد مطالعه مدل MLP-KH عملکرد خوبی دارد. همچنین، Huang et al. (2019) برای تخمین دقیق تبخیر-تعرق مرجع روزانه با داده‌های هواشناسی در مناطق مرطوب چین، یک الگوریتم جدید یادگیری ماشین را با استفاده از تقویت گرادیان روی درخت‌های تصمیم با پشتیبانی ویژگی‌های طبقه‌بندی و دو الگوریتم دیگر رایج یادگیری ماشین، جنگل‌های تصادفی (RF) و ماشین بردار پشتیبانی (SVM) را برای مقایسه مورد ارزیابی قرار دادند. هشت ترکیب ورودی داده‌های هواشناسی روزانه از پنج ایستگاه بین سال‌های ۲۰۱۵-۲۰۰۱ در جنوب چین برای آموزش و آزمایش مدل اعمال شد. طبق نتایج به‌دست آمده مشاهده شد که هر سه الگوریتم می‌توانند دقت لازم را برای برآورد دقیق تبخیر-تعرق مرجع به‌دست آورند. اما در بین آن‌ها الگوریتم CatBoost پتانسیل بسیار بالایی برای تخمین ET<sub>0</sub> در مناطق مرطوب چین دارد.

در مطالعه دیگری، Maroufpoor et al. (2020) دقت مدل شبکه عصبی مصنوعی مبتنی بر الگوریتم گرگ خاکستری (ANN-GWO) را در تخمین ET<sub>0</sub> بررسی کردند. این مطالعه بر اساس داده‌های هواشناسی ۳۱ استان ایران در پنج اقلیم متفاوت، با استفاده از هفت سناریو توسط

<sup>1</sup> Artificial neural network

مدل‌های شبکه‌ی عصبی مصنوعی و ادغام آن با تبدیل موجک، درخت تصمیم، رگرسیون خطی چندمتغیره و ماشین بردار پشتیبان، از پنج داده‌ی هواشناسی روزانه‌ی ایستگاه اسکاتسبلوف، از سال ۲۰۰۵ تا ۲۰۱۳ که شامل دمای کمینه، دمای بیشینه، رطوبت نسبی، تابش خورشیدی و سرعت باد است به‌عنوان ورودی استفاده کردند. هر مدل با هشت سناریو از ترکیب‌های متفاوت اجرا و نتایج مدل‌ها با استفاده از شاخص‌های ارزیابی و نمودار تیلور مورد بررسی قرار گرفت که نشان داد ترکیب هشتم از مدل ادغام شده‌ی شبکه‌ی عصبی با تبدیل موجک در مقایسه با مدل‌های دیگر عملکرد بسیار خوبی دارد. در نهایت، Zhao et al. (2022) به‌منظور بهبود دقت پیش‌بینی تبخیر-تعرق مرجع در مناطقی که داده‌های از دست رفته دارند، الگوریتم ترکیبی جدید به نام الگوریتم بهینه‌سازی عقاب طلایی (GEO) و الگوریتم بهینه‌سازی گنجشک (SSA) با مدل ماشین یادگیری افراطی (ELM) را پیشنهاد دادند. این الگوریتم با پنج متغیر ورودی بر روی ایستگاه‌های معمولی در مناطق نیمه‌خشک چین بررسی شد و با توجه به نتایج، مشاهده شد که مدل بهینه‌ساز SSA-ELM توانسته است با دقت بالا  $ET_0$  را تخمین بزند.

اخیراً استفاده از الگوریتم بهینه‌سازی پرندۀ کوت که الگوریتمی جدید است، در موضوعات مختلف توسط پژوهش‌گران متعددی مدنظر قرار گرفته و برحسب گزارش‌های موجود توانسته عملکرد قابل‌قبولی از خود نشان دهد (Memarzadeh and Keynia, 2021; Naruei and Keynia, 2021). هدف از پژوهش حاضر استفاده از الگوریتم‌های جدید و ابتکاری است که به‌صورت هیبرید شده با شبکه‌های عصبی مصنوعی می‌توانند در دستیابی به نتایج، باعث بهبود عملکرد شوند. با این رویکرد در این پژوهش برای منطقه‌ی مورد نظر، نخستین بار به‌منظور افزایش دقت روش‌های مبتنی بر شبکه‌ی عصبی مصنوعی، از الگوریتم کوت به‌عنوان یک راه‌کار جدید استفاده شد. نتایج حاصل از عملکرد مدل توسعه‌یافته با استفاده از شاخص‌های آماری کمی و نمودارهای گرافیکی مورد ارزیابی قرار گرفت.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه‌ی مورد مطالعه

در این مطالعه از داده‌های هواشناسی ایران که کشوری در غرب آسیا و منطقه‌ی خاورمیانه است استفاده و سه ایستگاه سینوپتیک گرگان، شیراز و کیش از شمالی‌ترین نقطه‌ی کشور تا مناطق خلیج فارس انتخاب شد. گرگان از شهرهای بخش شمالی دامنه‌ی ارتفاعات البرز با آب و هوای معتدل است. این شهر با مساحت

معیارهای ارزیابی و نمودار تیلور<sup>۱</sup> بررسی شد و نتایج نشان داد الگوریتم GWO در بهینه‌سازی سیستم شبکه‌ی عصبی مصنوعی مؤثر بوده و مدل ANN-GWO در همه‌ی سناریوها نسبت به ANN و LS-SVR عملکرد دقیق‌تری داشته است. در سد قلعه‌چای عجب‌شیر نیز، Arya Azar et al. (2021) به‌منظور تخمین مقدار تبخیر، بر اساس شبکه‌ی عصبی مصنوعی (ANN) و الگوریتم‌های ترکیبی آن (شامل بهینه‌سازی هریس هاکس (HHO)، الگوریتم بهینه‌سازی نهنگ (WOA) و بهینه‌سازی ازدحام ذرات (PSO))، متغیرهای مؤثر در فرآیند تبخیر را برای هر یک از مدل‌ها در نظر گرفتند. سپس تمام مدل‌ها توسط معیارهای ارزیابی و نمودار تیلور با هم مقایسه و با توجه به این‌که عملکرد هر سه مدل قابل‌قبول بود، اما مدل ANN-HHO عملکرد بالاتری نسبت به سایر مدل‌ها از خود نشان داد. در مناطق خشک و نیمه‌خشک شمال غربی چین نیز Dong et al. (2021) برای تخمین تبخیر روزانه‌ی تشت از مدل یادگیری ماشین ترکیبی جدید الگوریتم خفاش جفت (Bat) و تقویت گرادیان با پشتیبانی از ویژگی‌های طبقه‌بندی (CatBoost) و دو الگوریتم متداول دیگر از جمله جنگل تصادفی (RF) و CatBoost اصلی (CB) استفاده کردند. داده‌های به‌کار برده شده‌ی هواشناسی روزانه برای ۱۲ سال از ۴۵ ایستگاه هواشناسی در منطقه‌ی مورد نظر، حداقل و حداکثر دمای هوا ( $T_{min}$  و  $T_{max}$ )، رطوبت نسبی (RH)، سرعت باد (U)، و تابش خورشیدی جهانی ( $R_s$ ) است. طبق نتایج به‌دست آمده با مقایسه‌ی چهار شاخص آماری، مدل جدید Bat-CB نسبت به RF عملکرد بهتری از خود نشان داد.

به‌منظور بررسی تأثیر تغییر اقلیم بر منابع آب به‌ویژه جهت دستیابی به الگوی بهینه‌ی محصول و برنامه‌ریزی نیاز آبی در آینده، Ahi et al. (2022) اقدام به برآورد میزان تبخیر از مخزن کرایدمیر ترکیه با بهره‌گیری از روش‌های مبتنی بر هوش مصنوعی تحت الگوریتم‌های یادگیری مختلف کردند. آن‌ها در برای رسیدن به این هدف سناریوهای مختلفی را مدنظر قرار دادند و پس از استخراج نتایج جهت ارزیابی عملکرد این مدل توسعه داده شده از شاخص‌های آماری مختلفی استفاده نمودند و مشخص شد که مدل شبکه‌ی عصبی با بارگیری ورودی معین در جهت تعیین برآورد مقدار تبخیر از مخزن از دقت بسیار مطلوبی برخوردار است. هم‌چنین، Malekahmadi et al. (2022) به‌منظور مدل‌سازی فرآیند تبخیر-تعرق روزانه با استفاده از

<sup>1</sup> Taylor diagram

بسیار خشک در شهرستان بندر لنگه استان هرمزگان در خلیج فارس و در ۱۹ کیلومتری از جنوب ایران و تقریباً به شکل بیضوی قرار دارد. سطح این جزیره صاف و فاقد کوه یا تپه‌های بلند است که با وسعت ۹۱ کیلومترمربع در نیمه جنوبی منطقه معتدل شمالی با مختصات جغرافیایی  $26^{\circ} 32'$  عرض شمالی و  $53^{\circ} 58'$  طول شرقی و در فاصله ۱۷ کیلومتری از ساحل جنوبی ایران و ۲۴۰ کیلومتری غرب بندر عباس واقع شده است. در ادامه، در جدول ۱ و شکل ۱ به ترتیب مشخصات آماری داده‌های مطالعاتی و نمودار سری زمانی سه ایستگاه سینوپتیک گرگان، شیراز و کیش ارائه شده است.


