

Temperature modeling in semi-arid and humid climates using long-short-term memory and CEEMD and DWT preprocessor methods

Kiyoumars Roushangar^{1*} and Sadegh Abdelzad²

¹ Professor, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

² PhD Candidate of Water and Hydraulic Structures, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

Received: 25 January 2023

Accepted: 08 May 2023

Extended abstract

Introduction

Predicting the maximum temperature changes is very important and has become increasingly important due to the many effects it has on water resources, agriculture and the environment. By forecasting the temperature, one can be aware of future changes and make the necessary arrangements to adjust its negative effects on water resources, agriculture and the environment. Therefore, modeling and forecasting the maximum temperature can be used as an important tool in the planning and management of natural, economic and industrial resources.

Materials and methods

In this article, the maximum temperature was modeled using the Long-Short-Term Memory (LSTM) method based on Discrete Wavelet Transform (DWT) and Complete Experimental Mode Decomposition (CEEMD) methods in two different climates (humid and semi-arid). For this purpose, the daily data of maximum temperature, minimum temperature, precipitation, and solar radiation were used from 2001 to 2020 of the synoptic stations located in Siyahbisheh, Amol City in Mazandaran Province and Urmia City airport in West Azarbaijan Province. It was determined that in the semi-arid region, the parameters of maximum and minimum temperature two days before, and maximum and minimum temperature one day before, as well as the minimum temperature and solar radiation of the same day, and in the humid region, the parameters of maximum temperature two days before, and maximum and minimum temperature one day before, as well as the minimum temperature and solar radiation of the same day were recognized as the superior model.

Results and discussion

The results of the analysis of the models showed the capability and high efficiency of the method used in estimating the maximum temperature. On the other hand, the pre-processor methods improved the results. In the investigations, it was observed that the results of analysis based on wavelet transformation led to better results so that the DC evaluation criterion for the superior model in the semi-arid region of Urmia City went from 0.965 to 0.993 and in the humid area of Amol City increased from 0.926 to 0.970 and the RMSE criterion in Urmia Airport decreased from 1.943 to 0.896 and in Siyahbisheh from 2.595 to 1.648.

Conclusion

The results showed an increase in DC evaluation criteria and a decrease in RMSE for the synoptic station of Urmia Airport by 2.74% and 53.87%, respectively, and by 4.80% and 35.50% for the Siyahbisheh Amol Synoptic Station, respectively. This again shows that wavelet conversion has the greatest effect in improving the performance of the LSTM model and the selected models have high capability and efficiency in estimating the maximum temperature. According to the results of the sensitivity analysis, it was determined that the temperature parameter of the previous day is the most influential in estimating the maximum daily temperature for two regions with different climates (humid and semi-arid).

* Corresponding author: kroshangar@yahoo.com

Keywords: Artificial neural networks, Deep learning, Empirical mode decomposition, Maximum temperature, Wavelet transform

Cite this article: Roushangar, K., Abdelzad, S., 2023. Temperature modeling in semi-arid and humid climates using long-short-term memory and CEEMD and DWT preprocessor methods. *Watershed Engineering and Management* 15(4), 603-621.

© 2024, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



مدلسازی دما در دو اقلیم نیمه خشک و مرطوب با استفاده از حافظه طولانی-کوتاه-مدت و روش‌های پیش‌پردازنده CEEMD و DWT

کیومرث روشنگر^{۱*} و صادق عبدالزاد^۲

^۱ استاد، گروه مهندسی آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران

^۲ دانشجوی دکتری آب و سازه‌های هیدرولیکی، گروه مهندسی آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران

تاریخ پذیرش: ۱۴۰۲/۰۲/۱۸

تاریخ دریافت: ۱۴۰۱/۱۱/۰۵

چکیده مبسوط

مقدمه

پیش‌بینی تغییرات بیشینه دما، بسیار مهم است و به دلیل تأثیرات زیادی که بر منابع آبی، کشاورزی و محیطی دارد، اهمیت فزاینده‌ای پیدا کرده است. با پیش‌بینی دما، می‌توان از تغییرات آینده آگاه شد و تمهیدات لازم برای تعدیل اثرات منفی آن بر منابع آبی، کشاورزی و محیطی را انجام داد. بنابراین، مدلسازی و پیش‌بینی بیشینه دما می‌تواند، به‌عنوان یک ابزار مهم در برنامه‌ریزی و مدیریت منابع طبیعی، اقتصادی و صنعتی مورد استفاده قرار گیرد.

مواد و روش‌ها

در این پژوهش، بیشینه دما با استفاده از روش نوین حافظه طولانی-کوتاه-مدت (LSTM) بر پایه روش‌های پیش‌پردازنده تبدیل موجک گسسته (DWT) و تجزیه مد تجربی کامل (CEEMD) در دو اقلیم متفاوت (مرطوب و نیمه‌خشک) مدلسازی شد. برای این منظور، از داده‌های دمای بیشینه، دمای کمینه، بارش و تابش خورشیدی به‌صورت روزانه مربوط به دوره ۲۰۰۱ تا ۲۰۲۰ ایستگاه‌های سینوپیک واقع در سیاه‌بیشه شهرستان آمل در استان مازندران و فرودگاه شهرستان ارومیه در استان آذربایجان غربی، استفاده شد. مشخص شد که در منطقه نیمه‌خشک، پارامترهای دمای بیشینه و کمینه دو روز قبل و دمای بیشینه و کمینه یک روز قبل و دمای کمینه و تابش خورشیدی همان روز و در منطقه مرطوب، پارامترهای دمای بیشینه دو روز قبل و دمای بیشینه و کمینه یک روز قبل و دمای کمینه و تابش خورشیدی همان روز، به‌عنوان مدل برتر شناخته شده است.

نتایج و بحث

نتایج حاصل از تحلیل مدل‌ها، قابلیت و کارایی بالای روش به‌کار رفته در تخمین بیشینه دما را به خوبی نشان داد. از طرف دیگر، روش‌های پیش‌پردازنده باعث بهبود نتایج شدند. در بررسی‌های صورت گرفته مشاهده شد که نتایج حاصل از تجزیه بر اساس تبدیل موجک، منجر به نتایج بهتری می‌شود، به‌طوری که معیار ارزیابی DC برای مدل برتر در منطقه نیمه‌خشک شهرستان ارومیه، از ۰/۹۶۵ به ۰/۹۹۳ و در منطقه مرطوب شهرستان آمل از ۰/۹۲۶ به ۰/۹۷۰، افزایش یافت و معیار RMSE در فرودگاه ارومیه از ۱/۹۴۳ به ۰/۸۹۶ و در سیاه‌بیشه از ۲/۵۹۵ به ۱/۶۴۸، کاهش یافته است.

نتیجه‌گیری

نتایج بررسی نشان از افزایش معیار ارزیابی DC و کاهش RMSE برای ایستگاه سینوپتیک فرودگاه ارومیه به ترتیب ۲/۷۴ و ۵۳/۸۷ درصد و برای ایستگاه سینوپتیک سیاه‌بیشه آمل به ترتیب ۴/۸۰ و ۳۵/۵۰ درصد شد. این نتایج نشان می‌دهد، تبدیل موجک بیشترین تاثیر را در بهبود عملکرد مدل LSTM دارد و مدل‌های منتخب، قابلیت و کارایی بالایی در تخمین میزان دمای بیشینه را دارند. با توجه به نتایج تحلیل حساسیت مشخص شد، پارامتر دمای یک روز قبل، تاثیرگذارترین پارامتر در تخمین بیشینه دمای روزانه برای دو منطقه با اقلیم متفاوت مرطوب و نیمه‌خشک است.

واژه‌های کلیدی: بیشینه دما، تبدیل موجک، تجزیه مد تجربی، شبکه‌های عصبی مصنوعی، یادگیری عمیق

مقدمه

احتمالی اقلیمی هوا در دو منطقه با اقلیم‌های متفاوت، مدل‌سازی بیشینه دما برای پیش‌بینی آن اهمیت زیادی دارد. در سال‌های اخیر، روش‌های هوش مصنوعی^۱ توانایی قابل ملاحظه‌ای در پیش‌بینی سری‌های زمانی از خود نشان داده‌اند. این روش‌ها، به‌علت داده محور بودن، نیاز به دانش اولیه راجع به پدیده مورد مطالعه ندارند. همچنین، مدل‌های مبتنی بر AI، ابزاری کارآمد برای مدل‌سازی بر روی انبوهی از داده‌های دینامیکی و غیرخطی هستند.

