



Lorestan University

Online ISSN: 2717-2325

Journal of Geographical Studies of Mountainous Areasjournal homepage: <http://www.gsma.lu.ac.ir>

Research Paper

Forecasting Monthly Temperature using New Methods Based on Machine Learning in Different Climates of Iran

Fakhreddin Iranpour ^a, Jafar Masoompour Samakosh ^{b*}, Arash Azari ^c, Bahram Gharabaghi ^d

^a Ph.D Candidate in Climatology, Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran.

^{b*} Associate Professor, Department of Geography, Faculty of Literature and Humanities, Razi University, Kermanshah, Iran.

^c Associate Professor, Department of Water Engineering, Campus of Agriculture and Natural Resources, Razi University, Kermanshah, Iran.

^d Professor School of Engineering, University of Guelph, Guelph, ON N1G 2W1, Canada.

ARTICLE INFO

Article history:

Received: 07 April 2024;

Accepted: 17 July 2024

Available online 2

December 2024

Keywords:

Temperature Prediction,
Artificial Intelligence,
ORELM, Hybrid Models,
ELM.

ABSTRACT

Air temperature is one of the main components of hydroclimatology studies and a useful variable for planning and exploitation models of water resources. Obtaining reliable data to predict temperature changes in the coming years to use in meteorological and hydrological models is one of the most important challenges. In recent years, various prediction models have been able to be considered reliable solutions. Most of these models operate based on historical data and use artificial intelligence techniques. In this research, by using methods based on artificial intelligence such as hybrid methods, GA-ANN, ICA-ANN, PSO-ANN, and ELM and ORELM models, the best model for predicting monthly temperature data in different climates in Iran was tried. Ahvaz, Kermanshah, Mashhad, and Rasht stations) should be introduced over a statistical period of 58 years so that reliable results can be obtained by using them. The results showed that the output of the ORELM model has the best fit with the observational data with a correlation coefficient of 0.99 and also has the best and closest distribution of points around the 45-degree line, which is considered the most accurate model in this regard. Taylor's diagram was also used to ensure the accuracy of selecting the best model. The results showed that the closest point to the reference point is related to the ORELM method. Therefore, the ORELM model can be reliably used to predict the monthly temperature in different climates. This approach greatly helps the researchers in water and climatology use artificial intelligence to predict temperature changes with higher accuracy in the coming years and use them confidently in water resource planning models.

1. Introduction

Air temperature is one of the main components of hydroclimatology studies and a useful variable for planning and exploitation models of water resources. Obtaining reliable data to predict temperature changes in the coming years to use in meteorological and hydrological models is one of the most important challenges.

2. Methodology

The studied areas are Ahvaz, Kermanshah, Mashhad, and Rasht stations, located in different regions of Iran. The statistical period of the monthly temperature of the selected stations for the use of artificial intelligence models was from 1963 to 2020 (58 years), and all the available statistics were used to select the best model at each station. The aim of this research was to use artificial intelligence as an efficient tool to predict monthly temperatures. In this regard, GA-ANN, ICA-ANN,

*Corresponding Author.

Email Adresses: fa.iranpour@gmail.com (F. Iranpour), j.mclimate27@gmail.com (J. Masoompour Samakosh), a.azari@razi.ac.ir (A. Azari), bgharaba@uoguelph.ca (B. Gharabaghi).

To cite this article:

Iranpour, F., Masoompour Samakosh, J., Azari, A., Gharabaghi, B. (2024). Forecasting Monthly Temperature using New Methods Based on Machine Learning in Different Climates of Iran. *Journal of Geographical Studies of Mountainous Areas*, 5 (19), 53-70.



Doi: 10.22034/gsma.2024.719232

and PSO-ANN hybrid models and ELM and ORELM models were used to predict monthly temperatures. Then, considering 80% of the data as training data and 20% of the data as test data, the best model structure with a different number of inputs with the lowest error rate and the highest correlation coefficient with the observational data was obtained. RMSE, NRMSE, NASH, and R statistical indices were used to select the best model. Finally, Taylor's diagram was used to ensure the selection of the best model. This diagram introduces the best model with the lowest simulation error based on three indicators: standard deviation, correlation coefficient, and RMSE value.

3. Results

Among the models, the ORELM model showed the value of NRMSE in the test phase in the stations of Ahvaz, Kermanshah, Mashhad, and Rasht, respectively, 0.0378, 0.0461, 0.0523, and 0.0605, which has the highest accuracy. Taylor's diagram also confirmed this result by using more error criteria, and the ORELM model is confidently introduced as the best artificial intelligence model for predicting temperature changes in these 4 stations that represent 4 different climates. Based on the results, the ORELM model is more accurate than other models in the training and test stages with regard to all evaluation indicators. After that, the ELM model ranks second in terms of prediction accuracy.

4. Discussion

The possibility of predicting air temperature changes for a long-term period based on a low amount of information compared to atmospheric numerical models and using only monthly temperature data is one of the most important achievements of this research. In this study, monthly temperature changes are predicted based on artificial intelligence methods without the need for complex atmospheric parameters, without the need for complex atmospheric analysis maps and software, and without spending a lot of time and money calibrating and validating mathematical models. Considering the importance of knowing

temperature changes as one of the most important parameters of hydroclimatology balance, artificial intelligence models used in this research can be recommended, especially for areas without basic statistics or in situations where it is not possible to use mathematical models. Based on the results obtained, the models developed in this research can be proposed for other study areas with different climates.

5. Conclusion

Obtaining reliable data to predict temperature changes in the coming years to use in meteorological and hydrological models is one of the most important challenges. In recent years, various prediction models have been able to be considered reliable solutions. Most of these models operate based on historical data and use artificial intelligence techniques. In this research, by using methods based on artificial intelligence such as hybrid methods, GA-ANN, ICA-ANN, PSO-ANN, and ELM and ORELM models, the best model for predicting monthly temperature data in different climates in Iran was tried. Ahvaz, Kermanshah, Mashhad, and Rasht stations) should be introduced over a statistical period of 58 years so that reliable results can be obtained by using them. The results showed that the output of the ORELM model has the best fit with the observational data with a correlation coefficient of 0.99 and also has the best and closest distribution of points around the 45-degree line, which is considered the most accurate model in this regard. Taylor's diagram was also used to ensure the accuracy of selecting the best model. The results showed that the closest point to the reference point is related to the ORELM method. Therefore, the ORELM model can be reliably used to predict the monthly temperature in different climates. This approach greatly helps the researchers in water and climatology use artificial intelligence to predict temperature changes with higher accuracy in the coming years and use them confidently in water resource planning models.

Acknowledgments

Based on the author's statement, there is no funding support.



پیش بینی دمای ماهانه با استفاده از روش های جدید مبتنی بر یادگیری ماشین در اقلیم های مختلف ایران

فخرالدین ایران پور^۱؛ جعفر معصوم پور سماکوش^{۲*}؛ آرش آذری^۳؛ بهرام قره باغی^۴

^۱ دانشجوی دکتری اقلیم شناسی، گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران.

^{۲*} دانشیار گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه رازی، کرمانشاه، ایران.

^۳ دانشیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه رازی، کرمانشاه، ایران.

^۴ استاد دانشکده مهندسی، دانشگاه گلف، گلف، کانادا.

