

Research paper**Drought prediction using a collaborative LSTM model (Case study: North of Isfahan province)****M. Ghabraie¹, A. Ranjbar Fordoei^{2*} and M. Ehteram³****Extended Abstract****Introduction:**

Drought is a natural phenomenon that significantly impacts human life and ecosystems. Lack of rainfall can cause various problems, including damage to crops and a shortage of drinking water for local communities. These effects can lead to devastating economic and social disasters, such as famine, forced migration away from drought-affected areas, and conflicts over remaining resources. Predicting drought indices, such as the Standardized Precipitation Index (SPI), is crucial for assessing this phenomenon in water resource management. The SPI is a tool for evaluating and measuring the intensity and duration of drought, allowing for drought analysis on both short-term and long-term time scales, and providing accurate information on drought severity to water resource managers and policymakers. However, predicting the SPI can be challenging due to the complex interactions of influencing factors. While deep learning models, especially Long Short-Term Memory (LSTM) networks, have shown promise in predicting SPI, they also have key limitations. First, the LSTM model has parameters that need fine-tuning. Second, selecting the best input combination for the LSTM model is complex and challenging. The inputs required for drought prediction are usually associated with various time lags. Choosing the best input combination from a large number of inputs is important, as it affects the performance of the LSTM model. The third challenge is that the LSTM model lacks connections that directly transfer information from the model's memory to its computation gates, which can lead to the loss of important information.

Materials and Methods:

This study investigates the challenges and aims to improve the performance of the Long Short-Term Memory (LSTM) model in predicting the drought index (SPI) at 3-, 6-, and 9-month time scales (SPI-3, SPI-6, and SPI-9) in the northern region of Isfahan Province. To achieve this, a novel "Collaborative LSTM" model was proposed and a binary genetic algorithm was developed. Various large-scale climate indices were utilized as input data for the prediction models. To optimize model performance, the binary genetic algorithm was

1- Ph.D. Student, Department of Desert Management and Control, Faculty of Natural Resources and Earth Sciences, University of Kashan, Kashan, Iran.

2- Professor of Desert Dynamics, Department of Arid Environments, Faculty of Natural Resources and Earth Sciences, University of Kashan.

3- PhD in Water Resources Engineering and Management, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan, Iran.

* Corresponding Author: aranjbar@kashanu.ac.ir

Received: 2024/10/176

Accepted: 2025/01/09

employed to select the optimal input scenario and fine-tune the model parameters. In the first step, the input data, including time series, were divided into training and test datasets. Eighty percent of the input data were selected for training, and twenty percent were used for testing to minimize prediction error. The algorithm then selected the best input parameters from large-scale climate signals with different delays. Each chromosome comprised two parts: the first part contained the model inputs, and the second part contained the initial parameter values. Binary chromosomes were encoded based on 0 and 1 values, indicating the absence or presence of a factor in the modeling process, respectively. Each binary value in the second part determined how the initial value of a particular parameter was chosen. A new version of the LSTM model was then built with three additional weighted connections compared to the original LSTM model. The Collaborative LSTM incorporates three novel weight connections that facilitate the flow of crucial information from the memory cell to the input, forget, and output gates, enhancing information retention and improving prediction accuracy. The performance of the Collaborative LSTM was compared against traditional LSTM, Multilayer Perceptron (MLP), Radial Basis Function Neural Network (RBFNN), and Multiple Linear Regression (MLR) models. Multiple error metrics were used to assess model accuracy. The modeling process involved a multi-step approach: (1) optimal input scenario selection using the binary genetic algorithm, (2) model parameter optimization using the genetic algorithm, and (3) development and evaluation of the Collaborative LSTM model for SPI prediction.

Result and Discussion:

The results demonstrated the effectiveness of the binary genetic algorithm in optimizing both input selection and model parameters. The Collaborative LSTM consistently outperformed other models, achieving a 2.1-6.1% improvement in the Willmott Index (WI) for SPI-3, 1.1-5.1% for SPI-6, and 1.1-2.2% for SPI-9. Statistical analysis revealed that the predicted SPI values from the Collaborative LSTM closely resembled the observed SPI data. The superior performance of the Collaborative LSTM can be attributed to its enhanced information flow architecture, which enables more effective utilization of past information stored in the memory cell. Boxplots further visualized the improved accuracy of the Collaborative LSTM in predicting SPI values across different scenarios. The findings of this study demonstrate the potential of the Collaborative LSTM model as a reliable tool for accurate drought index forecasting. By addressing the limitations of traditional LSTMs and incorporating optimized input selection and parameter tuning, this novel approach offers significant advancements in drought prediction capabilities.