Ghorbani et al., (2010) برای پیش‌بینی دما در شهر تبریز با استفاده از مدل‌های AI، ANN و برنامه‌ریزی ژنتیک و مقایسه آن‌ها با یکدیگر دریافتند، هر سه مدل از همگرایی بالایی در تخمین دما برخوردار بوده است، ولی روش برنامه‌ریزی ژنتیک نسبت به دو مدل دیگر، دقت بالاتری را از خود نشان داد. (Karen et al., 2010). از روش‌های تطبیقی رگرسیون اسپین لاین^۲ و رگرسیون چندمتغیره و شبکه عصبی مصنوعی انتشار به عقب^۳ برای پیش‌بینی درجه حرارت و بارش در حوضه رودخانه‌های مانتارو^۴ و ژنگ ژو را مورد بررسی قرار دادند. آن‌ها برای پیش‌بینی دما و بارش حوضه رودخانه مانتارو، از روش رگرسیون چندمتغیره اسپین لاین و ANNB استفاده کردند. (Esfandiari et al., 2011). با استفاده از مدل ANN پرسپترون چندلایه^۵ پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج را انجام دادند. آن‌ها از میانگین دمای ماهانه ۳۸ سال آماری (۲۰۰۱-۱۹۶۴) به

دما، به‌عنوان یکی از تاثیرگذارترین پارامترها در شرایط اقلیمی است که در مشخص کردن تاثیر و انتشار عناصر دیگر اقلیمی، نقش مهمی دارد. بر این اساس، نوسانات و تغییرات دما دارای اهمیت زیادی است که عوامل اقلیمی و جغرافیایی زیادی از قبیل رطوبت، ابرناکی، سرعت باد، ارتفاع، دوری و نزدیکی به دریا و غیره، اثرات خود را بر آن نشان می‌دهد و در تغییرات آن نقش دارند. دمای بیشینه و کمینه، از عناصر اساسی شناسایی هوا است (Peixoto et al., 1992).

بنابراین، نوسانات ناشی از دما، دلیل تغییر در وضعیت هوا است. مطالعات اخیر نشان می‌دهد که میانگین دمای کره زمین طی سده گذشته روندی افزایشی داشته است. این روند حاوی الگوهای زمانی و مکانی متفاوتی است (IPCC, 2001; Behmanesh et al., 2015). لذا، شناسایی رفتار دما و مدل‌سازی در راستای آینده‌نگری رفتار این عنصر در حوزه‌های مختلف مدیریت مانند منابع آبی، محیط طبیعی، خشکسالی، کمبود مواد غذایی، گسترش آفات و بیماری‌ها، حمل و نقل و سایر عوامل دخیل در این زمینه، از اهمیت ویژه‌ای برخوردار است.

افزایش دما بر میزان بارندگی و رطوبت خاک و شدت خشکسالی‌ها تاثیرگذار بوده و می‌تواند به‌صورت مستقیم تولید محصولات کشاورزی را تحت تاثیر قرار دهد (Feng and Liu, 2015). برای آشکارسازی تغییرات

⁴ Mantaro

⁵ Multi Layer Percpetron (MLP)

¹ Artificial Intelligence (AI)

² Multivariate Regression Splines (MARS)

³ Artificial Neural Networks Backpropagation (ANNB)

سری‌های زمانی هیدرولوژیکی دارای دقت بالاتری نسبت به مدل ساده ANN است. (Zhang et al., 2020) برای پیش‌بینی درجه حرارت روزانه از یک مدل شبکه عصبی بازگشتی کانولوشن (CNN) که متشکل از دو بخش CNN و شبکه عصبی بازگشتی (RNN) بود، استفاده کردند. در این پژوهش، برای ارزیابی مدل پیشنهادی CRNN، از داده‌های دمای روزانه طی سال‌های ۲۰۱۸-۱۹۵۲ به عنوان داده‌های آموزشی استفاده شد و نتایج نشان داد که مدل انتخابی می‌تواند دمای آینده را با خطایی در حدود ۰/۹۰۷ درجه سانتی‌گراد پیش‌بینی کند. (et al., 2022) Omid Ghaleh Mohammadi در پژوهشی نسبت به پیش‌بینی دمای بیشینه روزانه در استان کرمان پرداختند. بدین منظور، پارامترهای اقلیمی روزانه به‌عنوان ورودی شبکه‌های عصبی، و دمای بیشینه روزانه به‌عنوان خروجی شبکه، طی دوره آماری ۲۴ ساله (۲۰۱۳-۱۹۸۹) مورد استفاده قرار گرفت. نتایج نشان داد، شبکه پرسپترون چندلایه با توجه به میزان خطا و همبستگی بین داده‌ها از دقت بیشتری برخوردار بوده ولی همبستگی بیشتری نسبت به خروجی مورد نظر (دمای بیشینه روزانه) را دارد. (Mirzania et al., 2021) در پژوهشی نشان دادند که موجک باعث بهبود نتایج و پیش‌بینی در مدل‌سازی بارش-رواناب شده است. با جمع‌بندی تحقیقات انجام یافته، هدف از این پژوهش، مدل‌سازی بیشینه دما و بررسی عملکرد مدل LSTM و پیش‌پردازنده DWT و EMD برای دو منطقه با اقلیم‌های متفاوت در کشور ایران است. نتایج به‌دست آمده از این تحقیق می‌تواند در برنامه ریزی مدیریتی و سیاست‌گذاری‌های کلان در حوزه‌های مختلف از قبیل منابع آبی، خشک‌سالی، مطالعات محیط زیستی، کمبود مواد غذایی گسترش آفات و بیماری‌ها و سایر موارد مورد استفاده قرار گیرد.

عنوان ورودی‌های شبکه پرسپترون چندلایه استفاده کردند و میانگین دمای ماهانه را در طی سال‌های ۲۰۰۵-۲۰۰۲ برای تعیین میزان خطای مدل، پیش‌بینی کردند. نتایج به‌دست آمده، نشان‌دهنده کارایی مناسب و دقت قابل قبول ANN در پیش‌بینی دما را دارد. به‌طوری که ضریب همبستگی برابر با ۰/۹۹ و میانگین درصد خطای مدل برابر با ۱/۹۷ درصد است. (Kisi and Cimen, 2011) توانایی ترکیب موجک^۱ با روش برنامه‌ریزی ژنتیک را در مقایسه با مدل برنامه‌ریزی ژنتیکی به اثبات رساندند.

در سال‌های اخیر، پژوهشگران از روش‌های پیش‌پردازش نظیر DWT برای بهبود نتایج شبیه‌سازی استفاده کردند. روش DWT و تجزیه مد تجزیه^۲ روشی کاملاً موثر استخراج سیگنال از داده‌ها است و برای تجزیه سیگنال در حوزه زمان-فرکانس کاربرد دارند. (Sharifi et al., 2016) با استفاده از سه مدل ANN، الگوریتم ژنتیک و شبکه عصبی موجک، به پیش‌بینی میزان تابش خورشیدی ایستگاه‌های تبریز و ارومیه پرداختند و نشان دادند که مدل شبکه عصبی موجک، از دقت و عملکرد قابل قبولی در پیش‌بینی تابش خورشیدی برخوردار است. (Ashour et al., 2016) در پیش‌بینی دمای میانگین ماهانه قاهره با روش‌های شبکه عصبی مصنوعی و رگرسیون خطی به این نتیجه رسیدند که روش شبکه عصبی مصنوعی عملکرد بهتری نسبت به روش دیگر دارد، اما در صورت استفاده همزمان از هر دو روش، قابلیت روش شبکه عصبی مصنوعی در پیش‌بینی، بهبود می‌یابد.

(Karthika and Deka, 2016) در پژوهشی دمای متوسط روزانه حوضه شیموگا^۳ واقع در هند را با استفاده از داده‌های سرعت باد، رطوبت نسبی، تعداد ساعات آفتابی و بارش، به‌وسیله مدل فازی و شبکه عصبی موجک پیش‌بینی کردند. نتایج نشان داد، مدل شبکه عصبی موجک در پیش‌بینی دمای متوسط روزانه، عملکرد بهتری نسبت به مدل فازی دارد. (Alizadeh et al., 2017) در مطالعه‌ای نشان دادند مدل ترکیبی DWT با ANN در

³ Shimoga

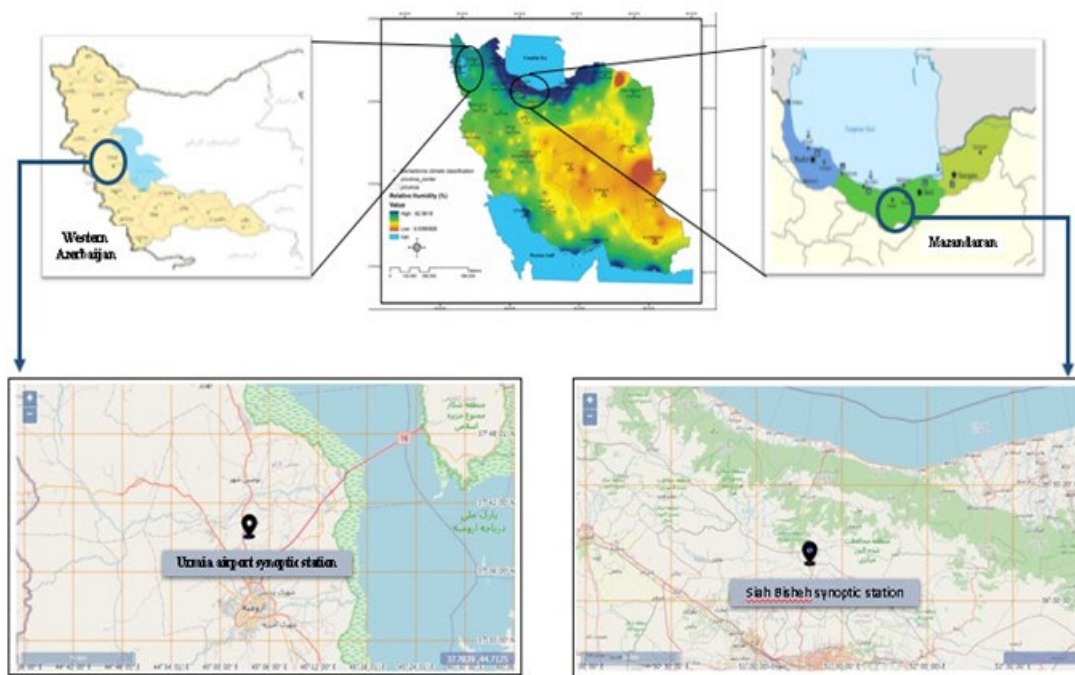
¹ Discrete Wavelet Transform (DWT)