چکیده	اطلاعات مقاله
دمای هوا از اجزای اصلی مطالعات هیدروکلیماتولوژی، و متغیری کاربردی برای مدل های برنامه ریزی و بهره برداری از منابع آب است. دستیابی به داده های قابل اعتماد برای پیش بینی تغییرات دمایی در سال های آتی به منظور کاربرد آن در مدل های هواشناسی و هیدرولوژیکی از مهم ترین چالش ها است. طی سالیان اخیر، مدل های پیش بینی مختلفی توانسته اند به عنوان یک راهکار قابل اطمینان مورد توجه قرار گیرند. اکثر این مدل ها بر اساس داده های تاریخی و با بهره گیری از تکنیک های هوش مصنوعی عمل می کنند. در تحقیق حاضر با استفاده از روش های مبتنی بر هوش مصنوعی مانند روش های هیبرید PSO-ANN، ICA-ANN، GA-ANN و مدل های ORELM، ELM سعی شد بهترین مدل برای پیش بینی دمای ماهانه در اقلیم های مختلف ایران (۱۰ ایستگاه های اهواز، کرمانشاه، مشهد و رشت) در یک دوره آماری ۵۸ ساله معرفی گردد، تا بتوان با استفاده از آن به نتایج قابل اعتمادی دست پیدا کرد. نتایج نشان داد که خروجی مدل ORELM دارای بهترین برازش با داده های مشاهداتی با ضریب همبستگی ۰/۹۹ بوده، و همچنین دارای بهترین و نزدیک ترین پراکندگی نقاط در اطراف خط ۴۵ درجه می باشد که از این نظر دقیق ترین مدل محسوب می شود. برای اطمینان از صحت انتخاب مدل برتر از نمودار تیلور نیز استفاده شد. نتایج نشان داد که نزدیک ترین نقطه به نقطه مرجع مربوط به روش ORELM می باشد. لذا برای پیش بینی دمای ماهانه در اقلیم های مختلف می توان با اطمینان از مدل ORELM استفاده کرد. این رویکرد کمک زیادی به محققین بخش آب و هواشناسی می کند تا با استفاده از هوش مصنوعی، تغییرات دمایی را با دقت بالاتری در سال های آتی پیش بینی نموده و با اطمینان در مدل های برنامه ریزی منابع آب استفاده نمایند.	دریافت مقاله: ۱۴۰۳/۰۱/۱۹ پذیرش نهایی: ۱۴۰۳/۰۴/۲۷ تاریخ انتشار: ۱۴۰۳/۰۹/۱۲
	واژگان کلیدی: پیش بینی دما، هوش مصنوعی، ORELM، مدل های هیبریدی، ELM.

* نویسنده مسئول

پست الکترونیک نویسندگان: fa.iranpour@gmail.com (ف، ایران پور)؛ j.mclimate27@gmail.com (ج، معصوم پور سماکوش)؛ a.azari@razi.ac.ir

(آ، آذری)؛ bgharaba@uoguelph.ca (ب، قره باغی).

نحوه استناد به مقاله: ایران پور، فخرالدین، معصوم پور سماکوش، جعفر، آذری، آرش، قره باغی، بهرام. (۱۴۰۲). پیش بینی دمای ماهانه با استفاده از روش های جدید

مبتنی بر یادگیری ماشین در اقلیم های مختلف ایران. فصلنامه مطالعات جغرافیایی مناطق کوهستانی. سال سوم، شماره ۵ (۱۹)، صص ۵۳-۷۰.



۱. مقدمه

امروزه یکی از مسائل مهم در زمینه تغییر اقلیم، گرمایش جهانی می‌باشد. گرمایش جهانی به پدیده‌ای اطلاق می‌شود که باعث بالارفتن میانگین دمای زمین و سطح اقیانوس‌ها شده است (IPCC, 2013). توسعه صنایع و کارخانه‌ها از یک سو و جنگل‌زدایی و تخریب محیط زیست از سوی دیگر، منجر به رشد میزان گازهای گلخانه‌ای در چند دهه اخیر شده است. این عامل خود منجر به افزایش دما در سطح زمین شده است. از جمله دیگر پیامدهای منفی این افزایش، بروز تغییرات چشمگیر در وضعیت آب‌وهوایی می‌باشد که از آن جمله می‌توان به شدت یافتن خشکسالی‌ها، سیلاب‌ها و پدیده‌های حدی در بخش‌های مختلف زمین در طی سال‌های اخیر اشاره نمود (Aghakhani Afshar et al, 2017: 218). بر اساس گزارش هیأت بین‌الدول تغییر اقلیم، تغییر اقلیم ناشی از گرمایش جهانی باعث پدید آمدن تغییرات در رژیم هیدرولوژی در سطح جهان شده است. این تغییرات در سال‌های اخیر بیشتر شامل تغییر در میزان بارش بوده است. بطوری که بارندگی و جریان‌های سطحی در عرض‌های جغرافیایی بالا و میانی بیشتر و در عرض‌های پایینی کمتر شده و احتمال رویارویی با سیلاب و خشکسالی افزایش یافته است (IPCC, 2001). بر همین اساس، پیش‌بینی و ارزیابی پارامترهای موثر جوی اعم از دما و بارش می‌تواند نقش موثری در تصمیم‌گیری درست انسان در آینده داشته باشد. در واقع با شناخت بهتر انسان نسبت به اقلیم می‌توان گفت تصمیماتش صحیح‌تر و دستیابی به اهدافش زودتر انجام می‌گیرد (Aghakhani Afshar et al, 2017: 218).

ارزیابی دقت پارامتر اقلیمی همچون دما، که نسبت به پدیده‌های اقلیمی دیگر از پیچیدگی رفتاری چشمگیرتری برخوردار است، اهمیت بیشتری دارد. اهمیت بررسی این پارامتر زمانی آشکارتر می‌شود که بدانیم کشور ایران به دلیل وسعت زیاد و تغییرات زیاد ارتفاعی، از جمله مناطقی است که دارای رفتار ناهنجار و بی‌قاعده در دما است. لذا برآورد مناسب دما می‌تواند مبنایی مناسب برای برنامه‌ریزی‌ها در آینده باشد (Masoodian, 2004: 90).

اهمیت بالای پیش‌بینی تغییرات دما و یافتن راه حلی مناسب جهت پیش‌بینی آن همواره مورد توجه محققان بوده است. بطوری که در دهه اخیر بخش قابل توجهی از پژوهش‌های آنها معطوف به بررسی این پدیده بوده است. از جمله این تلاش‌ها می‌توان به بهره‌گیری

محققان از روش‌های تجربی (Jusuf and Wong, 2009)، تحلیلی (Swaid and Hoffman, 1990)، مدل‌های منطقه‌ای (Inard et al, 1996) و همچنین بهره‌گیری از هوش مصنوعی (Alizamir et al, 2020; Feigl et al, 2021; Azari et al, 2022) اشاره کرد. از جمله پیشروترین روش‌ها در زمینه پیش‌بینی یک پدیده، بهره‌گیری از هوش مصنوعی می‌باشد. این روش‌ها بدلیل سهولت در بکارگیری و کاهش حداکثری خطا با حذف روابط، جزو دقیقترین روش‌های پیش‌بینی دسته‌بندی می‌شوند (Feigl et al, 2021: 2953). بعلاوه، بهره‌گیری از روش‌های استوکاستیک (Zeynoddin et al, 2020; Ebtehaj et al, 2020; Azari et al, 2021) و تلفیق آن با روش‌های مبتنی بر هوش مصنوعی مانند GMDH، ELM، ORELM و روش‌های هیبرید برای پیش‌بینی پارامترهای هیدروکلیماتولوژی مانند دما، بارندگی، جریان رودخانه‌ها و تغییرات تراز آب مخازن سطحی و آب زیرزمینی در سال‌های اخیر بصورت گسترده‌ای استفاده شده است (Ebtehaj et al, 2016; Zeynoddin et al, 2018; Soltani et al, 2021; Esmaili et al., 2021). Masoompoor Samakoosh et al (2022) در پیش‌بینی خشکسالی غرب ایران نیز نشان دادند که الگوریتم ژنتیک بهترین عملکرد را نسبت به سایر روش‌های استفاده شده دارد.