Keywords: Drought, Predictive models, Drought index deep, Learning models.

Citation: Ghabraie, M., Ranjbar Fordoei, A. and Ehteram M., 2025. Drought prediction using a collaborative LSTM model (Case study: North of Isfahan province). *Iranian Water Research Journal*, 56, pp. 3-15. <https://dx.doi.org/10.22034/IWRJ.2025.14963.2637>



مقاله پژوهشی

پیش‌بینی شاخص خشکسالی با استفاده از مدل همکارانه LSTM (مطالعه موردی: شمال استان اصفهان)

ملیحه غبرایی^۱، ابوالفضل رنجبر فردویی^{۲*} و محمد احترام^۳

چکیده

خشکسالی یکی از رخدادهای طبیعی است که اثرات قابل توجهی بر زندگی انسان و اکوسیستم دارد. پیش‌بینی شاخص‌های خشکسالی، نظیر شاخص بارش استاندارد شده (SPI) برای ارزیابی این پدیده یک موضوع مهم و کلیدی در مدیریت منابع آب است. مطالعه حاضر با ارائه نسخه جدیدی از مدل حافظه طولانی کوتاه‌مدت (LSTM) تحت عنوان LSTM همکارانه و همچنین توسعه الگوریتم ژنتیک باینری به پیش‌بینی شاخص بارش استاندارد شده می‌پردازد. نخست با استفاده از الگوریتم ژنتیک باینری پارامترهای مدل واسنجی می‌شوند. سپس این الگوریتم بهترین پارامترهای ورودی را از بین سیگنال‌های بزرگ مقیاس اقلیمی با تأخیرهای مختلف انتخاب می‌نماید. پس از آن نسخه جدیدی از مدل LSTM ساخته می‌شود که دارای سه اتصال وزنی بیشتر نسبت به مدل LSTM اولیه می‌باشد. این اتصال‌های وزنی، اطلاعات را از حافظه مدل به درجه‌های مدل انتقال می‌دهند. در مطالعه حاضر، مدل جدید LSTM با مدل‌های شبکه عصبی چندلایه (MLP)، شبکه عصبی شعاعی (RBFNN) و رگرسیون چندگانه (MLR) مقایسه شد. نتایج بیانگر آن بود که مدل LSTM همکارانه مقدار شاخص تطابق ویلموت (Willmott) سایر مدل‌ها را به میزان ۶/۱-۲/۱ درصد، ۵/۱-۱/۱ درصد و ۵/۲-۱/۱ درصد به ترتیب برای پیش‌بینی خشکسالی‌های سه‌ماهه، شش‌ماهه و نه‌ماهه بهبود می‌بخشد. مدل LSTM همکارانه مقدار شاخص RMSE سایر مدل‌ها را ۲۰ درصد برای پیش‌بینی شاخص SPI-3 کاهش داده است. علاوه بر این، الگوریتم ژنتیک باینری پارامترهای مدل‌های پیش‌بینی‌کننده را به طور دقیق تنظیم می‌نماید. مدل LSTM همکارانه همچنین خروجی‌هایی را تولید می‌نماید که عدم قطعیت کمتری نسبت به سایر مدل‌های پیش‌بینی‌کننده دارند.

واژه‌های کلیدی: خشکسالی، شاخص خشکسالی، مدل‌های پیش‌بینی‌کننده، مدل یادگیری عمیق.

ارجاع: غبرایی، ملیحه، رنجبر فردویی، ابوالفضل، و احترام، محمد، ۱۴۰۴. پیش‌بینی شاخص خشکسالی با استفاده از مدل همکارانه LSTM (مطالعه موردی: شمال استان اصفهان). *مجله پژوهش آب ایران*، ۵۶، صص. ۳-۱۵. <https://dx.doi.org/10.22034/IWRJ.2025.14963.2637>

۱- دانشجوی دکترای بیابان‌زدایی، گروه علوم مهندسی بیابان دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان.

۲- استاد تمام دینامیک بیابان، گروه مدیریت سرزمین‌های خشک، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان.

۳- دکترای مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه سمنان.