حدود ۱۳۱۶ کیلومترمربع و ارتفاع ۱۷۶ متر از سطح دریا و با مختصات جغرافیایی  $53^{\circ} 10'$  تا  $53^{\circ} 45'$  طول شرقی و  $36^{\circ} 44'$  تا  $36^{\circ} 58'$  عرض شمالی در استان گلستان واقع شده است. شیراز کلان‌شهری در ایران و جنوب کشور است که در بخش مرکزی استان فارس و منطقه کوهستانی زاگرس با آب و هوای معتدل از  $29^{\circ} 36'$  شمالی و  $52^{\circ} 32'$  با مساحتی حدود ۱۲۶۸ کیلومتر مربع به شکل مستطیل قرار دارد. این شهر از غرب با کوه دراک، از شمال با کوه‌های بمو، سبزویشان، چهل‌مقام و باباکوهی از رشته‌کوه‌های زاگرس همسایه است و ارتفاع آن از سطح دریا بین ۱۴۸۰ تا ۱۶۷۰ متر در نقاط مختلف شهر متغیر است. جزیره کیش به‌عنوان یک جزیره تفریحی ورزشی با آب و هوای نیمه استوایی

جدول ۱- مشخصات آماری داده‌های مطالعاتی

Table 1- Statistical characteristics of study data

نام ایستگاه	مشخصات آماری	دمای کمینه (درجه سانتی‌گراد)	دمای بیشینه (درجه سانتی‌گراد)	رطوبت نسبی (درصد)	سرعت باد (متر بر ثانیه)	ساعات آفتابی (مگاژول بر مترمربع بر روز)	تبخیر (میلی‌متر)
شیراز	کمینه	-2.22	10.55	11.19	0.43	166.00	0.00
	بیشینه	23.86	40.26	73.24	4.28	372.50	444.10
	میانه	10.27	28.08	32.96	1.72	284.75	188.20
	میانگین	10.58	26.83	36.44	1.75	282.31	201.60
	واریانس	54.39	81.90	241.92	0.33	2759.54	16261.38
	انحراف معیار	7.38	9.05	15.55	0.58	52.53	127.52
کیش	چولگی	0.02	-0.11	0.47	0.72	-0.17	0.17
	کمینه	0.00	20.88	47.69	2.32	33.00	5.10
	بیشینه	31.95	39.63	303.30	38.57	353.30	418.10
	میانه	23.64	33.04	66.80	3.87	273.50	233.90
	میانگین	23.79	31.77	68.60	4.33	267.59	228.53
	واریانس	30.87	30.56	587.13	13.40	2095.07	5269.89
گرگان	انحراف معیار	5.56	5.53	24.23	3.66	45.77	72.59
	چولگی	-0.84	-0.32	8.82	8.71	-1.65	-0.10
	کمینه	-3.97	8.49	58.11	0.79	74.10	14.80
	بیشینه	25.36	37.77	90.33	3.92	357.60	310.40
	میانه	11.87	24.27	74.76	2.45	184.45	96.90
	میانگین	12.62	24.02	74.52	2.48	194.08	116.90
گرگان	واریانس	59.12	67.31	54.97	0.47	3256.47	6045.82
	انحراف معیار	7.69	8.20	7.41	0.69	57.07	77.75
	چولگی	0.07	-0.02	-0.03	-0.04	0.47	0.49





شکل ۱- نمودار سری زمانی سه ایستگاه (گرگان، شیراز، کیش)

Figure 1- Time series plot of three stations (Gorgan, Shiraz, Kish)

سپس با یافتن مقادیر خطای مربوط به وزن‌ها و بایاس، الگوریتم به مرحله بعد یعنی Back-Propagation (BP) می‌رود. تا زمان نزدیک شدن خروجی به هدف این چرخه (and feed-forward and back-propagation) تکرار می‌شود. اگر داده‌ها در مقیاس داده شده مقیاس‌بندی نشده باشند، یک الگوریتم بهینه‌سازی ممکن است نتواند مقادیر بهینه را بیابد پس باید داده‌ها در یک بازه زمانی معین مقیاس شوند تا یک شبکه بتواند متغیرهای بهینه را سریع‌تر یاد بگیرد (Nourani, 2017). به‌منظور آغاز مدل‌سازی و با توجه به سناریوهای مشخص شده در جدول ۲، ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد برای فرآیند آزمون جداسازی شدند.

## ۲-۲- شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی همانند شبکه عصبی بیولوژیکی در دریافت پردازش و تولید اطلاعات عمل می‌کند. در شبکه‌های عصبی مصنوعی، کلید یادگیری تکرار است. هنگامی که چندین بار داده‌های مختلف وارد الگوریتم یادگیری شوند اختلاف داده‌ها را می‌توان با تفاوت‌هایی که در وزن و بردارهای سوگیری با یکدیگر دارند تشخیص داد. یکی از پرکاربردترین روش‌های آموزش و بازآموزی Back-Propagation of Error است که Back-Propagation (BP) نیز نامیده می‌شود. این الگوریتم و هر تکرار دو مرحله دارد؛ قدم اول حرکت روبه جلو (feed-forward motion) که شامل اندازه‌گیری مقادیر خطا پس از به‌دست آوردن مقادیر خروجی و مقایسه آن‌ها با هدف است

## جدول ۲- الگوهای مختلف ورودی مدل‌ها

Table 2- Different input patterns of the models

شماره	ورودی	خروجی	مدل شبکه عصبی مصنوعی	مدل هیبریدی
1	Tmin, Tmax	E	ANN1	COOT-ANN1
2	Tmin, Tmax, SSH	E	ANN2	COOT-ANN2
3	Tmin, Tmax, SSH, RH	E	ANN3	COOT-ANN3
4	Tmin, Tmax, SSH, RH, WS	E	ANN4	COOT-ANN4

موقعیت بر اساس رهبر، و حرکت رهبر است (Naruei and Keynia, 2021). انتخاب جمعیت به‌طور تصادفی بر اساس رابطه (۱) به‌دست می‌آید. در این رابطه CootPos(i) موقعیت d، تعداد متغیرها یا ابعاد و ub و lb به‌ترتیب کران بالایی و پایینی فضای جست و جو را نشان می‌دهند. در ادامه ub از طریق رابطه (۲) به‌دست می‌آید.

$$\text{CootPos}(i) = \text{rand}(1, d) \times (ub - lb) + lb \quad (1)$$

$$ub = [ub_1, ub_2, \dots, ub_d], lb = [lb_1, lb_2, \dots, lb_d] \quad (2)$$

پس از تولید جمعیت اولیه و تعیین موقعیت هر عامل، برای هر راه‌حل باید با استفاده از  $O_i = f(\vec{x})$  تابع هدف آن محاسبه

## ۲-۳- الگوریتم زندگی پرنده کوت

الگوریتم مدل زندگی طبیعی پرنده کوت شبیه‌سازی شده از رفتارهای جمعی مختلف از این پرنده است. پرنده کوت یک پرنده کوچک آبی با جثه متوسط است که عمدتاً پرهای سیاه دارند و از خانواده ریل (rail) هستند. این پرندگان در سطح آب حرکت می‌کنند و ابتدا حرکات نامنظمی دارند. اما به‌تدریج حرکات آن‌ها منظم می‌شود. پرندگان کوت به سمت رهبران پیشرو حرکت می‌کنند تا به یک منبع غذایی دسترسی پیدا کنند. طراحی الگوریتم کوت بر اساس چهار الگوی حرکتی از پرنده کوت در سطح آب که شامل حرکت تصادفی، حرکت زنجیره‌ای، تنظیم