از همین رو، بهره‌گیری از روش‌های هوش مصنوعی به منظور پیش‌بینی دما بعنوان یک روش کارآمد و قابل اتکا مورد قبول واقع شده است (Salcedo-Sanz et al, 2016; Zhang et al, 2017; Alizamir et al, 2020; Feigl et al, 2021; Azari et al, 2022). Azari et al (2022) در تحقیق خود پیرامون کارایی روش‌های یادگیری ماشین در پیش‌بینی دما نشان دادند که بهره‌گیری از نوع روش‌ها نتایج قابل اتکایی را به دست خواهد داد. نتایج نشان داد که مدل‌های مبتنی بر شبکه عصبی مصنوعی دارای توانایی بالاتری در مدلسازی و پیش‌بینی آینده دمای هوا در مقایسه با سایر روش‌ها هستند. Roy (2020)، از سه شبکه عصبی مصنوعی عمیق به نام‌های LSTM، MLP، و ترکیبی CNN-LSTM برای پیش‌بینی دمای هوای یک تا ده روز آینده بهره برد. ورودی‌های مدل در این پژوهش شامل سرعت باد، بارش، عمق برف و میانگین، حداکثر و حداقل دمای هفت روز گذشته بودند. نتایج نشان داد که این مدل‌ها توانایی کافی برای پیش‌بینی دما را دارا می‌باشند و از بین آنها مدل ترکیبی CNN-LSTM نسبت به سایر مدل‌ها بهتر

هدف از این تحقیق استفاده از هوش مصنوعی به عنوان ابزاری کارآمد برای پیش‌بینی دمای ماهانه است. در این راستا از مدل‌های هیبرید GA-ANN، ICA-ANN و PSO-ANN و مدل‌های ELM و ORELM برای پیش‌بینی دمای ماهانه استفاده خواهد شد. سپس با در نظر گرفتن ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد داده‌ها به عنوان داده‌های آزمایش^۲ و نتایج آن مورد مقایسه قرار خواهد گرفت.

۲. روش تحقیق

۲.۱. معرفی محدوده مورد مطالعه


محدوده مورد مطالعه، ایستگاه‌های اهواز، کرمانشاه، مشهد و رشت، واقع در اقلیم‌های مختلف ایران است (شکل ۱). دوره آماری دمای ماهانه ایستگاه‌های منتخب جهت بکارگیری مدل‌های هوش مصنوعی از ۱۹۶۳ تا ۲۰۲۰ (۵۸ سال) بود که برای انتخاب بهترین مدل در هر ایستگاه از تمامی آمار موجود استفاده شد.

۲.۲. مدل‌های هوش مصنوعی

همانطور که گفته شد برای کاهش زمانی محاسبات و پرهیز از پردازش حجم اطلاعات زیاد و با توجه به پیچیدگی‌های مدل‌های ریاضی، در این مطالعه از مدل‌های مبتنی بر هوش مصنوعی برای پیش‌بینی سری زمانی دمای ماهانه ایستگاه‌های منتخب استفاده شده است. تغییرات دمای ماهانه در هر یک از این ایستگاه‌ها در طول دوره مطالعاتی در شکل (۲) ارائه شده است.

عمل کرده است. این مدل‌های مبتنی بر یادگیری ماشین، همچنین توانایی مدل‌سازی دما در اقلیم‌های مختلف را هم دارا می‌باشند. بطور مثال، در پژوهشی که بمنظور مدل‌سازی دما در مناطق کوهستانی کشور ارمنستان صورت پذیرفت، نتایج نشان داد که این مدل‌ها توانایی قابل ملاحظه‌ای برای شبیه‌سازی دما در این دست مناطق را دارا می‌باشند. این پژوهش با هدف یافتن تکنیک پیش‌بینی آب و هوا بر اساس روش‌ها و رویکردهای یادگیری ماشینی و بهبود پیش‌بینی دمای ساعتی هوا تا ۲۴ ساعت در دره آرارات (ارمنستان) صورت پذیرفت و از داده‌های چندین ایستگاه هواشناسی و مجموعه داده‌های ماهواره‌ای بعنوان ورودی مدل شبکه‌های عصبی متعدد استفاده شد (Astsatryan et al, 2021: 711).


بررسی تحقیقات انجام شده نشان می‌دهد در اکثر مدل‌های هیدرولوژیکی و هواشناسی بکار گرفته شده برای پیش‌بینی تغییرات اقلیمی و هیدرولوژیکی و بیلان آب در آینده در حوضه‌های آبریز، پارامتر دما اهمیت ویژه‌ای دارد. به دلیل حجم زیاد آمار و اطلاعات مورد نیاز، مدل‌های عددی پیش‌بینی دما و همچنین لزوم انجام فرآیند واسنجی و صحت‌سنجی در مدل‌های جوی که فرآیندی بسیار وقت گیر و پیچیده است، استفاده از یک روش جایگزین که در مقایسه با مدل‌های ریاضی بتواند با همان دقت و در زمان کمتر و با استفاده از داده‌ها و اطلاعات ناچیز تغییرات دمایی را پیش‌بینی نماید بسیار حائز اهمیت است. از طرفی در بسیاری از مناطق اطلاعات کافی برای تحلیل‌های جوی پیش‌بینی تغییرات دمایی وجود ندارد یا از دقت کافی برخوردار نیست.



شکل ۱. موقعیت ایستگاه‌های مورد مطالعه برای مدل‌سازی هوش مصنوعی، منبع: (نگارنگان، ۱۴۰۲)

^۲ - test

^۱ - train





شکل ۲. تغییرات دمای ماهانه (°C) در هر یک از ایستگاه‌های مورد مطالعه، منبع: (نگارنگان، ۱۴۰۲)

$$NRMSE = \frac{RMSE}{(X_{Max}^{obs} - X_{Min}^{obs})} \quad (2)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2}{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2} \quad (3)$$

$$R = \frac{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})(X_i^{sim} - X_{Mean}^{sim})}{\sqrt{\sum_{i=1}^n (X_i^{obs} - X_{Mean}^{obs})^2 \sum_{i=1}^n (X_i^{sim} - X_{Mean}^{sim})^2}} \quad (4)$$

در این روابط، X_i^{obs} داده مشاهداتی، X_i^{sim} داده پیش‌بینی شده توسط مدل، X_{Mean}^{obs} و X_{Mean}^{sim} به ترتیب میانگین داده مشاهده‌ای و مدل‌سازی شده و n تعداد داده‌ها را نشان می‌دهد.