² Ensemble Empirical Mode Decomposition (EMD)

مواد و روش‌ها

موقعیت و ویژگی‌های منطقه مورد مطالعه: منطقه مورد مطالعه در این پژوهش، شامل دو منطقه با دو اقلیم مرطوب و نیمه‌خشک در کشور ایران است که بر اساس نقشه پهنه‌بندی بوم اقلیم‌شناسی کشور تعیین شد (Lashanizand et al., 2014). منطقه اول در استان آذربایجان غربی، شهرستان ارومیه در اقلیم نیمه‌خشک و منطقه دوم در استان مازندران، شهرستان آمل در اقلیم مرطوب قرار گرفته است. در این پژوهش، برای مدل‌سازی بیشینه دما از داده‌های روزانه دو ایستگاه سینوپتیک فرودگاه شهرستان ارومیه و سیاه‌بیشه شهرستان آمل با

اقلیم متفاوت نیمه‌خشک و مرطوب، استفاده شد. داده‌های ایستگاه‌های سینوپتیک شامل دمای بیشینه و کمینه، بارش و تابش خورشیدی روزانه مربوط به ۲۰ سال (۲۰۰۱ - ۲۰۲۰) است. از LSTM برای مدل‌سازی دمای بیشینه در دو منطقه استفاده شد. نهایتاً، دو نوع متفاوت از مدل‌سازی یکی بدون و دیگری پس از تجزیه داده‌های سری زمانی با استفاده از DWT و EMD انجام و نتایج با هم مقایسه شد. موقعیت منطقه مورد مطالعه در شکل ۱، و همچنین، مشخصات ایستگاه‌ها و پارامترهای اندازه‌گیری شده در جدول ۱، آورده شده است.



شکل ۱- موقعیت منطقه‌های مورد مطالعه
Fig. 1. Location of the studied areas

جدول ۱- مشخصات ایستگاه‌ها و پارامترهای اقلیمی به صورت روزانه برای دوره آماری (۲۰۰۱-۲۰۲۰)

Table 1. Characteristics of stations and climatic parameters on a daily basis for the statistical period (2020-2001)

Climate	Synoptic station name	Longitude	Latitude	Parameter (Daily)	Unit	Minimum	Maximum	Average
Semi-Arid	Urmia County Airport	45°02'59"	37°40'12"	Max temperature (Tmax)	°C	-7.2	39.9	18.82
				Min temperature (Tmin)	°C	-18	23.7	5.31
				Precipitation (P)	mm	165.27	443.68	3.6.56
				Solar radiation (S)	jm-2.day-1	0	14.5	8.09

ادامه جدول ۱
Table 1 Continued

				Max temperature (Tmax)	°C	-7.4	35.4	15.59
				Min temperature (Tmin)	°C	-17	32.4	6.49
				Precipitation (P)	mm	400.59	868.98	607.19
				Solar radiation (S)	jm-2.day-1	0	14.6	5.28
Humid	Amol County Siyahbisheh	36°15'00"	51°18'00"					

روش تجزیه مد تجربی (EMD): روش EMD، روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرایندی تحت عنوان، غربال کردن صورت می‌گیرد. طی این فرایند، سیگنال اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD، طبق رابطه (۱)، سیگنال اصلی $x(n)$ را به تعدادی مد ذاتی^۳ تجزیه می‌کند (Amirat et al., 2018).

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (1)$$

که در آن، $r_n(x)$ همان مولفه باقی‌مانده، بعد از n تعداد IMFها و $c_i(x)$ است. یک داده ممکن است در یک زمان دارای چندین مد ذاتی باشد. این مدهای نوسانی، تابع‌های مد ذاتی (IMF) نام دارند و دارای دو شرط شامل (۱) در کل داده‌ها، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند و (۲) در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد. به علت وجود تناوب و نویز در سیگنال‌ها، در برخی موارد به علت اختلاط مدها، توزیع حوزه زمان-فرکانس دچار انقطاع شده و عملکرد EMD دچار نقض می‌شود. به این علت که میانگین IMFها حالتی نامشخص به خود می‌گیرد.

برای رفع این نقیصه، روشی متفاوت با عنوان روش تجزیه مد تجربی یکپارچه^۳ پیشنهاد شد. در روند تجزیه سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. با استفاده از جنبه‌های مثبت آماری، نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب، از روند تجزیه حذف می‌شود. در روش تجزیه مد تجربی

تبدیل موجک (DWT): موجک^۱، دسته‌ای از توابع ریاضی است که برای تجزیه سیگنال پیوسته به مولفه‌های فرکانسی آن به کار می‌رود و توانایی بهینه‌سازی و افزایش دقت مدل‌های AI را نیز دارد. این روش، یک تحلیل طیفی مستقل از زمان است که به منظور توصیف مقیاس زمانی فرایندها و روابط آن‌ها، سری‌های زمانی را در فضای زمان-فرکانس از هم جدا می‌کند. تبدیل موجک همانند تبدیل فوریه، سری زمانی را به صورت ترکیب خطی از چند تابع اصلی در نظر می‌گیرد. در واقع می‌توان گفت، یکی از مشخصات اصلی DWT این است که این تبدیل توانایی به دست آوردن اطلاعات در زمان، تناوب و موقعیت را به طور همزمان، دارا است (Misiti et al., 1996).

DWT، ابزاری موثر برای استخراج اطلاعات داده، با تجزیه سیگنال اصلی به حوزه‌های فرکانس پایین و بالا است (Yadav and Eliza, 2017) که توانایی عملکرد در هر مقیاس را دارد. هر چند که تعیین ضرایب موجک در هر مقیاس بسیار مشکل است و نیازمند زمان محاسباتی بالا و تولید حجم زیادی داده است. در انفصال DWT، تنها یک زیرمجموعه از مقیاس‌ها و موقعیت‌ها به منظور انجام محاسبات انتخاب می‌شود. در مدلسازی، یک مساله خاص با استفاده از روش‌های مبتنی بر AI، علاوه بر توانایی روش مورد نظر در انتخاب عوامل موثر بر پارامترهای هدف، به عنوان ورودی‌های مدل، نقش قابل توجهی در افزایش دقت مدل دارد. در مدلسازی سری‌های زمانی که به صورت تاریخیچه زمانی ارائه می‌شود، در نظر گرفتن تاخیرهای موثر، می‌تواند منجر به یک نتیجه قابل قبول شود.

³ Ensemble Empirical Mode Decomposition (EEMD)

¹ Wavelet

² Intrinsic Mode Functions (IMF)

مخفی h_t خود را با استفاده از رابطه (۲)، به روزرسانی می کند.


$$\begin{cases} 0 & t=0 \\ \varphi(h_{t-1}, x_t) & \text{otherwise} \end{cases} \quad (2)$$

که در آن، φ تابع غیرخطی مانند تابع سیگموئید، x_t ورودی شبکه در زمان t ، h_t حالت مخفی در زمان t ، h_{t-1} حالت مخفی در یک واحد تاخیر زمانی است (Chung et al., 2014). عنصر اصلی شبکه LSTM، سلول حالت است. شبکه LSTM، این توانایی را دارد که اطلاعات جدیدی را به سلول حالت اضافه یا اطلاعات آن را حذف کند. این کار با استفاده از ساختارهایی به نام گیت انجام می شود که گیت ها مسیر ورودی اطلاعات هستند. آن ها از یک لایه شبکه عصبی سیگموئید به همراه یک عملگر ضرب نقطه به نقطه تشکیل شده اند. خروجی لایه سیگموئید عددی بین صفر و یک است که نشان می دهد چه مقدار از ورودی باید به خروجی ارسال شود. مقدار صفر یعنی هیچ اطلاعاتی نباید به خروجی ارسال شود، در حالی که مقدار یک، نشان می دهد که تمام ورودی به خروجی ارسال شود. LSTM، دارای سه گیت شامل گیت فراموشی، ورودی و خروجی، برای کنترل مقدار سلول حالت است (Graves and Schmidhuber, 2005). در نهایت، شکل نهایی سلول LSTM، به صورت شکل ۲، خواهد بود و معادلات مربوط به عملکرد گیت ها و سلول حالت در معادله ۳، آورده شده است.