## ۲-۳-۴- جنبش رهبر

موقعیت‌های رهبر بر اساس جهش از موقعیت‌های بهینه محلی به موقعیت‌های بهینه جهانی به‌روز می‌شوند (رابطه ۹). در آن، gBest بهترین موقعیت یافت شده،  $R_3$  و  $R_4$  اعداد تصادفی بین بازه صفر و یک،  $R$  عدد تصادفی بین بازه یک و منفی یک و  $B$  از طریق رابطه (۱۰) تعیین می‌شود:

$$\text{LeaderPos}(i) = \begin{cases} B \times B_3 \times \cos(2\pi R) \times \\ (g\text{Best} - \text{LeaderPos}(i)) + g\text{Best} & R_4 < 0/5 \\ B \times B_3 \times \cos(2\pi R) \times \\ (g\text{Best} - \text{LeaderPos}(i)) + g\text{Best} & R_4 \geq 0/5 \end{cases} \quad (9)$$

$$B = 2 - L \times \left(\frac{1}{\text{Iter}}\right) \quad (10)$$

## ۲-۴- الگوریتم هیبریدی پرنده کوت و شبکه عصبی مصنوعی (COOT-ANN)

ترکیب الگوریتم پرنده کوت و شبکه عصبی مصنوعی در مدل COOT-ANN، یک رویکرد جالب برای بهبود عملکرد مدل‌های پیش‌بینی است. با توجه به این‌که پرنده کوت یک الگوریتم بهینه‌سازی است که با الهام از رفتار گروهی پرنده‌ها طراحی شده است، می‌تواند بهبود قابل‌توجهی در عملکرد مدل‌های شبکه عصبی مصنوعی که برای پیش‌بینی استفاده می‌شوند، ایجاد کند. این روش به مدل‌ها اجازه می‌دهد تا به حداکثر دقت و کارایی دسترسی پیدا کنند، زیرا در هر مرحله از ترکیب الگوریتم پرنده کوت و شبکه عصبی مصنوعی، مدل با استفاده از الگوریتم پرنده کوت بهینه‌سازی شده و وزن‌ها و بایاس‌های بهینه برای شبکه عصبی مصنوعی به‌دست می‌آیند. در نهایت، با تکرار این فرآیند به حداکثر قابلیت‌های مدل دسترسی پیدا می‌شود. در مدل هیبریدی جدید نیز به‌منظور دستیابی به بهترین مدل، باید به بهینه‌سازی وزن‌ها و بایاس‌ها توجه کرد. این عملیات از طریق تکرار محاسبه خطا و بهینه‌سازی متغیرهای مدل انجام می‌شود و در نتیجه مدل به دقت و عملکرد بهتری دست‌یافته و مزایای شبکه عصبی مصنوعی و بهینه‌سازی را دارد.

در کل، ترکیب الگوریتم پرنده کوت و شبکه عصبی مصنوعی در مدل COOT-ANN، یک روش قدرتمند برای بهبود دقت و کارایی مدل‌های پیش‌بینی است که امیدواریم در آینده بیش‌تر موردبه آن توجه شود (Mohammadi et al., 2020). در شکل ۲ نمودار جریانی تداومی از گام‌های پیموده شده در مدل COOT-ANN که در طول پژوهش به‌کار گرفته شد، ارائه شده است.

شود. براساس توانایی‌های آن‌ها به‌صورت تصادفی تعداد معینی کوت را در گروه خود انتخاب می‌کنیم تا به‌عنوان رهبر عمل کنند (NL). سپس حرکات چهارگانه کوت بر سطح آب که در قسمت قبلی ذکر شد پیاده‌سازی می‌شود.

## ۲-۳-۱- حرکت تصادفی

موقعیت  $Q$  برای این حرکت به‌طور تصادفی با استفاده از رابطه (۳) مقدارهی اولیه می‌شود و موقعیت با رابطه (۴) به‌روز می‌شود. در رابطه (۴)،  $R_2$  یک عدد تصادفی در بازه صفر و یک است و  $A$  با استفاده از رابطه (۵) محاسبه می‌شود و در آن Iter حداکثر تعداد تکرارها و  $L$  تعداد تکرارهای فعلی است.

$$Q = \text{rand}(1, d) \times (ub - lb) + lb \quad (3)$$

$$\text{CootPos}(i) = \text{CootPos}(i) + A \times R_2 \times (Q) - \text{CootPos}(i) \quad (4)$$

$$A = 1 - L \times \left(\frac{1}{\text{Iter}}\right) \quad (5)$$

## ۲-۳-۲- جنبش زنجیره‌ای

برای اجرای حرکت زنجیره‌ای می‌توان موقعیت میانگین دو پرنده را با استفاده از رابطه (۶) محاسبه کرد که در آن  $\text{CootPos}(i-1)$  محل پرنده دوم را نشان می‌دهد.

$$\text{CootPos}(i) = \frac{\text{CootPos}(i-1) + \text{CootPos}(i)}{2} \quad (6)$$

## ۲-۳-۳- تنظیم موقعیت از نظر رهبر

در طول هر گروه، موقعیت یک پرنده بر اساس موقعیت رهبر به‌روز می‌شود. بنابراین، پیرو به سمت رهبر حرکت می‌کند. رهبر با استفاده از رابطه (۷) انتخاب می‌شود. در رابطه (۷)،  $K$  به‌عنوان تعداد شاخص رهبر،  $i$  تعداد دنبال‌کننده پرنده و  $NL$  تعداد رهبران است. موقعیت یک کوت طبق رابطه (۸) در طول این حرکت به‌روز می‌شود:

$$K = 1 + (i \text{ MOD } NL) \quad (7)$$

$$\text{CootPos}(i) = \text{LeaderPos}(k) + 2 \times R_1 \times \cos(2R\pi) \times (\text{LeaderPos}(k) - \text{CootPos}(i)) \quad (8)$$

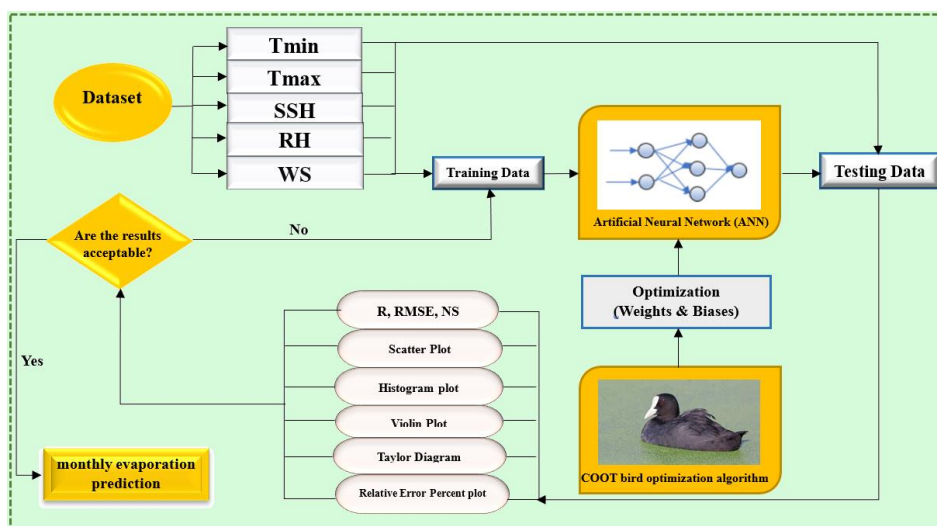
با استفاده از  $\text{CootPos}(i)$  به‌عنوان موقعیت فعلی پرنده کوت،  $\text{LeaderPos}(k)$  موقعیت رهبر انتخاب شده را نشان می‌دهد.  $R_1$  یک عدد تصادفی در بازه صفر و یک و  $R$  یک عدد تصادفی در بازه یک و منفی یک است.



جدول ۳- پارامترهای مورد استفاده برای آموزش مدل‌های ANN و COOT-ANN

Table 3- Parameters used for training ANN and COOT-ANN models

ANN		COOT-ANN	
Model Parameter	Value/Type	Model Parameter	Value
Network Type	feed-forward back propagation	Maxiter	1000
Number of Hidden layer (Neurons)	10	Pop Size	500
Data Division	Dividerand	Number of Hidden layer (Neurons)	10
Training function	Adam	Learning rate	0.001
Transfer function Layer1	Relu	P	0.1
Epoch	1000	NL	50
		NC	450



شکل ۲- نمودار جریان‌ی مدل COOT-ANN  
Figure 2- Flowchart of the COOT-ANN model

در این روابط،  $O_i$  نماد مقادیر مشاهداتی،  $P_i$  مقادیر حاصل از مدل،  $\bar{O}$  مقدار میانگین مقادیر مشاهداتی،  $\bar{P}$  مقدار میانگین مقادیر مدل و  $n$  تعداد داده‌ها است.