۳.۲. ماشین آموزش نیرومند^۴

ماشین آموزش نیرومند (ELM) یک شبکه عصبی پیش‌خور^۴ تک لایه بوده و توسط Huang et al (2004; 2006) ارائه شده است. ELM وزن‌های ورودی را به صورت تصادفی، و وزن‌های خروجی را به صورت تحلیلی^۵ تعیین می‌کند. ساختار کلی این الگوریتم در شکل (۳ الف) ارائه شده است. تنها تفاوت ELM با شبکه عصبی پیش‌خور تک لایه^۶ (SLFFNN)، عدم استفاده از بایاس^۷ برای نرون خروجی است. نرون‌های لایه ورودی با همه

پس از تنظیم اطلاعات مورد نیاز و در نظر گرفتن داده‌های دما در ماه‌های قبل با تاخیرهای ۱، ۲، ۳، ۶ و ۱۲ ماهه $t-1$ ، $t-2$ ، $t-3$ ، به عنوان لایه‌های ورودی و داده‌های دمای ماهانه در ماه حاضر (t)، از مدل‌های هیبرید ICA-، GA-ANN و PSO-ANN و مدل‌های ELM و ORELM برای پیش‌بینی دمای ماهانه در ایستگاه‌های مورد مطالعه استفاده شد. با در نظر گرفتن ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد داده‌ها به عنوان داده‌های آزمایش، بهترین ساختار مدل با تعداد مختلف ورودی با کمترین میزان خطا و بیشترین ضریب همبستگی با داده‌های مشاهداتی بدست آمد. برای انتخاب بهترین مدل از شاخص‌های آماری RMSE، NRMSE، Nash و R استفاده شد که در روابط (۱) تا (۴) نشان داده شده‌اند. در نهایت برای اطمینان از انتخاب درست مدل برتر از دیاگرام تیلور استفاده شد. این دیاگرام بر اساس سه شاخص انحراف معیار، ضریب همبستگی و مقدار RMSE، بهترین مدلی را که دارای کمترین خطای شبیه‌سازی است معرفی می‌کند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^{obs} - X_i^{sim})^2} \quad (1)$$

⁴ feed-forward

⁵ Analytical

⁶ single layer feed forward neural network

⁷ bias

^۱- train


^۲- test

³ Extreme Learning Machine (ELM)

از توابع فعال سازی به منظور محاسبه خروجی پاسخ نرون ها استفاده می شود. زمانی که مجموعه ای از سیگنال ورودی وزن دار اعمال شده، برای بدست آوردن پاسخ از توابع فعال سازی استفاده می شود (Pandey & Govind, 2016: 24). توابع فعال سازی غیر خطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله ای (hardlim)، سیگموید^۳ (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است که به صورت شکل (۳) تعریف می شوند.

فعال سازی نرون های لایه مخفی برای هر نمونه آموزشی در یک شبکه ELM با تعداد "j" نرون در لایه مخفی، "i" نرون ورودی و تعداد "k" نمونه آموزشی، از رابطه زیر محاسبه می شود:

$$H_{jk} = g(\sum (W_{ji} X_{ik}) + B_j) \quad (۷)$$



شکل ۳. الف- ساختار شبکه ELM ب- توابع فعال سازی مختلف در مدل ELM، منبع: (Ebtehaj et al. 2016)

همه نرون های لایه مخفی برای نمونه های مورد استفاده در آموزش توسط این ماتریس ارائه می شود. در این ماتریس j ستون و k ردیف است. ماتریس H به عنوان ماتریس لایه مخفی خروجی شبکه عصبی بیان می شود. وزن های بین نرون های لایه مخفی و خروجی با استفاده از برازش حداقل مربعات برای مقادیر هدف در حالت آموزش در برابر خروجی های نرون های لایه مخفی برای هر نمونه آموزشی،

نرون های لایه مخفی در ارتباط است. تابع فعال سازی نرون های مخفی می تواند به صورت تابع پیوسته تکه ای باشد، در حالی که برای نرون لایه خروجی به صورت خطی است. مدل ELM از الگوریتم های مختلفی جهت محاسبه وزن ها و بایاس ها استفاده می کند که در نتیجه کاهش قابل توجه زمان آموزش شبکه را به همراه دارد. توصیف ریاضی شبکه عصبی پیشخور تک لایه با تعداد n گره مخفی، به صورت زیر بیان می شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (۵)$$

که β_i وزن بین گره مخفی i ام و گره خروجی، $(a_i \in R^n)$ و b_i فاکتورهای آموزش گره های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعال سازی $g(x)$ (که دارای انواع مختلفی می باشد) برای گره مخفی افزاینده^۲ $G(a_i, b_i, x)$ را می توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (۶)$$

که $g(.)$ می تواند هر تابع فعال سازی غیر خطی پیوسته باشد. وزن نرون ورودی i ام و نرون لایه مخفی j ام، B_j ، بایاس نرون لایه مخفی j ام، X_{ik} ورودی نرون ورودی برای k امین نمونه آموزشی، و H_{ik} ماتریس فعال سازی j امین نرون لایه مخفی برای k امین نمونه آموزشی است، بطوریکه فعال سازی

³ sigmoid

¹ piecewise continuous function

² additive

لونبرگ-مارکوآردت^۱ که در آن هیچ نوع روالی از بهینه سازی غیر خطی را در بر نمی گیرد، برخوردار است. بنابراین زمان آموزش شبکه به طور قابل توجهی کاهش می یابد (Huang et al, 2006: 491).

۴.۲. ماشین آموزش نیرومند با داده های پرت^۲

به منظور مدل سازی با استفاده از مدل های مبتنی بر هوش مصنوعی، همیشه داده هایی به صورت outlier وجود دارند و به دلیل اینکه عموماً وجود چنین نمونه هایی در بسیاری از موارد به طبیعت موجود در مساله برمیگردد، امکان حذف آنها وجود ندارد. بنابراین، درصدی از کل خطای آموزش (e) را شامل می شود. به منظور برخورد با چنین داده هایی، وجود outliers با sparsity تعریف می شود. Mohammed et al (2023) با دانش اینکه استفاده از l_0 -norm، sparsity را نسبت به l_2 -norm بهتر منعکس می کند، جهت محاسبه ماتریس وزن خروجی (β)، به جای استفاده از l_2 -norm، خطای آموزش (e) را به گونه ای در نظر می گیرند که sparse باشد.

$$\min C\|e\|_0 + \|\beta\|_2^2 \text{ subject to } y - H\beta = e$$

$$\beta = [\beta_1, \dots, \beta_N]^T \quad (14)$$

(β)، ماتریس وزنه های خروجی است (w_o یا همان w_{output} است).