یکپارچه کامل^۱، نوفه سفید به صورت دوتایی، یکی مثبت و دیگری منفی، به داده اصلی اضافه می شود تا دو سری IMF مجموع ساخته شود. بنابراین، ترکیبی متشکل از داده اصلی و نوفه اضافی وجود دارد که مجموع IMFها برابر سیگنال اصلی می شود و نوفه اضافی دامنه موجی از مرتبه pm خواهد بود (Wu and Huang, 2004).

حافظه طولانی-کوتاه-مدت (LSTM): یادگیری عمیق، رده ای از الگوریتم های یادگیری ماشین است که از چندین لایه برای استخراج ویژگی های سطح بالا از ورودی خام استفاده می کنند (Deng and Yu, 2014). یک شبکه عصبی مکرر^۲، کلاسی از ANN هستند که در آن، اتصالات مابین گره ها، در امتداد یک دنباله زمانی بوده است و سبب می شود تا الگوریتم بتواند رفتار پویای موقتی را به نمایش بگذارد. برخلاف شبکه های عصبی رو به جلو، شبکه های عصبی مکرر می توانند از وضعیت درونی خود برای پردازش دنباله ورودی ها استفاده کنند (Graves et al., 2008; Sak et al., 2014; Li and Wu, 2015).

حافظه طولانی-کوتاه-مدت، یک معماری شبکه عصبی بازگشتی (یک ANN) است که در سال ۲۰۰۰ میلادی بهبود یافت (Hochreiter and Schmidhuber, 1997; Gers et al., 2000; Felix et al., 2000). یک سلول RNN، توالی $X = [x_1, x_2, x_3, \dots, x_n]$ با طول متغیری از ورودی ها را دریافت می کند و در هر گام زمانی، حالت



شکل ۲- شکل نهایی سلول LSTM

Fig. 2. The final shape of the LSTM cell

² Recurrent Neural Network (RNN)

¹ Complementary Ensemble Empirical Mode Decomposition (CEEMD)

میزان انحراف بین مقادیر پیش‌بینی شده است. هرچه مقدار R و DC برای یک مدل به یک نزدیک‌تر و مقدار RMSE کوچک‌تر باشد، به معنی مطلوب بودن آن مدل است. رابطه‌های این پارامترهای آماری به صورت زیر است:

$$DC = 1 - \frac{\sum_{i=1}^N (l_0 - l_p)^2}{\sum_{i=1}^N (l_0 - \bar{l}_p)^2} \quad RMSE = \sqrt{\frac{\sum_{i=1}^N (l_0 - l_p)^2}{N}}$$

$$R = \frac{\sum_{i=1}^N (l_0 - \bar{l}_0) \times (l_p - \bar{l}_p)}{\sqrt{\sum_{i=1}^N (l_0 - \bar{l}_0)^2 \times (l_p - \bar{l}_p)^2}}$$

که در آن‌ها، l_0 مقدار اندازه‌گیری شده، \bar{l}_0 متوسط مقدار اندازه‌گیری شده، l_p مقدار پیش‌بینی شده، \bar{l}_p متوسط مقدار پیش‌بینی شده و N تعداد داده‌ها است.

نتایج و بحث

تعریف مدل‌های ورودی: در پژوهش حاضر، برای مدلسازی بیشینه دمای روزانه به صورت زمانی از پارامترهای دمای بیشینه $T_{max}(t)$ و کمینه $T_{min}(t)$ ، بارش $P(t)$ و تابش خورشیدی $S(t)$ استفاده شده است. به این ترتیب که بیشینه دمای یک روز، تابع پارامترهای هواشناسی در همان روز (t) و یک روز قبل $(t-1)$ و همچنین، دو روز قبل $(t-2)$ است. این مدلسازی در دو اقلیم نیمه خشک و مرطوب، مورد ارزیابی قرار گرفته است. در تمامی مدلسازی‌ها، پس از نرمالیزه کردن داده‌ها، ابتدا سری‌های زمانی به وسیله تبدیل موجک و تجزیه یکپارچه مد تجزیه کامل، به زیر سری‌هایی تجزیه شده است، سپس، این زیرسری‌ها به عنوان ورودی مدل LSTM استفاده شد. جدول ۲، بیان‌گر مدل‌های تعریف شده است. لازم به توضیح است که داده‌های سری زمانی دما از سال ۲۰۰۱ تا ۲۰۱۴، به عنوان داده‌های آموزش و بقیه داده‌ها از سال ۲۰۱۴ تا ۲۰۲۰، به عنوان داده‌های آزمون مورد استفاده قرار گرفته‌اند.

$$\begin{aligned} f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\ i_t &= \sigma(W_i x_t + U_i h_{t-1} + b_i) \\ o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\ \tilde{c}_t &= \sigma_h(W_z x_t + U_z h_{t-1} + b_z) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ h_t &= o_t \odot \sigma_h(c_t) \end{aligned} \quad (3)$$

در روابط بالا، x_t بردار ورودی، h_t بردار حالت مخفی یا بردار خروجی نهایی، f_t بردار فعال‌ساز گیت فراموشی، i_t بردار فعال‌ساز گیت ورودی، o_t بردار فعال‌ساز گیت خروجی، \tilde{c}_t بردار فعال‌ساز ورودی سلول، h_{t-1} بردار فعال‌ساز خروجی سلول، c_t بردار حالت سلول، W_f, W_i, W_o, W_z ماتریس‌های وزنی قابل یادگیری بین ورودی و بردارهای مربوطه، U_f, U_i, U_z و U_o ماتریس‌های وزنی قابل یادگیری بین خروجی و بردارهای مربوطه با یک واحد تاخیر زمانی، b_f, b_i, b_o, b_z بردارهای بایاس، σ و σ_h تابع فعال‌ساز سیگموئید و تانژانت هیپربولیک، \odot ضرب نقطه ای دو بردار را نشان می‌دهد.

نرمالیزه کردن داده‌ها: یکی از مراحل اصلی در استفاده از روش‌های هوشمند، پیش‌پردازش داده‌ها است. با توجه به دامنه وسیع داده‌های ورودی و به منظور افزایش دقت و سرعت مدلسازی، داده‌های مورد استفاده در این پژوهش، با استفاده از رابطه (۴) بین بازه ۰/۱ تا ۱، نرمال شده‌اند و در نهایت، مجموع داده‌های فوق برای مدلسازی به کار گرفته شدند.

$$X_{istd} = 0.1 + 0.9 \times \left[\frac{X_i - X_{i \min}}{X_{i \max} - X_{i \min}} \right] \quad (4)$$

که در آن، $X_{i \min}$ کمترین داده و $X_{i \max}$ بیشترین داده از نظر مقدار است (Roushangar and Shahnazi, 2019). **معیارهای ارزیابی:** به منظور ارزیابی دقت و کارایی مدل از طریق مقایسه داده‌های مشاهداتی و شبیه‌سازی شده، از سه پارامتر آماری استفاده شد که عبارت‌اند از ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی^۱، ضریب تبیین که همبستگی بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد و یکی از معیارهای مهم ارزیابی، قابلیت یک مدل^۲ است و ریشه میانگین مربعات خطاها^۳ که بیانگر

³ Root Mean Squar Error (RMSE)

¹ Correlation Coefficient (R)

² Coefficient of Determination (DC)

جدول ۲- مدل‌های تعریف شده

Table 2. Defined models

Model	Input	Aim
T(I)	T min(t), p(t), S(t)	T max(t)
T(II)	T min(t), p(t), S(t), S(t-1)	T max(t)
T(III)	T min(t), p(t), S(t), S(t-1), S(t-2)	T max(t)
T(IV)	T min(t), T min(t-1), S(t), S(t-1), S(t-2)	T max(t)
T(V)	T min(t), T min(t-1), S(t), S(t-1), S(t-2), T max(t-1)	T max(t)
T(VI)	T min(t), T min(t-1), p(t), S(t)	T max(t)
T(VII)	T min(t), T min(t-1), p(t), S(t), T max(t-1)	T max(t)
T(VIII)	T min(t), T min(t-1), p(t), p(t-1), p(t-2)	T max(t)
T(IX)	T min(t), T min(t-1), S(t), T max(t-1), T max(t-2)	T max(t)
T(X)	T min(t), T min(t-1), T min(t-2), S(t)	T max(t)
T(XI)	T min(t), T min(t-1), T min(t-2), S(t), T max(t-1), T max(t-2)	T max(t)
T(XII)	T min(t), T min(t-1), S(t), T max(t-1)	T max(t)
T(XIII)	T min(t), T min(t-1), T min(t-2), T max(t-1), T max(t-2)	T max(t)
T(XIV)	p(t), S(t), S(t-1), S(t-2), T max(t-1)	T max(t)
T(XV)	T min(t), T min(t-1), T min(t-2), p(t), S(t)	T max(t)

سپس، این مدل‌ها با روش LSTM تحلیل شد و نتایج حاصل از تحلیل مدل‌ها در جدول ۳، نشان داده شد. با توجه به نتایج به‌دست آمده از سه معیار ارزیابی مدل برای داده‌های آموزش و آزمون، مشاهده می‌شود که نتایج برای مدل T(IX) برای اقلیم مرطوب و T(XI) برای اقلیم نیمه‌خشک از مدل‌های دیگر بهتر است.