### ۳- نتایج و بحث

در این مطالعه امکان ادغام مدل شبکه عصبی مصنوعی با یک الگوریتم جدید الهام گرفته از طبیعت به نام الگوریتم زندگی پرندۀ کوت به منظور مدل‌سازی میزان تبخیر در سه ایستگاه سینوپتیک واقع در ایران با استفاده از داده‌های هواشناسی مورد بررسی قرار گرفت. برای فرآیند مدل‌سازی، ۷۰ درصد ابتدای سری زمانی ماهانه داده‌ها شامل ۱۹۲ عدد جهت استفاده در بخش آموزش (واسنجی) و ۳۰ درصد بقیه شامل ۸۲ عدد برای استفاده در بخش آزمون (صحت‌سنجی) در نظر گرفته شد. در جدول ۴، عملکرد مدل‌های مورد استفاده با استفاده از شاخص‌های آماری در سناریوهای مختلف آورده شده است. به منظور طراحی سناریوهای مختلف برای تنظیم داده‌های ورودی، از مقادیر همبستگی داده‌های دمای کمینه و بیشینه، ساعات آفتابی، رطوبت نسبی و سرعت باد با تبخیر استفاده شد. نتایج جدول ۴ نشان می‌دهد که برای ایستگاه گرگان، سناریوی

### ۲-۵- پارامترهای ارزیابی

برای ارزیابی میزان دقت مدل‌های انتخاب شده از شاخص‌های آماری و نیز مقایسه نمودار مقادیر مشاهداتی با محاسباتی و نمودار پراکنش استفاده شد که عبارت‌اند از: ضریب همبستگی<sup>۱</sup> (R)، ریشه میانگین مربعات خطا<sup>۲</sup> (RMSE) و ضریب نش-ساتکلیف<sup>۳</sup> (NS). بهترین مدل آن است که ضریب همبستگی و ضریب نش-ساتکلیف آن به یک و ریشه میانگین مربعات خطا به صفر نزدیک‌تر باشد.

$$R = \frac{[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (12)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (13)$$

<sup>1</sup> Correlation coefficient

<sup>2</sup> Root mean square error

<sup>3</sup> Nash-Sutcliffe coefficient

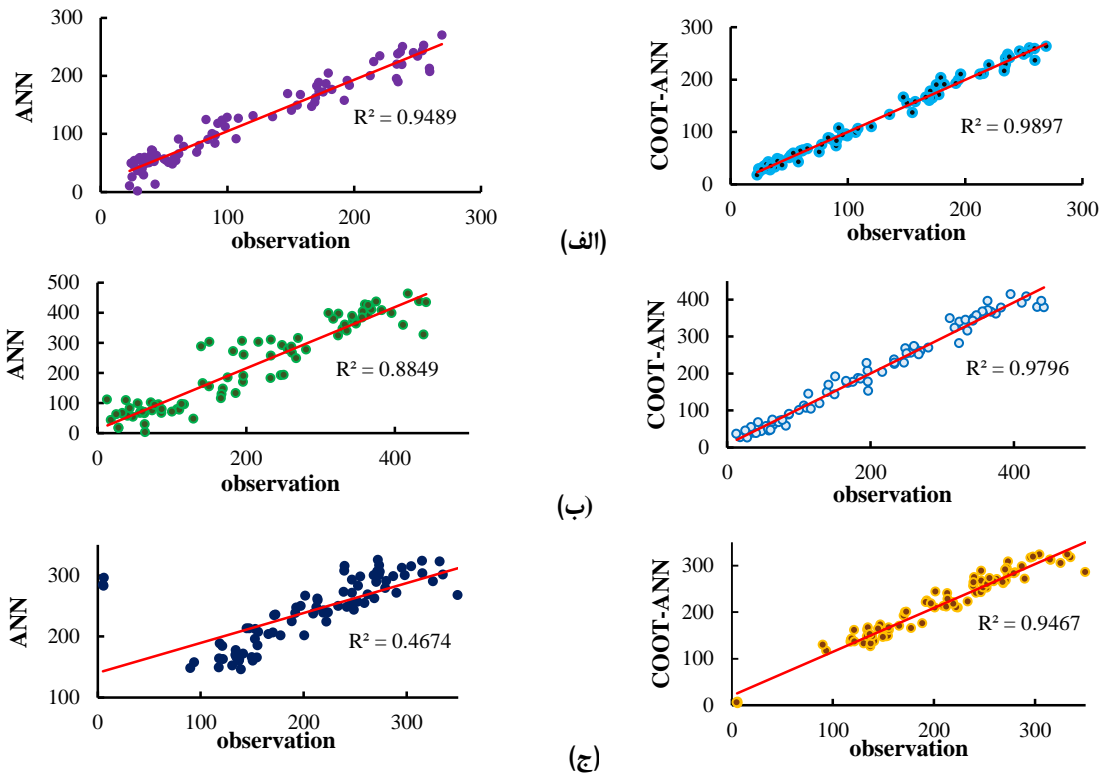
شبکه عصبی مصنوعی به این منظور دست یابد و باعث افزایش دقت مدل‌های متکی بر هوش مصنوعی شود. در شکل ۳ نمودار پراکندگی داده‌ها نشان داده شده است. نمودار پراکندگی نوعی نمودار گرافیکی است که در آن داده‌ها به صورت تک‌تک نقاط روی صفحه نمایش داده می‌شوند. این داده‌ها با دو متغیر مختلف مانند  $x$  و  $y$  بیان شده و این دو متغیر به عنوان محورهای مستقل و وابسته نمودار در نظر گرفته می‌شوند. با رسم خطی بر روی این نقاط می‌توان رابطه‌ای بین دو متغیر را مشخص کرد. با مراجعه به نمودارهای مورد بررسی و در نظر گرفتن شاخص  $R^2$  ملاحظه می‌شود که همبستگی مثبت نقاط مربوط به سناریوی چهارم در هر سه ایستگاه، برای مدل هیبریدی به طور قابل توجهی بیش‌تر از شبکه عصبی مصنوعی است. شکل ۴، نمودار هیستوگرام را نشان می‌دهد که یک نمودار گرافیکی است و برای نشان دادن فراوانی توزیع یک مجموعه از داده‌ها به کار می‌رود. در این نوع نمودار، محور افقی به صورت پهنای بازه‌های داده‌ها و محور عمودی به صورت فراوانی یا تعداد داده‌ها نمایش داده می‌شود. بر اساس نتایج به دست آمده، شبکه عصبی مصنوعی و مدل هیبریدی، با استفاده از داده‌های مشاهداتی مقایسه شدند و در سه ایستگاه مختلف، مدل هیبریدی نسبت به داده‌های مشاهداتی تطابق بهتری را نشان داد.