* نویسنده مسئول: aranjbar@kashanu.ac.ir

تاریخ پذیرش: ۱۴۰۳/۱۰/۲۰

تاریخ دریافت: ۱۴۰۳/۰۷/۲۶

مقدمه

خشکسالی به‌عنوان یکی از پدیده‌های طبیعی، تأثیرات گسترده‌ای بر محیط‌زیست، اقتصاد و جامعه دارد (Vo et al., 2023). این پدیده ناشی از کاهش بارش و کمبود آب است که می‌تواند منجر به مشکلات جدی مانند فرسایش خاک، کاهش تولیدات کشاورزی، تخریب منابع طبیعی و در نهایت مهاجرت مردم از مناطق تحت تأثیر شود (Kheyruri et al., 2023). پیامدهای خشکسالی نه تنها بر کشاورزی و منابع آب تأثیر می‌گذارد، بلکه می‌تواند تنوع زیستی را به شدت تهدید کند. مبارزه با خشکسالی نیازمند استراتژی‌های مدیریتی مؤثر و پایدار است. یکی از راهکارهای مهم، پیش‌بینی و ارزیابی خشکسالی از طریق تحلیل شاخص‌های مختلف خشکسالی است. این شاخص‌ها دربرگیرنده متغیرهایی مانند میزان بارش، رطوبت خاک، جریان آب‌های سطحی، تراز آب زیرزمینی، تبخیر-تعرق و دمای هوا هستند (Shah et al., 2024). بررسی این عوامل با استفاده از فناوری‌های نوین مانند مدل‌های هوش مصنوعی و سنجش‌ازدور، به شناسایی الگوهای خشکسالی و ارزیابی شدت و مدت آن کمک می‌کند. شاخص بارش استاندارد شده^۱ (SPI) ابزاری برای ارزیابی و اندازه‌گیری شدت خشکسالی است (Nandgude et al., 2023). این شاخص بر اساس مقایسه بارش منطقه‌ای با میانگین بلندمدت در یک دوره زمانی مشخص به دست می‌آید. شاخص بارش استاندارد شده امکان تحلیل خشکسالی در مقیاس‌های زمانی کوتاه‌مدت و بلندمدت را فراهم می‌کند و می‌تواند اطلاعات دقیقی را درباره شدت خشکسالی در اختیار مدیران منابع آب و سیاست‌گذاران قرار دهد (Gyaneshwar et al., 2023). این اطلاعات به طور مستقیم در برنامه‌ریزی‌های مدیریتی برای تخصیص بهینه منابع و کاهش خسارات ناشی از خشکسالی نقش دارند. تاکنون پژوهشگران مدل‌های مختلفی را برای پیش‌بینی شاخص SPI معرفی نموده‌اند (Pande et al., 2023).

مدل‌های یادگیری عمیق^۲ به‌عنوان یکی از مهم‌ترین مدل‌های پیش‌بینی‌کننده شاخص SPI هستند. مدل حافظه طولانی کوتاه‌مدت^۳ که به اختصار LSTM نامیده می‌شود، یکی از پرکاربردترین مدل‌های یادگیری عمیق در

زمینه مدیریت منابع آب است (Taylan, 2024). مدل مذکور دارای سه درجه محاسباتی است که می‌تواند به طور مؤثری به پردازش اطلاعات بپردازد. Zhang et al. (2020) از مدل LSTM برای پیش‌بینی شاخص SPI در مناطق مختلف جهان استفاده نمودند. مدل مذکور شاخص‌های یک‌ماهه، شش‌ماهه و دوازده‌ماهه SPI را با موفقیت پیش‌بینی نمود.

Xu et al. (2022) از ترکیب مدل LSTM و یک مدل رگرسیونی برای پیش‌بینی شاخص SPI در مناطق مختلف کشور چین استفاده کردند. مدل مذکور از ورودی‌های تاخیر یافته SPI استفاده می‌کرد. نتایج بیانگر دقت بالای مدل هیبریدی در پیش‌بینی خشکسالی بود.

Wu et al. (2022) از مدل LSTM برای پیش‌بینی‌های فصلی خشکسالی در کشور چین استفاده نمودند. نتایج بیانگر آن بود که مدل مذکور دقت بهتری از مدل‌های رگرسیونی در پیش‌بینی خشکسالی داشت. Vo et al. (2023) از ترکیب مدل LSTM و یک مدل اقلیمی برای پیش‌بینی شاخص SPI در کره جنوبی و ویتنام استفاده کردند. نتایج نشان داد که مدل هیبریدی تحقیق مذکور عملکرد مدل LSTM را در پیش‌بینی شاخص SPI ارتقاء می‌داد.