نتایج به‌دست آمده برای مدل LSTM بدون تجزیه داده‌ها: برای تخمین میزان دمای بیشینه، بر اساس سری زمانی اصلی و بدون تجزیه آن به چندین زیر سری، (۱۵ مدل) بر اساس داده‌های روزانه دمای بیشینه، دمای کمینه، بارش، تابش خورشیدی مربوط به روزهای قبل، تعریف شد و کارایی روش LSTM مورد بررسی قرار گرفت.

جدول ۳- نتایج ارزیابی مدل‌سازی زمانی بدون تجزیه داده‌ها

Table 3. Evaluation results of temporal modeling without data analysisw

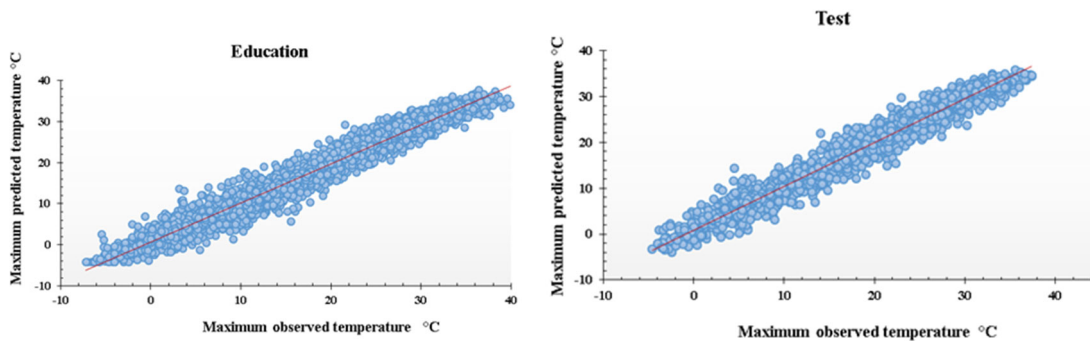
Area	Model	Education			Test		
		DC	R	RMSE	DC	R	RMSE
Semi-arid	T(I)	0.9379	0.9697	2.5816	0.9263	0.9679	2.8355
	T(II)	0.9395	0.9732	2.5522	0.9212	0.9704	2.9474
	T(III)	0.9355	0.9739	2.6417	0.9137	0.9707	3.1012
	T(IV)	0.9463	0.9741	2.3986	0.9440	0.9717	2.4611
	T(V)	0.9679	0.9839	1.8523	0.9640	0.9824	1.9751
	T(VI)	0.9417	0.9708	2.4976	0.9337	0.9696	2.6857
	T(VII)	0.9666	0.9839	1.8891	0.9639	0.9831	1.9748
	T(VIII)	0.9462	0.9735	2.3981	0.9358	0.9719	2.6466
	T(IX)	0.9609	0.9829	2.0492	0.9618	0.9820	2.0350
	T(X)	0.9375	0.9690	2.5847	0.9343	0.9674	2.6679
	T(XI)	0.9661	0.9831	1.9026	0.9651	0.9824	1.9435

ادامه جدول ۳
Table 3 Continued

Wet	T(XII)	0.9490	0.9758	2.3384	0.9468	0.9743	2.3985
	T(XIII)	0.9417	0.9763	2.5109	0.9381	0.9752	2.6050
	T(XIV)	0.9616	0.9811	2.0259	0.9575	0.9789	2.1436
	T(XV)	0.9418	0.9720	2.4937	0.9390	0.9694	2.5698
	T(I)	0.9203	0.9595	2.5605	0.8994	0.9532	3.0332
	T(II)	0.9218	0.9611	2.5376	0.9051	0.9535	2.9392
	T(III)	0.9243	0.9617	2.4965	0.9008	0.9541	3.0147
	T(IV)	0.9321	0.9658	2.3646	0.9112	0.9580	2.8448
	T(V)	0.9333	0.9667	2.3452	0.9215	0.9605	2.6689
	T(VI)	0.9235	0.9647	2.5190	0.9138	0.9564	2.7953
	T(VII)	0.9350	0.9677	2.3138	0.9246	0.9626	2.6163
	T(VIII)	0.9303	0.9651	2.3969	0.9186	0.9603	2.7209
	T(IX)	0.9344	0.9679	2.3262	0.9257	0.9622	2.5954
	T(X)	0.9283	0.9647	2.4332	0.9177	0.9585	2.7336
	T(XI)	0.9338	0.9671	2.3355	0.9244	0.9618	2.6191
T(XII)	0.8943	0.9470	2.9539	0.8836	0.9400	3.2496	
T(XIII)	0.8939	0.9486	2.9639	0.8848	0.9411	3.2337	
T(XIV)	0.8609	0.9344	3.4078	0.8623	0.9323	3.5480	
T(XV)	0.9288	0.9654	2.4248	0.9186	0.9589	2.7187	


همان روز، به‌عنوان مدل برتر شناخته شد. نتایج مربوط به اقلیم نیمه‌خشک از نتایج مربوط به اقلیم مرطوب به مراتب بهتر است. نتایج مربوط به دو ایستگاه سینوپتیک برای سری داده‌های آموزش و آزمون در شکل‌های ۳ و ۴ نشان داده شده است.

بنابراین، نتیجه گرفته می‌شود که در منطقه نیمه‌خشک، پارامترهای دمای بیشینه و کمینه دو روز قبل، دمای بیشینه و کمینه یک روز قبل، دمای کمینه و تابش خورشیدی همان روز و در منطقه مرطوب پارامترهای دمای بیشینه دو روز قبل، دمای بیشینه و کمینه یک روز قبل، دمای کمینه و تابش خورشیدی



شکل ۳- نتایج مرحله آموزش و آزمون مدل برتر T(XI) در ایستگاه سینوپتیک فرودگاه ارومیه بدون تجزیه داده‌ها


Figure 3- The results of the training and testing phase of the superior T(XI) model at the Urmia airport synoptic station without data analysis




شکل ۴- نتایج مرحله آموزش و آزمون مدل برتر T(IX) در ایستگاه سینوپتیک سیاه‌بیشه آمل بدون تجزیه داده‌ها
 Fig. 4. The results of the training and testing stage of the superior T(IX) model at Siyabishheh Amol Synoptic Station without data analysis

یک سیگنال باقی‌مانده است که در مجموع این‌ها، همان سیگنال اصلی خواهد بود. روش تشکیل IMFها بر اساس تفریق تابع پایه از سیگنال اصلی است. این فرایند تا وقتی ادامه می‌یابد که تقریباً سیگنال باقی‌مانده، ثابت شود. در آخر، زیر سری‌های به‌دست آمده از هر دو روش، به‌عنوان ورودی به مدل LSTM داده شد. به‌عنوان مثال، پیش پردازش سری‌های زمانی، پارامتر بیشینه دمای ایستگاه ارومیه در مقیاس روزانه به‌وسیله تبدیل موجک و همچنین، تجزیه مد تجزیه در شکل‌های ۵ و ۶، نشان داده شده است.

نتایج به‌دست آمده برای مدل LSTM پس از تجزیه داده‌ها: در این قسمت، با استفاده از دو روش تجزیه یکپارچه مد تجزیه کامل و تبدیل موجک گسسته، ابتدا سری‌های زمانی تجزیه شد و سپس، زیر سری‌های به‌دست آمده به‌عنوان ورودی به مدل LSTM داده شد. مدلسازی نیز در دو حالت اقلیم نیمه‌خشک و مرطوب انجام شد. اولین قدم برای تجزیه سیگنال با تبدیل موجک، انتخاب کردن موجک مادر است. در این پژوهش، از موجک مادر db4 با سه سطح تجزیه استفاده شد. اساس روش CEEMD نیز تجزیه سیگنال به IMFهای مختلف و



شکل ۵- زیر سری تجزیه‌شده پارامتر بیشینه دما در ایستگاه سینوپتیک فرودگاه ارومیه با استفاده از تبدیل موجک گسسته
 Fig. 5. Decomposed subseries of the maximum temperature parameter at Urmia Airport Synoptic Station using discrete wavelet transform



شکل ۶- زیر سری تجزیه‌شده پارامتر بیشینه دما در ایستگاه سینوپتیک فرودگاه ارومیه با استفاده از تجزیه مد تجربی یکپارچه کامل
Fig. 6. Decomposed subseries of the maximum temperature parameter at Urmia Airport Synoptic Station using fully integrated empirical mode analysis

مطابق نتایج به‌دست آمده، مدل‌های $T(IX)$ و $T(XI)$ ، برترین مدل بوده و طبق نتایج، بدون پیش‌پردازش تغییر نوع اقلیم تاثیر چندانی بر روی نتایج ندارد، ولی مدل برتر در ایستگاه ارومیه در اقلیم نیمه‌خشک نتایج بهتری نسبت به ایستگاه سیاه‌بیشه در اقلیم مرطوب دارد.