دوم از مدل هوش مصنوعی، برای مرحله صحت‌سنجی در مقایسه با سایر سناریوها عملکرد بهتری داشته است. برای ایستگاه سینوپتیک شیراز، سناریوی اول از مدل هوش مصنوعی نتایج بهتری را با توجه به معیارهای ارزیابی در مرحله صحت‌سنجی نشان داده است. برای ایستگاه سینوپتیک کیش، سناریوی سوم از مدل هوش مصنوعی، در مقایسه با سایر سناریوها از دقت بیش‌تری برخوردار بوده است. با مقایسه معیارهای ارزیابی، نتایج جدول ۴ نشان داد که مدل COOT-ANN4 در مرحله آزمون برای گرگان با بیش‌ترین ضریب همبستگی ( $R=0/99$ ) و کم‌ترین ریشه میانگین مربعات خطا ( $RMSE=0/19$ ) و ضریب نش-ساتکلیف ( $NS=0/99$ )، برای شیراز با بیش‌ترین ( $R=0/99$ )، کم‌ترین ( $RMSE=18/43$ ) و برای کیش نیز با بیش‌ترین ( $R=0/97$ )، کم‌ترین ( $NS=0/98$ )، بهترین نتایج را ارائه داده است. نتایج نشان داد که الگوریتم هیبریدی کوت و شبکه عصبی مصنوعی برای سناریوهایی که پنج متغیر ورودی را برای شبیه‌سازی تبخیر مورد استفاده قرار می‌دهند از عملکرد بهتری برخوردار است. با توجه به این‌که در مدل‌های تبخیر، پنج متغیر دمای کمینه و بیشینه، ساعات آفتابی، رطوبت نسبی و سرعت باد به عنوان عوامل تأثیرگذار هستند و اکثر مدل‌های ارائه شده سعی دارند تا در ترکیب خود این عوامل را در نظر بگیرند، الگوریتم بهینه‌ساز کوت توانسته است در ترکیب با مدل‌های

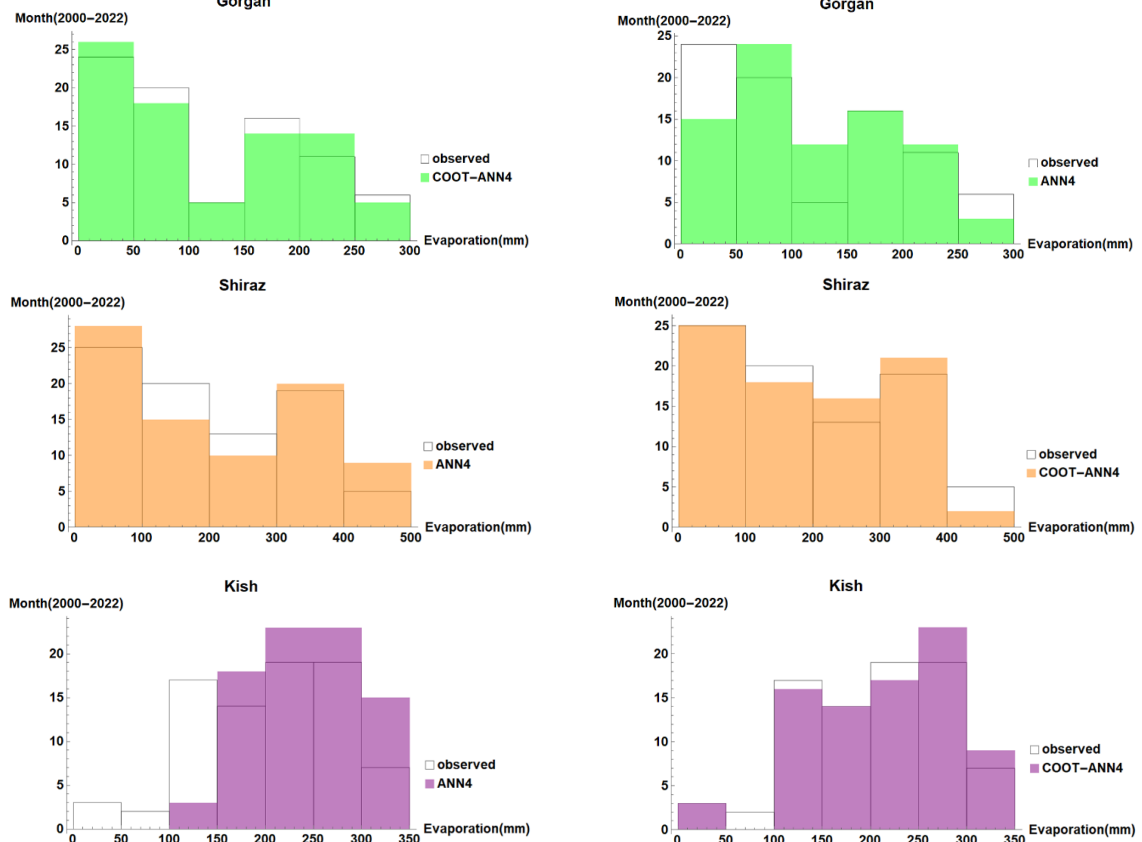
جدول ۴- معیارهای عملکرد در فرآیند آموزش و آزمون برای مدل‌های ANN و COOT-ANN

Table 4- Performance criteria in the training and testing process for ANN and COOT-ANN models

ایستگاه	مدل	آموزش			آزمون		
		NS	RMSE	R	NS	RMSE	R
گرگان	ANN1	0.89	25.64	0.89	0.93	22.00	0.96
	ANN2	0.92	21.91	0.96	0.95	17.70	0.98
	ANN3	0.94	25.39	0.94	0.92	23.00	0.96
	ANN4	0.96	21.43	0.96	0.94	19.12	0.97
	COOT-ANN1	0.97	17.94	0.97	0.97	14.45	0.99
	COOT-ANN2	0.97	18.41	0.97	0.97	13.40	0.99
	COOT-ANN3	0.98	16.67	0.98	0.98	12.32	0.99
	COOT-ANN4	<b>0.99</b>	<b>12.41</b>	<b>0.99</b>	<b>0.99</b>	<b>8.19</b>	<b>0.99</b>
	ANN1	0.97	32.69	0.97	0.92	35.10	0.96
	ANN2	0.96	36.15	0.96	0.90	41.21	0.95
شیراز	ANN3	0.96	36.59	0.96	0.89	42.96	0.95
	ANN4	0.95	40.71	0.95	0.85	49.68	0.94
	COOT-ANN1	0.97	29.16	0.97	0.94	30.42	0.97
	COOT-ANN2	0.98	26.49	0.98	0.96	24.41	0.98
	COOT-ANN3	0.98	24.31	0.98	0.97	21.08	0.99
	COOT-ANN4	<b>0.99</b>	<b>20.39</b>	<b>0.99</b>	<b>0.98</b>	<b>18.43</b>	<b>0.99</b>
	ANN1	0.76	45.05	0.76	0.53	50.39	0.89
	ANN2	0.78	43.48	0.78	0.50	52.24	0.84
	ANN3	0.77	44.12	0.77	0.54	49.83	0.88
	ANN4	0.89	31.17	0.89	0.21	65.71	0.68
کیش	COOT-ANN1	0.90	44.17	0.90	0.81	32.07	0.93
	COOT-ANN2	0.81	42.71	0.81	0.75	36.80	0.90
	COOT-ANN3	0.82	41.10	0.82	0.80	32.73	0.92
	COOT-ANN4	<b>0.91</b>	<b>30.22</b>	<b>0.91</b>	<b>0.93</b>	<b>19.36</b>	<b>0.97</b>
	ANN1	0.56	45.05	0.56	0.53	50.39	0.89
	ANN2	0.59	43.48	0.59	0.50	52.24	0.84



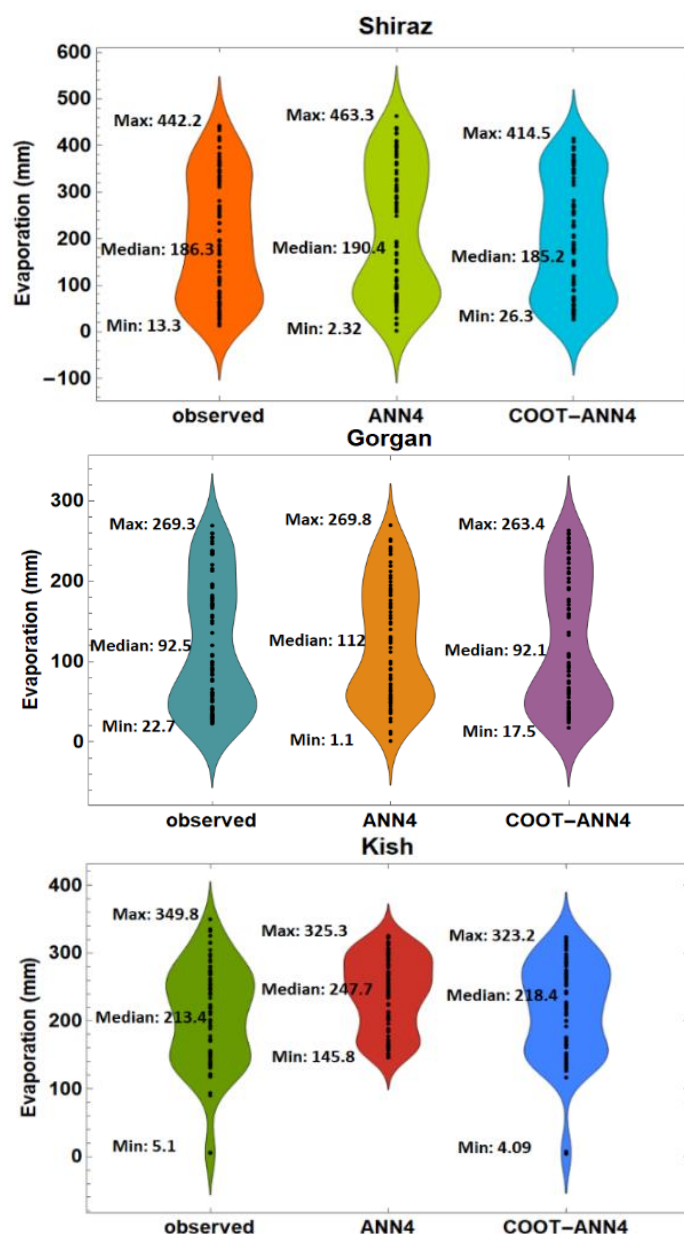
شکل ۳- نمودارهای پراکنندگی مقادیر مشاهده‌ای نسبت به مقادیر محاسباتی در مرحله آزمون سناریوی چهارم (الف: گرگان، ب: شیراز، ج: کیش)  
 Figure 3- Scatter plots of observed values compared to calculated values in testing phase of fourth scenario (a: Gorgan, b: Shiraz, c: Kish)