Danandeh Mehr et al. (2023) از مدل LSTM برای پیش‌بینی خشکسالی هواشناسی در استان آنکارا، ترکیه استفاده نمودند. نتایج بیانگر آن بود که عملکرد مدل LSTM به شدت به تنظیم پارامترهای آن وابسته است. تحقیق‌های انجام گرفته نشان می‌دهد که مدل LSTM دارای عملکرد مناسبی برای پیش‌بینی خشکسالی است. به هرحال مدل مذکور در پیش‌بینی خشکسالی با چالش‌هایی مواجه است که تاکنون به درستی بررسی نشده‌اند. نخست آن که تحقیق‌های انجام گرفته از مدل اصلی LSTM بدون بهبود آن استفاده کرده‌اند. مدل LSTM دارای پارامترهایی است که نیاز به تنظیم دقیق دارند. دوم آن که انتخاب بهترین ترکیب ورودی به مدل LSTM موضوعی پیچیده و دشوار است. ورودی‌های لازم برای پیش‌بینی خشکسالی معمولاً با تأخیرهای مختلف زمانی همراه هستند. انتخاب بهترین ترکیب ورودی از بین تعداد زیاد ورودی‌ها، موضوعی حائز اهمیت است که همچنین عملکرد مدل LSTM را تحت تأثیر قرار می‌دهد. سومین چالش این است که مدل LSTM فاقد اتصال‌هایی است که به طور مستقیم اطلاعات

1- Standardized Precipitation Index (SPI)

2- Deep learning models

3- Long short term memory

اتصال‌ها وظیفه انتقال مستقیم اطلاعات از حافظه مدل به دریاچه‌های مدل را بر عهده دارند.

مواد و روش‌ها

منطقه مطالعاتی

منطقه مورد مطالعه در این پژوهش، ایستگاه‌های منتخب در شمال استان اصفهان است که بین ۵۱ درجه و ۸۱ دقیقه تا ۵۵ درجه و ۰۲ دقیقه طول شرقی و ۳۳ درجه و ۵۹ دقیقه تا ۳۴ درجه و ۱۵ دقیقه عرض شمالی در بخش مرکزی ایران (شامل شهرستان‌های کاشان، آران و بیدگل، اردستان، نایین و نطنز) قرار دارد. اقلیم منطقه مورد مطالعه براساس روش دومارتن عمدتاً از نوع خشک و فرا خشک است. میزان متوسط بارش سالیانه استان ۱۶۰ میلی‌متر و میانگین دمای سالیانه ۴ درجه سانتی‌گراد است.

منطقه مورد مطالعه از شمال به استان قم، از شرق به خور و بیابانک، از غرب به میمه و شاهین شهر و از جنوب به مرکز استان اصفهان منتهی می‌شود. ایستگاه‌های مورد مطالعه در محدوده و اطراف منطقه مورد مطالعه به نمایندگی از هر تراز ارتفاعی انتخاب شده است. شایان ذکر است که با توجه به هدف مطالعه تمام ایستگاه‌ها از نوع سینوپتیک هستند. جدول ۱ مشخصات ایستگاه‌های منتخب در استان اصفهان را نشان می‌دهد.


جدول ۱- مشخصات ایستگاه‌های منتخب در استان اصفهان

نام ایستگاه	نوع ایستگاه	طول جغرافیایی (درجه)	عرض جغرافیایی (درجه)
کاشان	سینوپتیک	۵۱/۴۸	۳۳/۲۷
نطنز	سینوپتیک	۵۱/۹۰	۳۳/۵۳
میمه	سینوپتیک	۵۱/۱۷	۳۳/۴۳
اردستان	سینوپتیک	۵۲/۳۸	۳۳/۳۶
نجف‌آباد	سینوپتیک	۵۱/۲۳	۳۲/۶۰
نایین	سینوپتیک	۵۳/۰۸	۳۲/۸۵
سلفچگان	سینوپتیک	۵۰/۴۸	۳۴/۴۸


استفاده شد. داده‌های بارش ماهیانه در بازه زمانی ۲۰۰۰-۲۰۲۳ مربوط به ایستگاه‌های کاشان، نطنز، میمه، اردستان، نجف‌آباد، نایین و سلفچگان که از سازمان هواشناسی کشور جمع‌آوری گردید. مقادیر متوسط شاخص SPI مربوط به ایستگاه‌ها محاسبه و در شکل ۲ نمایش داده شد. منابع داده‌های شاخص‌های اقلیمی از سایت <http://www.esrl.noaa.gov/psd/data/climateindices> قابل دسترس است.