نتایج حاصل از مدلسازی پس از پردازش داده‌ها به وسیله تبدیل موجک گسسته و تجزیه مد تجربی برای سه مدل برتر برای هر منطقه در جدول‌های ۴ و ۵، آمده است. همان‌طور که در نتایج نیز مشاهده می‌شود، تجزیه سری‌های زمانی تا حدودی باعث بهبود نتایج شده و تاثیر تجزیه با استفاده تبدیل موجک گسسته بیشتر از روش تجزیه مد تجربی کامل است.

جدول ۴- نتایج ارزیابی مدلسازی زمانی پس از تجزیه داده‌ها برای سه مدل برتر (DWT)

Table 4. Time modeling evaluation results after data analysis for the top three models (DWT)

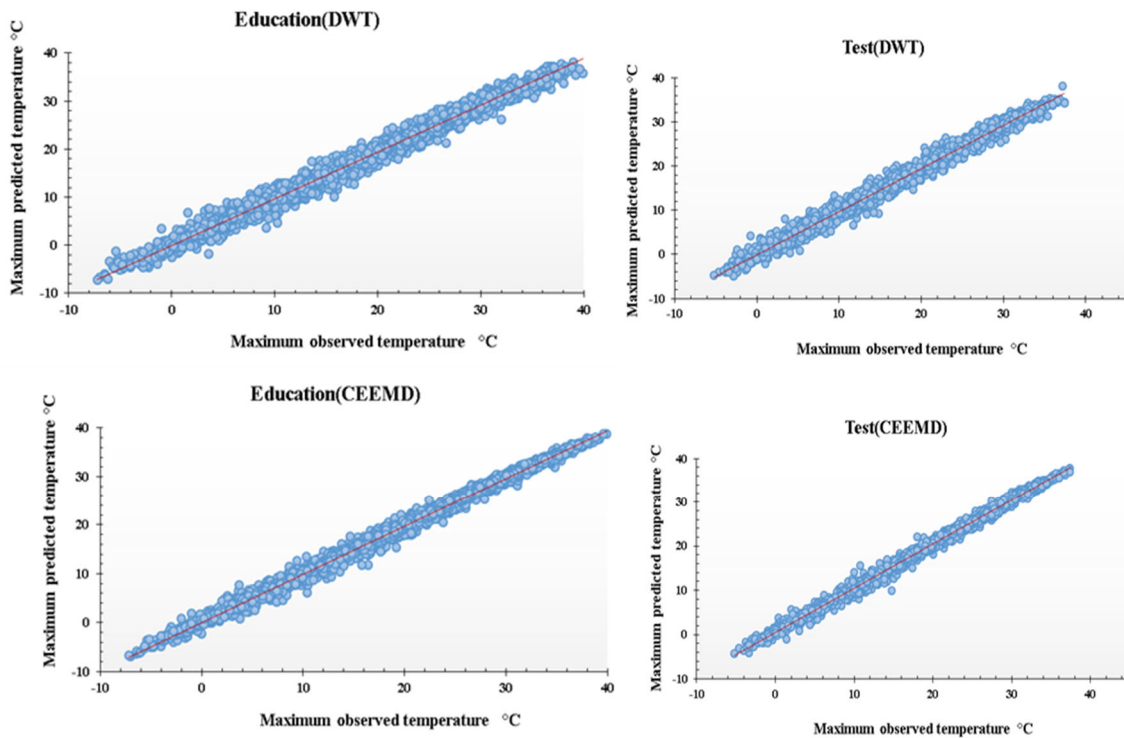
Area	Model	Education			Test		
		DC	R	RMSE	DC	R	RMSE
Semi-arid	T(XI)	0.9861	0.9947	1.2213	0.9851	0.9938	1.2712
	T(IX)	0.9861	0.9938	1.2206	0.9833	0.9928	1.3456
	T(XIII)	0.9831	0.9937	1.3478	0.9816	0.9929	1.4123
Wet	T(IX)	0.9770	0.9897	1.3770	0.9695	0.9865	1.6642
	T(XI)	0.9701	0.9870	1.5734	0.9695	0.9857	1.6658
	T(XIII)	0.9711	0.9859	1.5426	0.9694	0.9848	1.6669

جدول ۵- نتایج ارزیابی مدلسازی زمانی پس از تجزیه داده‌ها برای سه مدل برتر (CEEMD)

Table 5. Time modeling evaluation results after data analysis for the top three models (CEEMD)

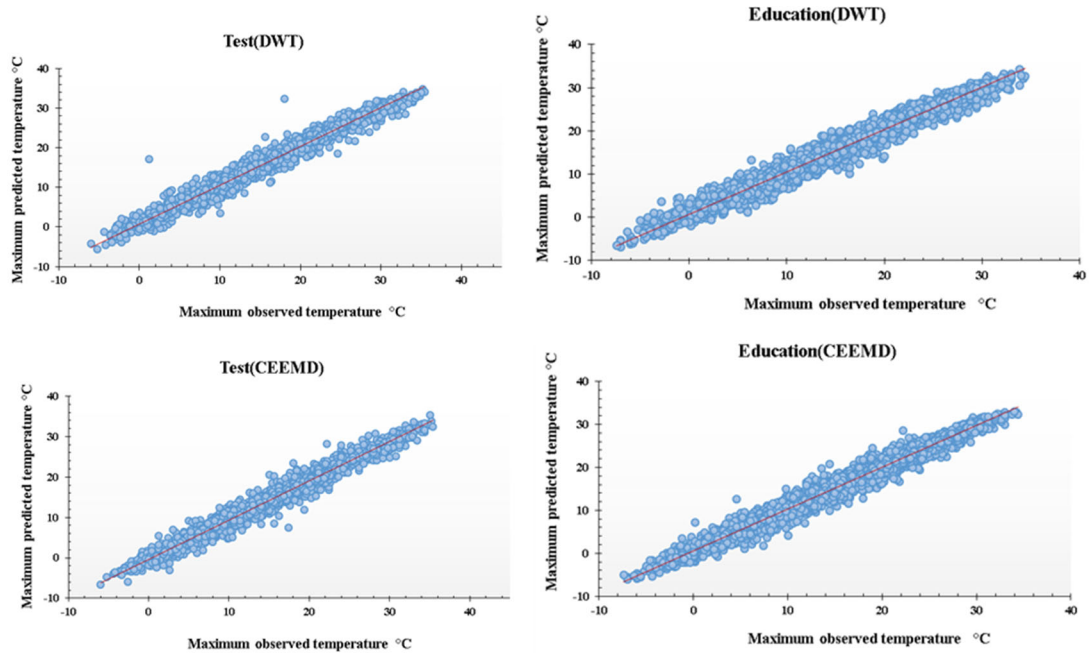
Area	Model	Education			Test		
		DC	R	RMSE	DC	R	RMSE
Semi-arid	T(XI)	0.9957	0.9980	0.6766	0.9926	0.9975	0.8965
	T(IX)	0.9938	0.9980	0.8160	0.9855	0.9976	1.2565
	T(XIII)	0.9884	0.9977	1.1164	0.9798	0.9978	1.4892
Wet	T(IX)	0.9745	0.9885	1.4520	0.9702	0.9865	1.6478
	T(XI)	0.9755	0.9887	1.4218	0.9644	0.9859	1.8051
	T(XIII)	0.9717	0.9876	1.5291	0.9632	0.9857	1.8349

بنابراین، نتیجه گرفته می‌شود که در منطقه نیمه‌خشک، بیشینه دما در یک روز، تابعی از دمای بیشینه و کمینه دو روز قبل، دمای بیشینه و کمینه یک روز قبل، دمای کمینه و تابش خورشیدی همان روز و همچنین، در منطقه مرطوب، بیشینه دما در یک روز تابعی از دمای بیشینه دو روز قبل، دمای بیشینه و کمینه یک روز قبل و دمای کمینه و تابش خورشیدی همان روز خواهد بود. بدین منظور، مقایسه نتایج دو ایستگاه سینوپتیک پس از پردازش داده‌ها به دو روش ذکر شده در شکل‌های ۷ و ۸، آورده شده است.