شکل ۴- نمودارهای هیستوگرام مقادیر مشاهده‌ای نسبت به مقادیر محاسباتی در مرحله آزمون سناریوی چهارم  
 Figure 4- Histogram plots of observed values compared to calculated values in the testing phase of the fourth scenario

مدل هیبریدی COOT-ANN بود (شکل ۵). به عبارت دیگر، می‌توان گفت پراکندگی و توزیع احتمال داده‌های مدل هیبریدی با مقادیر مشاهداتی تطابق بیشتری دارد و این یافته نشان از کارایی بهتری مدل هیبریدی در شبیه‌سازی فرآیند تبخیر دارد.

در شکل ۵، نمودار ویولنی داده‌ها نسبت به مقادیر بیشینه، کمینه و میانه برای مقادیر مشاهداتی و مدل‌ها که نمودار اصلاح شده و کامل‌تری از نمودار جعبه‌ای است ارائه شده است. در هر سه ایستگاه، نزدیک‌ترین نمودار ویولنی به داده‌های مشاهداتی،



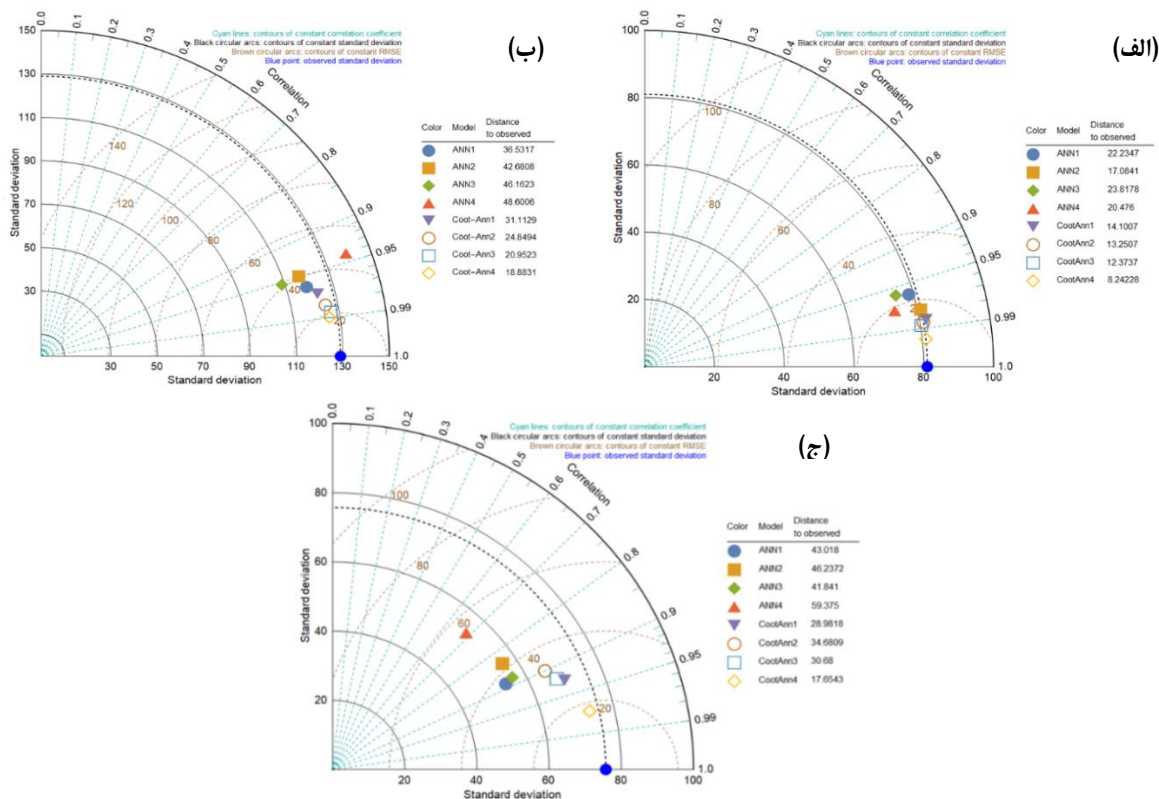
شکل ۵- نمودارهای ویولنی مقادیر مشاهداتی نسبت به مقادیر محاسباتی در قسمت آزمون سناریوی چهارم  
Figure 5- Violin charts of observed values compared to calculated values in the testing phase of the fourth scenario

(Taylor, 2001). در دیاگرام تیلور فاصله مقادیر مشاهداتی نسبت به مقادیر خروجی هر یک از سناریوهای مدل‌ها به صورت کمی نیز ارائه شده است. در ایستگاه سینوپتیک گرگان، کم‌ترین مقدار عددی دیاگرام تیلور در بین هشت سناریو، مربوط به مدل هیبریدی COOT-ANN4 با مقدار ۸/۲۴ است. همچنین، در ایستگاه سینوپتیک شیراز کم‌ترین مقدار عددی تیلور در انتخاب

دیاگرام تیلور (شکل ۶) یک ابزار مفید و کاربردی در پیش‌بینی و ارزیابی مدل‌های آماری است. نمودار تیلور امکان بررسی نتایج پیش‌بینی‌های مدل‌های مختلف را به طور هم‌زمان فراهم می‌کند. به عبارت دیگر، می‌تواند خلاصه‌ای از معیارهای ارزیابی به منظور تطابق الگوها با یکدیگر از نظر همبستگی، ریشه میانگین مربعات خطا و نسبت واریانس آن‌ها ارائه دهد

بوده است. نتایج نشان داد که در هر سه ایستگاه سینوپتیک، الگوریتم هیبریدی دقت را افزایش داده است.