(یا در برخی منابع به این شکل نوشته می شود (w_o) ماتریس وزن های خروجی است):

$$\min_{w_o} C\|e\|_0 + \|w_o\|_2^2 \text{ subject to } T - Hw_o \quad (15)$$

رابطه فوق یک مساله برنامه نویسی غیرمحدب^۳ است. یکی از ساده ترین راه ها جهت حل این مساله، نوشتن آن به صورت یک مساله محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی است. ترم پراکنده یا sparse با استفاده از l_1 -norm بدست می آید. جایگذاری l_0 -norm با l_1 -norm، نه تنها منجر به حداقل سازی تحدب^۴ (کم شدن تابع خطا)

بکار برده می شود که معادل ریاضی آن را می توان به شکل زیر بیان کرد:

$$H\beta = T \quad (8)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (9)$$

که β نشان دهنده وزن بین نرون لایه خروجی و نرون های لایه مخفی است و T بردار نشان دهنده مقادیر هدف برای نمونه های آموزش است که به صورت رابطه (۱۰) بیان می شود:

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (10)$$

نهایتاً وزن ها را می توان از رابطه (۱۱) محاسبه کرد:

$$\beta = HT \quad (11)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (12)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \text{ and } T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (13)$$

که $\tilde{a} = a_1, \dots, a_L; \tilde{b} = b_1, \dots, b_L; \tilde{x} = x_1, \dots, x_L$ بردار وزن بین نرون های لایه های مخفی و لایه پنهان و H' شبه معکوس Moore-Penrose ماتریس H است. T بردار بین وزن های نمونه های آموزشی است. با توجه به توضیحات ارائه شده می توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن ها و بایاس ها به نرون های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه های آموزشی مختلف. روند آموزش جهت پیدا کردن ماتریس لایه پنهان (H)، سریع است بطوریکه از سرعت بالاتری نسبت به الگوریتم های مبتنی بر تکرار رایج مانند

^۳non-convex programming

^۴minimization convex

^۱ Levenberg-Marquardt

^۲ Outlier Robust Extreme Learning Machine (ORELM)

داشتن n نورون درون لایه پنهان، نیاز به n تا مجموعه وزن-های $(W_1, W_2, \dots, W_n)$ دارید تا بتوان عملیات ضرب وزن‌ها در ورودی‌های X انجام شود. برای پیش‌بینی دقیق خروجی مدل، باید وزن‌های شبکه در تمام لایه‌ها اصلاح شده، و مقادیر بهینه آنها بدست آید. به منظور آموزش شبکه و اصلاح وزن‌ها تا رسیدن به یک خطای معنادار، روش‌های بسیار زیادی وجود دارد. یکی از روش‌های موثر در این زمینه، ترکیب مدل MLP با الگوریتم بهینه‌سازی در قالب یک مدل هیبرید است. در این تحقیق از سه مدل هیبرید GA-ANN، ICA-ANN و PSO-ANN استفاده شده است. در ساختار این مدل‌ها، وزن‌های بهینه توسط الگوریتم‌های بهینه‌سازی ژنتیک و رقابت استعماری بدست می‌آیند. تابع هدف در این مدل‌ها کمینه‌سازی مقدار RMSE می‌باشد. تولید و اصلاح وزن‌ها در ساختار مدل تا رسیدن به کمترین خطا ادامه می‌یابد و تعداد تکرار الگوریتم بر این اساس تنظیم می‌شود.

۳. یافته‌های پژوهش

۳.۱. پیش‌بینی دمای ماهانه بر اساس هوش مصنوعی

در این مطالعه از روش‌های مبتنی بر شبکه‌های عصبی مصنوعی برای پیش‌بینی سری زمانی دمای ماهانه در اقلیم‌های مختلف ایران استفاده شده است تا بتوان قابلیت استفاده از این روش‌ها را برای پیش‌بینی دما که یکی از پارامترهای مهم اقلیمی است بررسی کرد. این امر برای مناطقی که شرایط مطلوب برای به کارگیری مدل‌های عددی پیچیده برقرار نیست و یا اینکه اطلاعات کافی در دسترس نیست بسیار حائز اهمیت است. بطوری که بتوان بر اساس تعداد ورودی‌های بسیار اندک، سری زمانی دمای ماهانه را بتوان با دقت زیاد پیش‌بینی نمود.

با توجه به اهداف این تحقیق، در تمامی روش‌های هوش مصنوعی و مدل‌های هیبرید از داده‌های دمای ماهانه در ماه‌های قبل (t-1, t-2, t-3, t-6, t-12) به عنوان داده‌های

می‌شود بلکه وجود مشخصات پراکندگی یا وجود وقایع حادی (داده‌های نادر) را نیز تضمین می‌کند.

$$\min \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 \text{ subject to } y - H\beta = e \quad (16)$$

رابطه (۱۶) یک مساله بهینه‌سازی محدب مقید^۱ است به طوری که به طور کامل دامنه مناسب رویکرد تکمیل شده ضرب لاگرانژی^۲ را تطبیق می‌کند.

$$L_\mu(e, \beta, \lambda) = \|e\|_1 + \frac{1}{c} \|\beta\|_2^2 + \lambda^2 (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (17)$$

که $\mu = \frac{2N}{\|y\|_1}$ (Yang & Zhang, 2011: 253) بر پارامتر جریمه^۳ دلالت دارد و $\lambda \in R^n$ بردار ضرب لاگرانژی است. جواب بهینه (e, β) و بردار ضرب لاگرانژی (λ) با استفاده از حداقل سازی تابع زیر طی فرایند تکراری، بدست می‌آید.

$$\left\{ \begin{array}{l} (e_{k+1}, \beta_{k+1}) = \arg \min_{e, \beta} L_\mu(e, \beta, \lambda) \quad (a) \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) \quad (b) \end{array} \right. \quad (18)$$

۲.۵. مدل‌های هیبرید GA-ANN ICA-ANN و PSO-ANN

یکی از ساده‌ترین و کارآمدترین روش‌های پیشنهادی برای استفاده در طراحی شبکه‌های عصبی، مدل پرسپترون چند لایه^۴ (MLP) می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد. برخلاف شبکه‌های عصبی پرسپترون تک لایه، شبکه‌های چندلایه می‌توانند برای یادگیری مسائل غیرخطی و همچنین مسائلی با تصمیم‌گیری‌های متعدد بکار روند. اگر مجموعه داده دارای m ویژگی باشد بنابراین در شبکه‌های عصبی، لایه ورودی نیز دارای m نورون است و از این رو نیاز به n تا وزن W نیز هست که در ورودی‌ها ضرب شوند. ویژگی‌های مجموعه داده‌ها، متغیرهای مستقلی هستند که بر خروجی یا متغیر وابسته تأثیر می‌گذارند. همچنین با

^۱penalty

^۲Multi layer perceptron (MLP)

^۳constrained convex


^۴Augmented Lagrangian (AL) multiplier

ورودی به مدل استفاده شد. خروجی مدل نیز داده‌های دمای ماهانه در ماه حاضر (t) است که بر اساس داده‌های مشاهداتی ثبت شده در ایستگاه‌های هواشناسی استخراج شده است. برای پیش‌بینی سری زمانی دمای ماهانه در ایستگاه‌های اهواز، کرمانشاه، مشهد و رشت که نماینده اقلیم‌های مختلف هستند، عملکرد این مدل‌ها بر اساس شاخص‌های RMSE، NRMSE، NES و R مورد ارزیابی قرار گرفت. به دلیل عدم همبستگی بالا بین داده‌های دمای هوا با تاخیر بیش از ۲۴ ماه، از این داده‌ها برای مدلسازی استفاده نشد. بهترین نتایج حاصل از اجرای هر کدام از این مدل‌ها در جدول (۱) ارائه شده است. بر اساس این جدول مدل ORELM با توجه به تمامی شاخص‌ها دارای دقت بیشتری نسبت به سایر مدل‌ها در



مراحل آموزش و آزمون می‌باشد. پس از آن، مدل ELM در رده دوم از نظر دقت پیش‌بینی قرار دارد. شکل (۴) پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی را در مرحله تست مدل سازی برای هر یک از مدل‌های GA-ANN، PSO-ANN، ICA-ANN، ELM و ORELM نشان می‌دهد. پراکنش منظم تر و نزدیکتر نقاط در اطراف خط $Y=X$ در مدل ORELM نیز حاکی از دقت بیشتر این مدل در مقایسه با سایر مدل‌ها است. بر این اساس، سری زمانی مقادیر پیش‌بینی شده دمای ماهانه بر اساس مدل برتر (ORELM) در مقایسه با داده‌های مشاهداتی در مرحله تست در شکل‌های (۵) و (۶) نشان داده شده است.