شکل ۷- نتایج مرحله آموزش و آزمون مدل برتر T(IX) در ایستگاه سینوپتیک فرودگاه ارومیه پس از تجزیه داده‌ها

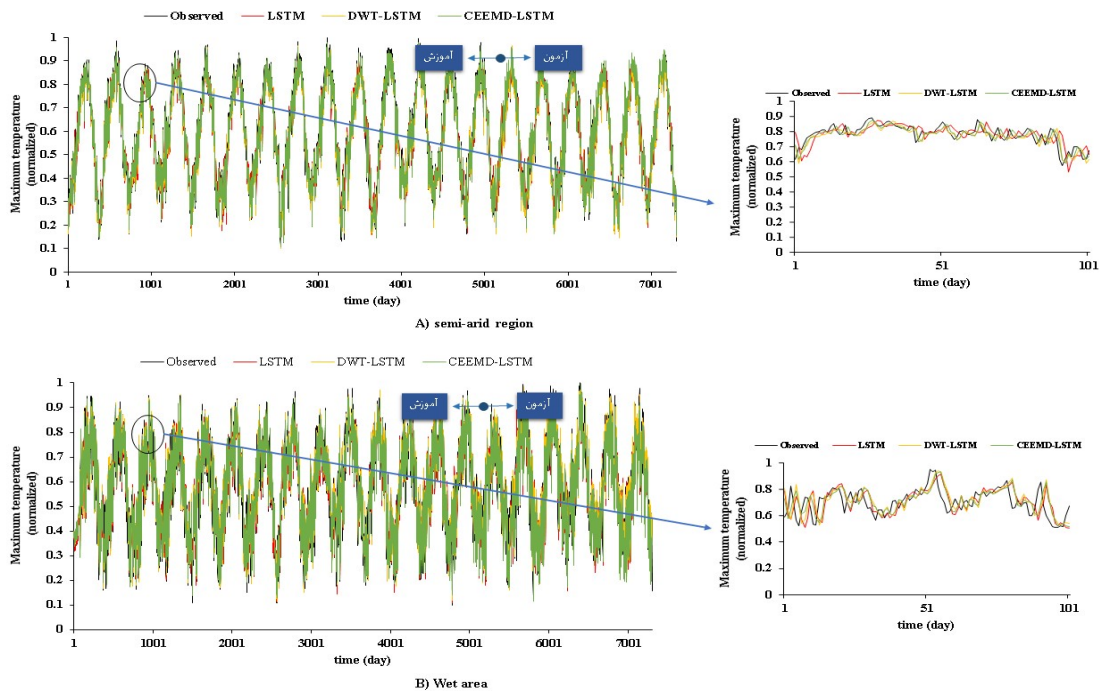
Fig. 7. The results of the training and test phase of the superior model T(IX) at the Urmia Airport Synoptic Station after data analysis



شکل ۸- نتایج مرحله آموزش و آزمون مدل برتر T(IX) در ایستگاه سینوپتیک سیاه‌بیشه آمل پس از تجزیه داده‌ها
 Fig. 8. The results of the training and testing stage of the superior T(IX) model at the Siah Bisheh Amel synoptic station after data analysis

دمای بیشینه در دو منطقه نیمه‌خشک و مرطوب در شکل ۹، آورده شده است.

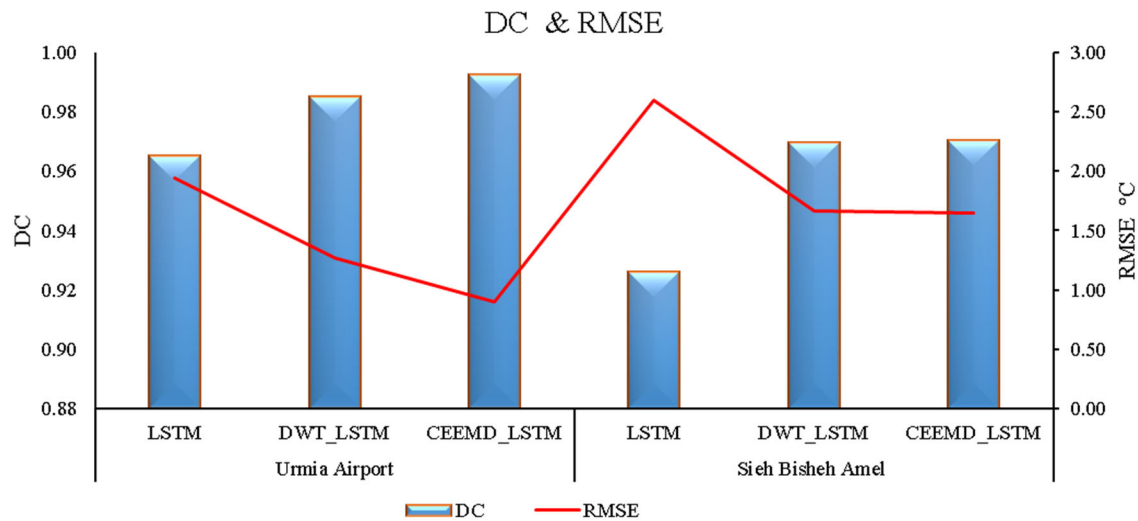
مقایسه نتایج: به‌منظور مقایسه نتایج به‌دست آمده از روش‌های مختلف، نتایج مربوط به مدلسازی سری زمانی



شکل ۹- مقایسه نتایج مرحله آموزش و آزمون مدل برتر T(IX) و T(XI) بدون تجزیه و پس از تجزیه داده‌ها با تبدیل موجک و تجزیه مد تجزیه‌ی
 Fig. 9. Comparison of the results of the training and test phase of the superior model T(XI) and T(IX) without analysis and after data analysis with wavelet transformation and empirical mode analysis

برترین مدل ارزیابی شد. با توجه به نتایج ایستگاه سینوپتیک فرودگاه ارومیه، معیار DC از ۰/۹۶۵ به ۰/۹۹۳ در تبدیل موجک و در ایستگاه سیاه‌بیشه آمل، از ۰/۹۲۶ به ۰/۹۷۰ افزایش یافته و معیار RMSE در فرودگاه ارومیه از ۱/۹۴۳ به ۰/۸۹۶ و در سیاه‌بیشه از ۲/۵۹۵ به ۱/۶۴۸ کاهش یافته است. اگرچه در هر دو نوع مدل‌سازی، پردازش داده‌ها باعث بهبود نتایج شده است، اما مدل‌سازی با استفاده از تبدیل موجک، موجب کاهش RMSE و افزایش مقدار DC شده است.

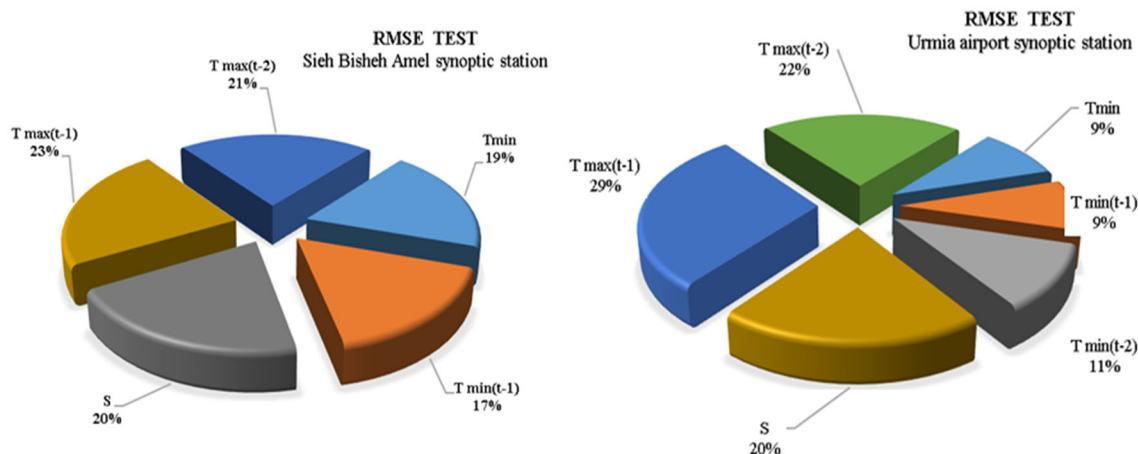
در این پژوهش، با استفاده از روش‌های مبتنی بر AI مانند روش حافظه طولانی-کوتاه-مدت و مدل‌های ترکیبی موجک (LSTM) و تجزیه مد تجزیه (LSTM)، نسبت به پیش‌بینی بیشینه دما در دو اقلیم مختلف پرداخته شد. نتایج معیارهای ارزیابی برای مرحله آزمون مدل‌های برتر با استفاده از روش‌های مذکور در شکل ۱۲ آورده شده است. مطابق نتایج مشاهده شده در شکل ۱۰، در اقلیم مرطوب، مدل T(XI) و اقلیم نیمه‌خشک، مدل T(IX) با داشتن بیشترین DC و کمترین RMSE، به‌عنوان



شکل ۱۰- مقایسه معیارهای ارزیابی برای سه روش LSTM، DWT_LSTM و CEEMD_LSTM برای مدل برتر در دو اقلیم
 Fig. 10. Comparison of evaluation criteria for the three methods LSTM, DWT_LSTM and CEEMD_LSTM for the superior model in two climates

دقت مدل، مورد بررسی قرار گرفت. نتایج حاصل از تحلیل حساسیت به‌صورت شکل ۱۱، ارائه شده است. همان‌طور که از شکل ۱۱ مشخص است، با حذف پارامتر $T_{max}(t-1)$ ، دقت مدل تا حدود زیادی کاهش یافته است. بنابراین، می‌توان نتیجه گرفت که پارامتر $T_{max}(t-1)$ بیشترین تاثیر را در تخمین میزان بیشینه دمای روزانه دارد.