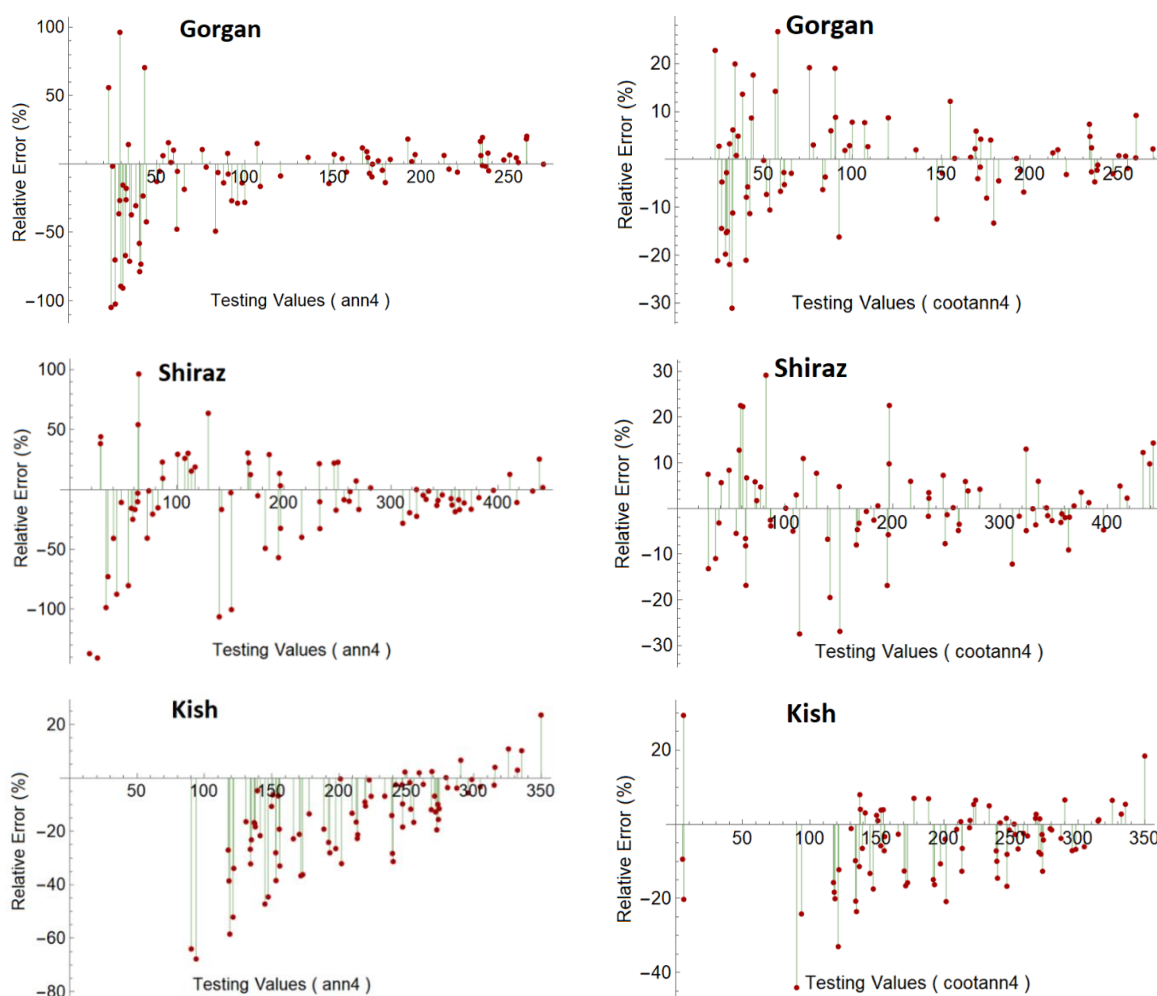
بهترین مدل برای سناریوی چهارم مدل هیبریدی کوت معادل ۱۸/۸۸ به دست آمد. در ایستگاه سینوپتیک کیش نیز بهترین مدل، سناریوی چهارم مدل هیبریدی کوت معادل برابر ۱۷/۶۵



شکل ۶- دیاگرام تیلور برای مرحله آزمون (الف: ایستگاه گرگان، ب: ایستگاه شیراز، ج: ایستگاه کیش)  
Figure 6- Taylor diagram for testing phase (a: Gorgan, b: Shiraz, c: Kish)

است. این الگوریتم با استفاده از ترکیب وزن دار توابع هدف نتایج بهتری را نشان داد و در مقایسه با سایر الگوریتم‌های بهینه‌سازی و کنترل‌کننده‌های معمولی، عملکرد بهتری دارد. در پژوهش دیگری Sheng et al. (2023) الگوریتم کوت را به‌منظور کاهش آلاینده‌های محیط زیستی توزیع سیستم قدرت واحدهای تولید حرارتی و نیروگاه‌های بادی و نیروگاه‌های فتوولتائیک پیشنهاد داده است. طبق نتایج ارائه شده، الگوریتم مذکور توانسته هدف‌های مربوط به هزینه عملیاتی و کاهش آلودگی را به‌طور قابل‌توجهی کاهش و موجب بهبود پایداری، اقتصادی و تمیزی عملکرد سیستم‌های فوق شود. نتایج این پژوهش نشان داد که استفاده از الگوریتم کوت همراه با شبکه عصبی مصنوعی، به‌عنوان یک بهینه‌ساز مناسب، باعث افزایش دقت در مدل‌سازی فرآیند تبخیر در ایستگاه‌های سینوپتیک با اقلیم‌های مختلف شده است.

در شکل ۷، نمودارهای خطای نسبی مشاهده می‌شود. خط وسط که از صفر عبور می‌کند خط مرجع است که نشان‌دهنده پیش‌بینی دقیق مدل است. هرچه فاصله نقاط از این خط بیشتر باشد، خطای نسبی مدل بیشتر است. تعداد نقاط مشخص شده نشان‌دهنده تعداد داده‌های مربوط به قسمت صحت‌سنجی (۸۲ عدد) است و محور عمودی درصد خطا را تعیین کرده است. بنابراین، مطابق شکل ۷، بعد از ادغام الگوریتم کوت با شبکه عصبی مصنوعی خطای ایستگاه گرگان از ۱۰۰ و -۱۰۰ به ۳۰ و -۳۰، خطای ایستگاه شیراز از ۱۰۰ و -۱۰۰ به ۳۰ و -۳۰ و خطای ایستگاه کیش از ۲۰ و -۸۰ به ۳۰ و -۴۰ رسیده است. بنابراین، می‌توان نتیجه گرفت که الگوریتم کوت توانسته است شبکه عصبی را بهبود ببخشد. در تأیید نتایج این پژوهش، Begum (2023) در مطالعه‌ای به‌منظور کنترل دمای راکتورهای مخزنی از الگوریتم بهینه‌سازی کوت استفاده کرده



شکل ۷- نمودارهای خطای نسبی برای هر سه ایستگاه سینوپتیک در مرحله صحت‌سنجی

Figure 7- Relative Error Percent plots for three stations in the testing phase

داده‌های ورودی دمای کمینه، دمای بیشینه، ساعت آفتابی، رطوبت نسبی و سرعت باد دقت و عملکرد بهتری در هر سه ایستگاه سینوپتیک دارد و این یعنی وجود تمام متغیرها در کنار هم از اهمیت زیادی برخوردار است. به‌طورکلی یافته‌های مطالعه حاضر نشان داد الگوریتم پرندۀ کوت یک الگوریتم قدرتمند و کارآمد است و می‌تواند در هر اقلیمی سیستم شبکه عصبی مصنوعی را بهبود دهد و یک مدل هیبریدی با دقت بیشتر و خطای کمتر برای مدل‌سازی تبخیر ارائه کند. توصیه می‌شود کارایی این الگوریتم در هیبرید با روش‌های عصبی مصنوعی در زمینه‌های مختلف بیشتر آزمون شود تا نتایج حاصله از قطعیت و اطمینان بیشتری برخوردار باشد.

#### سپاسگزاری

مطالعه حاضر بخشی از یک پایان‌نامه است و اطلاعاتی که در این مقاله از آن‌ها استفاده شده با همکاری سازمان هواشناسی

#### ۴- نتیجه‌گیری

با در نظر گرفتن اهمیت میزان تبخیر در طبیعت، کشاورزی و سیستم‌های مدیریت منابع آب، مطالعه‌ای باهدف بررسی عملکرد مدل شبکه عصبی مصنوعی مبتنی بر الگوریتم پرندۀ کوت که یک الگوریتم جدید الهام گرفته از طبیعت است صورت گرفت. برای این پژوهش از داده‌های هواشناسی ماهانه سه ایستگاه سینوپتیک با اقلیم‌های متفاوت در کشور ایران استفاده شده است. در این راستا برای هر مدل ۷۰ درصد داده‌ها (۸۲ عدد) برای مرحله آموزش و ۳۰ درصد داده‌ها (۸۲ عدد) برای مرحله آزمون انتخاب و با استفاده از چهار حالت مختلف در ترکیب متغیرهای ورودی مستقل که با توجه به ماتریس همبستگی آن‌ها انتخاب شده بودند، طراحی سناریوها برای انتخاب داده‌های ورودی صورت گرفت. با توجه به این که مدل شبکه عصبی به‌تنهایی مدل دقیقی است. اما با مقایسه معیارهای ارزیابی می‌توان نتیجه گرفت که سناریوی چهارم از مدل هیبریدی شبکه عصبی و الگوریتم کوت (COOT-ANN4) با