جدول ۱. ارزیابی عملکرد مدل‌های GA-ANN، ICA-ANN، PSO-ANN، ELM و ORELM در پیش‌بینی دمای ماهانه بر اساس شاخص‌های آماری در مراحل آموزش و آزمون


ایستگاه	نوع مدل	ترکیب ورودی		آموزش		آزمون				
		GWL	RMSE	NRMSE	NASH	R	RMSE	NRMSE	NASH	R
اهواز	GA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۶۰۳۴	۱/۰۵۱۵	۰/۹۷۲۱	۰/۹۸۶۱	۱/۳۶۳۷	۰/۰۴۵۲	۰/۹۷۵۴	۰/۹۸۸۱
	ICA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۴۹۶۲	۰/۰۴۸۵	۰/۹۷۳۷	۰/۹۸۶۸	۱/۴۶۸۹	۰/۰۴۸۲	۰/۹۷۸۳	۰/۹۸۹۲
	PSO-ANN	t-1, t-2, t-3, t-6, t-12	۱/۲۷۹۷	۰/۰۴۱۶	۰/۹۸۲۰	۰/۹۹۱۰	۱/۳۹۵۰	۰/۰۴۵۳	۰/۹۷۶۸	۰/۹۸۸۶
	ELM	t-1, t-2, t-3, t-6, t-12	۱/۰۸۹۴	۰/۰۳۵۰	۰/۹۸۶۸	۰/۹۹۳۴	۱/۲۴۴۵	۰/۰۴۴۷	۰/۹۸۲۵	۰/۹۹۱۷
	ORELM	t-1, t-2, t-3, t-6, t-12	۱/۲۷۲۱	۰/۰۴۰۸	۰/۹۸۲۰	۰/۹۹۱۰	۱/۰۵۳۰	۰/۰۳۷۸	۰/۹۸۷۵	۰/۹۹۳۸
کرمانشاه	GA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۶۴۹۳	۰/۰۵۳۰	۰/۹۵۱۲	۰/۹۷۶۰	۱/۴۵۵۷	۰/۰۵۴۱	۰/۹۶۰۶	۰/۹۸۰۴
	ICA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۶۳۶۹	۰/۰۵۲۶	۰/۹۵۱۸	۰/۹۵۵۷	۱/۶۲۹۷	۰/۰۵۸۱	۰/۹۵۶۳	۰/۹۷۶۶
	PSO-ANN	t-1, t-2, t-3, t-6, t-12	۱/۳۹۰۸	۰/۰۴۷۷	۰/۹۶۵۵	۰/۹۸۲۸	۱/۳۰۶۷	۰/۰۴۹۶	۰/۹۶۹۹	۰/۹۸۵۲
	ELM	t-1, t-2, t-3, t-6, t-12	۱/۴۱۷۲	۰/۰۳۶۰	۰/۹۷۷۷	۰/۹۸۸۸	۱/۴۴۸۴	۰/۰۵۰۳	۰/۹۷۵۷	۰/۹۸۹۶
	ORELM	t-1, t-2, t-3, t-6, t-12	۱/۵۵۵۸	۰/۰۳۹۶	۰/۹۷۳۰	۰/۹۸۶۶	۱/۳۲۸۹	۰/۰۴۶۱	۰/۹۷۹۶	۰/۹۹۰۳
مشهد	GA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۸۱۸۱	۰/۰۵۸۴	۰/۹۳۵۸	۰/۹۶۷۸	۱/۸۶۸۸	۰/۰۶۵۷	۰/۹۳۱۸	۰/۹۶۵۷
	ICA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۶۹۸۹	۰/۰۵۶۲	۰/۹۴۲۶	۰/۹۷۱۰	۱/۶۵۵۰	۰/۰۵۳۳	۰/۹۴۹۷	۰/۹۷۴۶
	PSO-ANN	t-1, t-2, t-3, t-6, t-12	۱/۷۲۲۳	۰/۰۵۵۳	۰/۹۴۳۹	۰/۹۷۱۶	۱/۵۱۵۹	۰/۰۵۷۷	۰/۹۵۷۰	۰/۹۷۸۲
	ELM	t-1, t-2, t-3, t-6, t-12	۱/۷۲۹۲	۰/۰۴۵۲	۰/۹۶۴۵	۰/۹۸۲۱	۲/۳۹۶۳	۰/۰۶۲۴	۰/۹۳۳۵	۰/۹۶۹۵
	ORELM	t-1, t-2, t-3, t-6, t-12	۱/۹۰۲۶	۰/۰۴۹۷	۰/۹۵۷۱	۰/۹۷۸۵	۲/۰۱۱۱	۰/۰۵۲۳	۰/۹۵۳۲	۰/۹۷۷۹
رشت	GA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۹۸۰۱	۰/۰۶۹۷	۰/۹۳۳۱	۰/۹۶۶۵	۲/۱۳۰۶	۰/۰۶۸۴	۰/۹۲۳۵	۰/۹۶۱۱
	ICA-ANN	t-1, t-2, t-3, t-6, t-12	۱/۹۷۸۸	۰/۰۶۶۷	۰/۹۳۳۴	۰/۹۶۶۳	۲/۱۰۱۰	۰/۰۶۸۴	۰/۹۲۴۸	۰/۹۶۲۴




شکل ۴. نمایش گرافیکی پراکندگی نقاط در اطراف خط $Y=X$ و مقدار مجذور ضریب همبستگی برای انتخاب بهترین مدل هوش مصنوعی در مرحله تست مدل سازی، منبع: (نگارندگان: ۱۴۰۲)



شکل ۵. سری زمانی مقادیر پیش‌بینی شده دمای ماهانه بر اساس مدل برتر (ORELM) در مقایسه با داده‌های مشاهده‌ای در مرحله تست - ایستگاه‌های اهواز و کرمانشاه، منبع: (نگارندگان: ۱۴۰۲)





شکل ۶. سری زمانی مقادیر پیش بینی شده دمای ماهانه بر اساس مدل برتر (ORELM) در مقایسه با داده های مشاهداتی در مرحله تست - ایستگاه های مشهد و رشت، منبع: (نگارندگان: ۱۴۰۲)





را با روش پیشنهادی برای ارزیابی صحت پیش بینی های انجام شده مقایسه می کند. فاصله هر نقطه ایجاد شده برای مدل های مختلف (A, B, C, D, E, F) از نقطه مشاهده شده (A) به عنوان یک مرجع مقایسه در نظر گرفته می شود. بنابراین، یک مدل سازگار با مقادیر مشاهده شده، مجموعه ای از نقاطی است که ضریب همبستگی نزدیک به ۱ و انحراف استاندارد مشابهی با مقادیر مشاهده شده دارند (Zeynoddin et al, 2018: 203).