تحلیل حساسیت: برای بررسی تاثیر پارامترهای به‌کار رفته در مدل برتر، مدل T(IX) برای منطقه مرطوب و مدل T(XI) برای منطقه نیمه‌خشک در حالت تجزیه با تبدیل موجک گسسته، در هر دو اقلیم متفاوت، تحلیل حساسیت انجام گرفت. برای این منظور، با حذف تک‌تک پارامترهای مدل برتر، اجرای دوباره مدل و تعیین معیار ارزیابی RMSE، میزان تاثیر پارامتر حذف شده در کاهش



شکل ۱۱- تاثیر نسبی هر یک از پارامترهای ورودی مدل برتر در ایستگاه سینوپتیک فرودگاه ارومیه و سیاه‌بیشه آمل
 Fig. 11. The relative influence of each of the input parameters of the superior model at the Synoptic Station of Urmia and Siah Bisheh Amol Airports

افزایش معیار ارزیابی DC و کاهش RMSE برای ایستگاه سینوپتیک فرودگاه ارومیه به ترتیب به مقدار ۲/۷۴ و ۵۳/۸۷ درصد و برای ایستگاه سینوپتیک سیاه‌بیشه آمل به ترتیب به مقدار ۴/۸۰ و ۳۵/۵۰ درصد به دست آمد و نشان داد که تبدیل موجک، بیشترین تاثیر را در بهبود عملکرد مدل LSTM دارد و مدل‌های منتخب قابلیت و کارایی بالایی در تخمین میزان دمای بیشینه دارند که با پژوهش‌های صورت گرفته توسط Mirzania et al., (2021) و Saghebian (2020) در خصوص بهبود عملکرد تاثیر موجک بر افزایش دقت مدل‌های تخمینی در مدلسازی همخوانی دارد. با توجه به نتایج تحلیل حساسیت مشخص شد، پارامتر $T_{max}(t-1)$ تاثیرگذارترین پارامتر در تخمین بیشینه دمای روزانه برای دو منطقه است.

تشکر و قدردانی

بدین‌وسیله نویسندگان این پژوهش، از کلیه عزیزانی که در تهیه این پژوهش یاری نموده‌اند، کمال تشکر را دارند.

نتیجه‌گیری

هدف از این پژوهش، مدلسازی بیشینه دما و بررسی عملکرد مدل LSTM و پیش‌پردازنده DWT و EMD برای دو منطقه با اقلیم‌های متفاوت در کشور ایران است. در این پژوهش، به‌منظور دستیابی به این اهداف، ابتدا داده‌های اقلیمی دما، بارش و ساعات آفتابی طی دوره ۲۰۰۱ تا ۲۰۲۰، از سازمان هواشناسی برای دو منطقه اخذ شد. برای دو ایستگاه سینوپتیک واقع در دو منطقه، مدلسازی دمای بیشینه روزانه طی دوره ۲۰۰۱ تا ۲۰۲۰، با استفاده از حافظه طولانی-کوتاه (LSTM) صورت گرفت.

برای ارزیابی مدل‌های سری زمانی تعریف شده برای دو منطقه، مدل $T(XI)$ برای منطقه نیمه‌خشک شامل پارامترهای دمای بیشینه و کمینه دو روز و یک روز قبل و دمای کمینه و تابش خورشیدی همان روز با DC به مقدار ۰/۹۶۵ و RMSE ۱/۹۴۳ و همچنین، مدل $T(IX)$ برای منطقه مرطوب شامل پارامترهای دمای بیشینه دو روز قبل، دمای بیشینه و کمینه یک روز قبل، دمای کمینه و تابش خورشیدی همان روز با DC به مقدار ۰/۹۲۶ و RMSE ۲/۵۹۵، به‌عنوان مدل‌های برتر شناخته شدند.

سپس، مدلسازی با استفاده از تجزیه داده‌های سری زمانی با تبدیل موجک و تجزیه مد تجربی به‌صورت جداگانه مورد بررسی قرار گرفت و نتایج بررسی نشان از

تعارض منافع

مورد تایید همه نویسندگان است.

در این مقاله تضاد منافی وجود ندارد و این مساله

منابع مورد استفاده

- Alizadeh, M.J., Kavianpour, M.R., Kisi, O., Nourani, V., 2017. A new approach for simulating and forecasting the rainfall-runoff process within the next two months. *J. H.* 548, 588-597.
- Amirat, Y., Benbouzid, M.E.H., Wang, T., Bacha, K., Feld, G.J.A.A., 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133, 202-209.
- Ashour, M.A., ElZahaby, S.A., Abdalla, M.I., 2016. Backpropagation neural network approach for mean temperature prediction. *Inter. J. Recent Res. Appli. Studies* 29, 12-18.
- Behmanesh, J., Azad Talatappeh, N., Montaseri, M., Rezayi, H., Khalili, K., 2015. Climate change impact on reference evapotranspiration, precipitation deficit and vapor pressure deficit in Urmia. *Water Soil Sci.* 25(2), 79-91.
- Chung, J., Gulcehre, C., Cho, K., Bengio, Y., 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv Preprint* 1412, 3555.
- Deng, L., Yu, D., 2014. Deep learning: methods and applications. *Found. Trends Signal Process.* 7(3-4), 197-387.
- Esfandiari, D.F., Hosseni, S.A., Azadi, M.M., Hejazizadeh, Z., 2011. Prediction of monthly average temperature through Artificial Neural Network Multilayer Perceptron (MLP). *Water* 13(9), 1294 (in Persian).
- Feng, H., Liu, Y., 2015. Combined effects of precipitation and air temperature on soil moisture in different land covers in a humid basin. *J. H.* 531, 1129-1140.
- Felix, A.G., Jürgen, S., Fred, C., 2000. Learning to forget: continual prediction with LSTM. *Neural Comput.* 12(10), 2451-2471.
- Ghorbani, M., Shiri, J., Kazemi, H., 2010. Estimation of maximum, mean and minimum air temperature in Tabriz city using artificial intelligent methods. *Water Soil Sci.* 20(3), 87-104 (in Persian).
- Graves, A., Schmidhuber, J., 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Netw.* 18(5-6), 602-610.
- Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., Schmidhuber, J., 2008. A novel connectionist system for unconstrained handwriting recognition. *IEEE Trans. Pattern Anal.* 31(5), 855-868.
- Gers, F., Schmidhuber, J., Cummins, F., 2000. Learning to Forget: Continual Prediction with LSTM. *Neural Comput.* 12:2451-71.
- Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural Comput.* 9(8), 1735-1780.
- IPCC, 2001. Climate change: the scientific basis, contribution of working group to the third assessment report of the intergovernmental panell on climate change. Cambridge Univ. Press, New York, NY, USA, 881 pages.
- Karen, A., Latinez, S., 2010. Comparison of adaptive methods using Multivariate Regression Splines (MARS) and Artificial Neural Networks Backpropagation (ANNB) for the forecast of rain and temperatures in the Mantaro River Basin. *Hydrol. Days* 58-68.
- Karthika, B.S., Deka, P.C., 2016. Modeling of air temperature using ANFIS by wavelet refined parameters. *Int. J. Intell. Syst. Appl.* 8(1), 25.
- Kisi, O., Cimen, M., 2011. A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *J. Hydrol.* 399(1-2), 132-140.
- Lashanizand, M., Payamani, K., Ahmadi, S., Veyskarami, I., 2014. Ecological climate zonation of Iran. *Watershed Eng. Manage.* 6(2), 175-189 (in Persian).
- Li, X., Wu, X., 2015. Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* 4520-4524 pages.
- Mirzania, E., Malek Ahmadi, H., Shahmohammadi, Y., Ebrahim Zadeh, A., 2021. Impact of wavelet on accuracy of estimated models in rainfall-runoff modeling, case study: Sufi Chay. *Water Soil Manage. Modell.* 1(3), 67-79.
- Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M., 1996. Wavelet toolbox for use with matlab. The Mathworks, Inc. Natick, Massachusetts, USA.
- Omid Ghaleh Mohammadi, S., Mazidi, A., Karemi, S., Hassani Sadi, N., Omid Ghaleh Mohammadi, M., Kharajpor, H., 2022. Estimating daily maximum temperatures using artificial networks, case study: Kerman. *Territory* 19(73), 109-120 (in Persian).

- Peixoto, J.P., Oort, A.H., Lorenz, E.N., 1992. *Physics of climate*, Vol. 520. New York: American Institute of Physics.
- Roushangar, K., Shahnazi, S., 2019. Evaluating the performance of data-driven methods for prediction of total sediment load in gravel-bed rivers. *Iran. J. Soil Water Res.* 50(6), 1467-1477.
- Saghebian, S., 2020. Temporal and spatial Flow discharge prediction using integrated artificial intelligence and pre and post-processing time series methods. *Iran. J. Irrigation Drainage* 14(4), 1137-1151(in Persian).
- Sak, H., Senior, A.W., Beaufays, F., 2014. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Interspeech* 338-342 pages.
- Sharifi, S.S., Rezaverdinejad, V., Nourani, V., 2016. Estimation of daily global solar radiation using wavelet regression, ANN, GEP and empirical models: a comparative study of selected temperature-based approaches. *J. Atmos. Sol. Terr. Phys.* 149, 131-145.
- Wu, Z., Huang, N.E., 2004. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 460(2046), 1597-1611.
- Yadav, B., Eliza, K., 2017. A hybrid wavelet-support vector machine model for prediction of lake water level fluctuations using hydro-meteorological data. *Measurement* 103, 294-301.
- Zhang, Z., Dong, Y., 2020. Temperature forecasting via convolutional recurrent neural networks based on time-series data. *Complexity*, 2020, 3536572.