## منابع

- خاری، دانیال، آگدرنژاد، اصلان، و ابراهیمی پاک، نیازعلی (۱۴۰۲). مقایسه مدل‌های هوش مصنوعی و مدل‌های تجربی در برآورد تبخیر و تعرق مرجع (مطالعه موردی: ایستگاه سینوپتیک رامهرمز). *مدل‌سازی و مدیریت آب و خاک*، ۳(۲)، ۱۱۲-۱۲۴. doi:10.22098/mmws.2022.11293.1117
- طالبی، حامد، صمدیان فرد، سعید، و ولیزاده کامران، خلیل (۱۴۰۲). روش جدید مبتنی بر تصاویر ماهواره لندست ۸ و سنجنده مادیس برای تخمین تبخیر و تعرق مرجع ماهانه در دو اقلیم خشک و نیمه‌خشک. *مدل‌سازی و مدیریت آب و خاک*، ۳(۳)، ۱۸۰-۱۹۵. doi:10.22098/MMWS.2023.12048.1198
- ملک احمدی، حسین، میرزانیان احسان، خسروی، سپیده، و ابراهیم‌زاده، علی (۱۴۰۱). مدل‌سازی فرآیند تبخیر-تعرق روزانه با استفاده از مدل‌های رگرسیونی و هوشمند. *پژوهش آب ایران*، ۱۶(۱)، ۴۹-۶۲. doi:10.22034/iwrj.2022.10026.2338
- میرزانیان احسان، ملک احمدی، حسین، شاه محمدی، یادگار، و ابراهیم‌زاده، علی (۱۴۰۰). تأثیر موجک بر افزایش دقت مدل‌های تخمینی در مدل‌سازی بارش-رواناب (مطالعه موردی: حوضه صوفی چای). *مدل‌سازی و مدیریت آب و خاک*، ۱(۳)، ۶۷-۷۹. doi:10.22098/MMWS.2021.9335.1035

## References

- Ahi, Y., Coşkun Dilcan, Ç., Köksal, D.D., & Gültaş, H. T. (2022). Reservoir evaporation forecasting based on climate change scenarios using artificial neural network model. *Water Resources Management*, 37, 2607-2624. doi:10.1007/s11269-022-03365-0
- Arya Azar, N., Kardan, N., & Ghordoyee Milan, S. (2021). Developing the artificial neural network-evolutionary algorithms hybrid models (ANN-EA) to predict the daily evaporation from dam reservoirs. *Engineering with Computers*, 39, 1375-1393. doi:10.1007/s00366-021-01523-3
- Ashrafzadeh, A., Ghorbani, M.A., Biazar, S.M., & Yaseen, Z.M. (2019). Evaporation process modelling over northern Iran: application of an integrative data-intelligence model with the krill herd optimization algorithm. *Hydrological Sciences Journal*, 64(15), 1843-1856. doi:10.1080/02626667.2019.1676428
- Begum, K.G. (2023). Coot bird optimization algorithm for the temperature control of continuous stirred tank reactor process. *Asia-Pacific Journal of Chemical Engineering*, 18(1), e2787. doi:10.1002/apj.2787
- Dong, L., Zeng, W., Wu, L., Lei, G., Chen, H., Srivastava, A.K., & Gaiser, T. (2021). Estimating the Pan Evaporation in Northwest China by Coupling CatBoost with Bat

کشور تهیه شده است؛ لذا نویسندگان مقاله از مسئولان محترم آن سازمان کمال قدردانی و تشکر را دارند.

## تضاد منافع نویسندگان

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

## دسترسی به داده‌ها

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

## مشارکت نویسندگان

فرناز عالم‌پور رجبی: انجام تحلیل‌های نرم‌افزاری/آماری، نگارش نسخه اولیه مقاله؛ محمدعلی قربانی: مفهوم‌سازی، راهنمایی، بازبینی مقاله، کنترل نتایج؛ اسماعیل اسدی: مشاوره، راهنمایی، ویرایش و بازبینی متن مقاله.

- Algorithm. *Water*, 13(3), 256. https://www.mdpi.com/2073-4441/13/3/256
- Ghorbani, M.A., Kazempour, R., Chau, K.W., Shamshirband, S., & Taherei Ghazvinei, P. (2018). Forecasting pan evaporation with an integrated artificial neural network quantum-behaved particle swarm optimization model: a case study in Talesh, Northern Iran. *Engineering Applications of Computational Fluid Mechanics*, 12(1), 724-737. doi:10.1080/19942060.2018.1517052
- Goyal, M.K., Bharti, B., Quilty, J., Adamowski, J., & Pandey, A. (2014). Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert Systems with Applications*, 41(11), 5267-5276. doi:10.1016/j.eswa.2014.02.047
- Huang, G., Wu, L., Ma, X., Zhang, W., Fan, J., Yu, X., Zeng, W., & Zhou, H. (2019). Evaluation of CatBoost method for prediction of reference evapotranspiration in humid regions. *Journal of Hydrology*, 574, 1029-1041. doi:10.1016/j.jhydrol.2019.04.085
- Khari, D., Egdernezhad, A., & Ebrahimpak, N.A. (2023). Comparison of artificial intelligence models and experimental models in estimating reference evapotranspiration (Case study: Ramhormoz synoptic station). *Water and Soil Management and Modeling*, 3(2), 112-124. doi:10.22098/mmws.2022.11293.1117. [In Persian]

- Malekhamadi, H., Mirzania, E., Khosravi, S., & Ebrahim Zadeh, A. (2022). Daily evapotranspiration modeling using regression and intelligent models (Case Study). *Iranian Water Research Journal*, 16(1), 49-62. doi:10.22034/iwrj.2022.10026.2338. [In Persian]
- Maroufpoor, S., Bozorg-Haddad, O., & Maroufpoor, E. (2020). Reference evapotranspiration estimating based on optimal input combination and hybrid artificial intelligent model: Hybridization of artificial neural network with grey wolf optimizer algorithm. *Journal of Hydrology*, 588, 125060. doi:10.1016/j.jhydrol.2020.125060
- Memarzadeh, G., & Keynia, F. (2021). A new optimal energy storage system model for wind power producers based on long short term memory and Coot Bird Search Algorithm. *Journal of Energy Storage*, 44, 103401. doi:10.1016/j.est.2021.103401
- Mirzania, E., Malek Ahmadi, H., Yadegar Shahmohammadi, Y., & Ebrahimzadeh, A. (2021). Impact of wavelet on accuracy of estimated models in rainfall-runoff modeling (Case study: Sufi Chay. *Water and Soil Management and Modeling*, 1(3), 67-79. doi:10.22098/MMWS.2021.9335.1035 [In Persian]
- Moazenzadeh, R., Mohammadi, B., Shamshirband, S., & Chau, K.W. (2018). Coupling a firefly algorithm with support vector regression to predict evaporation in northern Iran. *Engineering Applications of Computational Fluid Mechanics*, 12(1), 584-597. doi:10.1080/19942060.2018.1482476
- Mohammadi, B., Linh, N.T.T., Pham, Q.B., Ahmed, A.N., Vojteková, J., Guan, Y., Abba, S.I., & El-Shafie, A. (2020). Adaptive neuro-fuzzy inference system coupled with shuffled frog leaping algorithm for predicting river streamflow time series. *Hydrological Sciences Journal*, 65, 1738-1751. doi:10.1080/02626667.2020.1758703
- Naruei, I., & Keynia, F. (2021). A new optimization method based on COOT bird natural life model. *Expert Systems with Applications*, 183, 115352. doi:10.1016/j.eswa.2021.115352
- Nourani, V. (2017). An Emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology*, 544, 267-277. doi:10.1016/j.jhydrol.2016.11.033
- Sheng, W., Li, R., Yan, T., Tseng, M.L., Lou, J., & Li, L. (2023). A hybrid dynamic economics emissions dispatch model: Distributed renewable power systems based on improved COOT optimization algorithm. *Renewable Energy*, 204, 493-506. doi:10.1016/j.renene.2023.01.010
- Talebi, H., Samadianfard, S., & Kamran, K.V. (2023). A novel method based on Landsat 8 and MODIS satellite images to estimate monthly reference evapotranspiration in arid and semi-arid climates. *Water and Soil Management and Modeling*, 3(3), 180-195. doi: 10.22098/mmws.2023.12048.1198 [In Persian]
- Taylor K.E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research*, 106(7), 7183-7192. doi:10.1029/2000JD900719
- Zhao, X., Li, Y., Zhao, Z., Xing, X., Feng, G., Bai, J., Wang, Y., Qiu, Z., & Zhang, J. (2022). Prediction model for daily reference crop evapotranspiration based on hybrid algorithm in semi-arid regions of China. *Atmosphere*, 13(6), 922. <https://www.mdpi.com/2073-4433/13/6/922>