نتایج حاصل از ارزیابی روش ها با استفاده از دیاگرام تیلور نشان می دهد که در تمامی ایستگاه های مورد مطالعه، روش های GA-ANN، ICA-ANN و PSO-ANN (نقاط D، E و F) دقت کمتری در پیش بینی دمای ماهانه بر اساس داده های مشاهداتی دما دارند، در حالی که روش های ORELM و ELM (نقاط B و C) تفاوت نسبتاً کمتری با مقادیر مشاهده شده دارند. بین تمامی روش ها، نزدیکترین نقطه به نقطه مرجع مربوط به روش ORELM (نقطه B) می باشد. بر این اساس روش ORELM دقت بالاتری نسبت به سایر روش ها دارد.

۲.۳. انتخاب مدل برتر بر اساس دیاگرام تیلور

برای اطمینان از انتخاب درست مدل برتر از دیاگرام تیلور استفاده شد. شکل (۷) نمودار تیلور (Taylor, 2001) را برای انتخاب روش برتر بین روش های GA-ANN، ICA-ANN، PSO-ANN، ELM و ORELM جهت پیش بینی دمای ماهانه در ایستگاه های مورد مطالعه نشان می دهد. در این دیاگرام، فاصله نقاط ایجاد شده برای هر روش از نقطه مشاهده شده برابر با RMSE می باشد. بنابراین، مدلی که با مقادیر مشاهده شده سازگار است، مجموعه ای از مقادیر شبیه سازی شده است که دارای ضریب تعیین ۱ و انحراف معیار مشابه با مقادیر مشاهده شده است (Zeynoddin et al, 2018: 203).

در این دیاگرام نقطه A نشان دهنده داده های مشاهداتی دما و نتایج ارزیابی مدل های فوق به ترتیب با نقاط B، C، D، E و F نشان داده شده اند. این نمودار با استفاده از شاخص های ضریب همبستگی و انحراف معیار، صحت روش های مختلف را ارزیابی می کند. این شکل عملکرد، روش های GA-ANN، ICA-ANN، PSO-ANN، ELM و ORELM



شکل ۷- نمودار گرافیکی تبلور برای انتخاب بهترین مدل هوش مصنوعی در ایستگاه‌های مورد مطالعه- مرحله تست مدل سازی، منبع: (نگارنگان: ۱۴۰۲)

جوی و تنها با استفاده از داده‌های ماهیانه دما یکی از مهمترین دستاوردهای این تحقیق است. در این حالت بدون نیاز به پارامترهای جوی پیچیده و بدون نیاز به نقشه‌ها و نرم‌افزارهای پیچیده تحلیل جوی و بدون صرف زمان و هزینه زیاد برای کالیبراسیون و صحت‌سنجی مدل‌های ریاضی، تغییرات دمای ماهیانه بر اساس روش‌های هوش مصنوعی پیش‌بینی می‌گردد. این امر کمک بزرگی به متخصصین بخش اقلیم و هیدرولوژیست‌ها در حوضه‌های فاقد آمار یا مناطقی که فاقد اطلاعات پایه‌ای و نقشه‌های دقیق بوده و با نقص آمار گسترده مواجه هستند می‌کند. زیرا با استفاده از مدل‌های هوش مصنوعی، با صرف زمان و هزینه بسیار کم، اطلاعات مدیریتی بسیار ارزشمندی در خصوص پیش‌بینی نوسانات دمایی هوا برای استفاده در مدل‌های هیدرولوژیکی و هواشناسی در سال‌های خشک و تر به دست می‌آید. ارزیابی عملکرد مدل‌های هوش مصنوعی (ELM, ICA-ANN, GA-ANN)

نتایج حاصل از کاربرد مدل هوش مصنوعی ORELM نشان می‌دهد این روش توانسته است در دوره‌های آماری ۱۱۲، ۱۳۲، ۱۵۶ و ۱۴۴ ماهه، به ترتیب در ایستگاه‌های اهواز، کرمانشاه، مشهد و رشت با کمترین میزان خطا در مراحل train و test دمای ماهانه را پیش‌بینی نماید. بطوری که مقدار NRMSE در این روش در مرحله آزمون در این ایستگاه‌ها به ترتیب ۰/۰۳۷۸، ۰/۰۴۶۱، ۰/۰۵۲۳ و ۰/۰۶۰۵ می‌باشد. این امر نشان می‌دهد که مدل ORELM بدون نیاز به اطلاعات و داده‌های فراوان و بدون بهره‌گیری از فرآیندهای پیچیده مدلسازی و با صرف زمان بسیار کمتر، دمای ماهانه را به درستی و با دقت زیاد پیش‌بینی نماید.

۴. بحث و نتیجه‌گیری

امکان پیش‌بینی تغییرات دمای هوا برای یک دوره بلندمدت بر اساس حجم اطلاعات بسیار کم، نسبت به مدل‌های عددی

را بخصوص برای مناطق فاقد آمار پایه و یا در شرایطی که امکان استفاده از مدل‌های ریاضی وجود ندارد توصیه نمود. بر اساس نتایج بدست آمده می‌توان مدل‌های توسعه داده شده در این تحقیق را برای سایر مناطق مطالعاتی با اقلیم‌های متفاوت نیز پیشنهاد داد. در این صورت بدون نیاز به روابط و معادلات پیچیده برای تحلیل‌های پیچیده جوی و تنها بر اساس اطلاعات تاریخی ثبت شده می‌توان نوسانات ماهیانه دما را در منطقه مورد مطالعه در دوره‌های مختلف با دقت زیاد پیش‌بینی نمود.

فهرست منابع

- Agghakhani Afshar, A., Hassanzadeh, Y., Besalatpour, A. A., & Pourreza Bilondi, M. (2017). Annual assessment of Kashafrud watershed basin climate components in future periods by using fifth report of intergovernmental panel on climate change. *Journal of Water and Soil Conservation*, 23(6), 217-233, <https://doi.org/10.22069/jwfst.2017.11186.2553>. (in Persian)
- Alizamir, M., Kisi, O., Ahmed, A.N., Mert, C., Fai, C.M., Kim, S., Kim, N.W. and El-Shafie, A., (2020). Advanced machine learning model for better prediction accuracy of soil temperature at different depths. *PLoS One*, 15(4), p.e0231055, <https://doi.org/10.1371/journal.pone.0231055>.
- Astsatryan, H., Grigoryan, H., Poghosyan, A., Abrahamyan, R., Asmaryan, S., Muradyan, V., ... & Giuliani, G. (2021). Air temperature forecasting using artificial neural network for Ararat valley. *Earth Science Informatics*, 14, 711-722, <https://doi.org/10.1007/s12145-021-00583-9>.
- Azari, A., Zeynoddin, M., Ebtehaj, I., Sattar, A. M., Gharabaghi, B., & Bonakdari, H. (2021). Integrated preprocessing techniques with linear stochastic approaches in groundwater level forecasting. *Acta Geophysica*, 69(4), 1395-1411, <https://doi.org/10.1007/s11600-021-00617-2>.
- ORELN و GMDH) در چهار ایستگاه مورد مطالعه اهواز، کرمانشاه، مشهد و رشت نشان داد که این مدل‌ها دقت بسیار خوبی در پیش‌بینی نوسانات دمایی دارند. طوری که از بین این مدل‌ها، در مدل ORELM مقدار NRMSE در مرحله آزمون در این ایستگاه‌ها به ترتیب ۰/۰۳۷۸، ۰/۰۴۶۱، ۰/۰۵۲۳ و ۰/۰۶۰۵ بود که از این نظر دارای بیشترین دقت بود. دیاگرام تیلور نیز با بهره‌گیری از معیارهای خطای بیشتر، این نتیجه را تایید کرد تا مدل ORELM با اطمینان زیاد به عنوان بهترین مدل هوش مصنوعی برای پیش‌بینی تغییرات دمایی در این ۴ ایستگاه که نماینده ۴ اقلیم متفاوت می‌باشند معرفی گردد. با توجه به اهمیت آگاهی از تغییرات دما به عنوان یکی از مهمترین پارامترهای بیلان هیدروکلیماتولوژی، می‌توان مدل‌های هوش مصنوعی مورد استفاده در این تحقیق
- Azari, B., Hassan, K., Pierce, J., & Ebrahimi, S. (2022). Evaluation of machine learning methods application in temperature prediction. *Environ Eng*, 8, 1-12, <https://doi.org/10.52547/crpase.8.1.2747>.
- Ebtehaj, I., Bonakdari, H., & Shamshirband, S. (2016). Extreme learning machine assessment for estimating sediment transport in open channels. *Engineering with Computers*, 32, 691-704, <https://doi.org/10.1007/s00366-016-0446-1>.
- Ebtehaj, I., Bonakdari, H., Zeynoddin, M., Gharabaghi, B., & Azari, A. (2020). Evaluation of preprocessing techniques for improving the accuracy of stochastic rainfall forecast models. *International Journal of Environmental Science and Technology*, 17, 505-524, <https://doi.org/10.1007/s13762-019-02361-z>.
- Esmaeili, F., Shabanlou, S., & Saadat, M. (2021). A wavelet-outlier robust extreme learning machine for rainfall forecasting in Ardabil City, Iran. *Earth Science Informatics*, 14(4), 2087-2100, <https://doi.org/10.1007/s12145-021-00681-8>.
- Feigl, M., Lebedzinski, K., Herrnegger, M., & Schulz, K. (2021). Machine-learning methods for stream water temperature

- prediction. *Hydrology and Earth System Sciences*, 25(5), 2951-2977, <https://doi.org/10.5194/hess-25-2951-2021>.
- Huang, G. B., & Siew, C. K. (2004, December). Extreme learning machine: RBF network case. In *ICARCV 2004 8th Control, Automation, Robotics and Vision Conference*, 2004. (Vol. 2, pp. 1029-1036). IEEE, <https://doi.org/10.1109/ICARCV.2004.1468985>.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501, <https://doi.org/10.1016/j.neucom.2005.12.126>.
- Inard, C., Bouia, H., & Dalicieux, P. (1996). Prediction of air temperature distribution in buildings with a zonal model. *Energy and buildings*, 24(2), 125-132, [https://doi.org/10.1016/03787788\(95\)00969-8](https://doi.org/10.1016/03787788(95)00969-8).
- IPCC, (2013), *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp, <https://doi.org/10.1017/CBO978110741532>
- IPCC. (2001), *Special Report on Emission Scenarios*. N. Nakicenovic, R. Swart (Eds). Intergovernmental Panel on Climate Change (IPCC), Cambridge University Press, Cambridge, UK.
- Jusuf, S. K., & Wong, N. H. (2009). Development of empirical models for an estate level air temperature prediction in Singapore. In *Proceedings of the second international conference on countermeasures to urban heat islands* (pp. 21-23).
- Masoodian, S. A. (2004). Temperature trends in Iran during the last half century. *Geography and Development*, 2(3), 89-106. (in Persian)
- Masoompoor Samakoosh, J; Sohrabi, V; & Miri, M. (2022), Evaluation and prediction of droughts in the west and northwest of Iran using artificial neural network. *Journal of Geographical Studies of Mountainous Areas*, 3(10), 19-37, <https://doi.org/10.52547/gsma.3.2.19>. (in Persian)
- Mohammed, K. S., Shabanlou, S., Rajabi, A., Yosefvand, F., & Izadbakhsh, M. A. (2023). Prediction of groundwater level fluctuations using artificial intelligence-based models and GMS. *Applied Water Science*, 13(2), 54, <https://doi.org/10.1007/s13201-022-01861-7>.
- Pandey, P., & Govind, R. (2016). Analysis of randomized performance of bias parameters and activation function of extreme learning machine. *International Journal of Computer Applications*, 135(1), 23-28.
- Roy, D. S. (2020). Forecasting the air temperature at a weather station using deep neural networks. *Procedia Computer Science*, 178, 38-46, <https://doi.org/10.1016/j.procs.2020.11.005>
- Salcedo-Sanz, S., Deo, R. C., Carro-Calvo, L., & Saavedra-Moreno, B. (2016). Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theoretical and applied climatology*, 125, 13-25, <https://doi.org/10.1007/s00704-015-1480-4>.
- Soltani, K., Ebtehaj, I., Amiri, A., Azari, A., Gharabaghi, B., & Bonakdari, H. (2021). Mapping the spatial and temporal variability of flood susceptibility using remotely sensed normalized difference vegetation index and the forecasted changes in the future. *Science of the Total Environment*, 770, 145288, <https://doi.org/10.1016/j.scitotenv.2021.145288>.
- Swaid, H., & Hoffman, M. E. (1990). Prediction of urban air temperature variations using the analytical CTTC model. *Energy and Buildings*, 14(4), 313-324, [https://doi.org/10.1016/03787788\(90\)90094-Y](https://doi.org/10.1016/03787788(90)90094-Y).
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of geophysical research: atmospheres*, 106(D7), 7183-7192, <https://doi.org/10.1029/2000JD900719>.
- Yang, J., & Zhang, Y. (2011). Alternating direction algorithms for \ell_1-problems in compressive sensing. *SIAM journal on*

- scientific computing, 33(1), 250-278,
<https://doi.org/10.1137/090777761>.
- Zeynoddin, M., Bonakdari, H., Azari, A., Ebtehaj, I., Gharabaghi, B., & Madavar, H. R. (2018). Novel hybrid linear stochastic with non-linear extreme learning machine methods for forecasting monthly rainfall a tropical climate. Journal of environmental management, 222, 190-206, <https://doi.org/10.1016/j.jenvman.2018.05.072>.
- Zeynoddin, M., Bonakdari, H., Ebtehaj, I., Azari, A. and Gharabaghi, B. 2020. A generalized linear stochastic model for lake level prediction. Science of The Total Environment. 723, 138015, <https://doi.org/10.1016/j.scitotenv.2020.138015>