را از حافظه مدل به دریاچه‌های محاسباتی مدل انتقال دهد. این مشکل سبب می‌گردد که مدل اطلاعات مهمی را از دست بدهد. بنابراین مطالعه حاضر به بررسی این چالش‌ها و رفع آنها برای بهبود عملکرد مدل LSTM در پیش‌بینی شاخص خشکسالی SPI می‌پردازد. در طی سالهای اخیر پژوهشگران از الگوریتم‌های تکاملی برای تنظیم پارامترهای مدل‌ها و انتخاب ورودی‌های مؤثر به مدل‌های پیش‌بینی کننده استفاده نموده‌اند. این الگوریتم‌ها به طور مؤثری قادر به جستجوی فضای مسئله هستند. Ehteram et al. (2024) گزارش کردند که الگوریتم‌های تکاملی ابزارهایی مؤثر برای یافتن پارامترهای مدل‌های پیش‌بینی کننده و انتخاب ورودی‌ها هستند. بنابراین، مطالعه حاضر از یک الگوریتم تکاملی برای انتخاب هم‌زمان بهترین پارامترهای مدل LSTM و بهترین ترکیب ورودی استفاده می‌نماید. الگوریتم ژنتیک باینری یکی از الگوریتم‌های مؤثر برای تنظیم پارامترهای مدل‌ها است (Skobtsov et al., 2024). علاوه بر این، الگوریتم مذکور می‌تواند به طور مؤثری بهترین ترکیب ورودی به مدل را تعیین نماید (Skobtsov et al., 2024). در مطالعه حاضر، نوع جدیدی از مدل LSTM توسعه داده شد که دارای سه اتصال بیشتر نسبت به مدل اصلی است. این

شکل‌های ۱ و ۲ به ترتیب موقعیت منطقه مورد مطالعه (شمال استان اصفهان) و مقادیر سری‌های زمانی SPI در ایستگاه‌های کاشان، نطنز، میمه، اردستان، نجف‌آباد، نایین و سلفچگان در مقیاس‌های سه، شش و نه ماهه را نشان می‌دهند. همچنین جدول ۲ جزئیات آماری داده‌های ورودی و شاخص‌های بزرگ مقیاس اقلیمی را نشان می‌دهد. داده‌های ورودی برای پیش‌بینی شاخص‌های SPI ۳ ماهه (SPI-3)، ۶ ماهه (SPI-6) و ۹ ماهه (SPI-9)



شکل ۱- موقعیت مکانی ایستگاه‌های مختلف



شکل ۲- سری‌های زمانی شاخص SPI در مقیاس‌های ۳، ۶ و ۹ ماهه مربوط به ایستگاه‌های کاشان، نطنز، میمه، اردستان، نجف آباد، نایین و سلفچگان

$$I_t = s(w_i[h_{t-1}, x_t] + b_i) \quad (۱)$$

$$O_t = s(w_o[h_{t-1}, x_t] + b_o) \quad (۲)$$

$$F_t = s(w_f[h_{t-1}, x_t] + b_f) \quad (۳)$$

$$\hat{C}_t = \tanh[w_c[h_{t-1}, x_t] + b_c] \quad (۴)$$

$$C_t = F_t \times C_{t-1} + I_t \times \hat{C}_t \quad (۵)$$

$$H_t = O_t \times \tanh(C_t) \quad (۶)$$

که در آن، I_t ، s ، $[w_o, w_i, w_c, w_f]$ ، $[b_o, b_f, b_c, b_i]$ ، $\hat{C}_t$ ، F_t ، O_t و h_{t-1} به ترتیب نشان‌دهنده دریچه ورودی، تابع فعال‌سازی، ضرایب وزنی، بایاس، دریچه خروجی، دریچه فراموشی، وضعیت حافظه (بردار سلول)، وضعیت پنهان و خروجی نهایی هستند.

مدل بهبودیافته LSTM

شکل زیر یک مدل جدید LSTM را نشان می‌دهد که دارای سه اتصال بیشتر نسبت به مدل LSTM است (شکل ۳). اتصال‌های اضافه شده اطلاعات سلول حافظه LSTM را به دریچه‌های مدل LSTM انتقال می‌دهند. این مدل تحت عنوان مدل LSTM همکارانه استفاده می‌شود. دریچه‌های جدید مدل LSTM بر اساس سه اتصال جدید به روزرسانی می‌گردند (معادلات (۷) تا (۹)).

$$I_t = s(w_i h_{t-1} + w_i x_t + \tanh(w_{ic} C_{t-1}) b_i) \quad (۷)$$

$$O_t = s(w_o h_{t-1} + w_o x_t + \tanh(w_{oc} C_{t-1}) b_o) \quad (۸)$$

$$F_t = s(w_f h_{t-1} + w_f x_t + \tanh(w_{fc} C_{t-1}) b_f) \quad (۹)$$

که در آن، $[w_{fc}, w_{ic}, w_{oc}]$ ضرایب اتصال‌های وزنی بین دریچه‌ها و حافظه مدل LSTM می‌باشند.

مقایسه با سایر مدل‌ها

مطالعه حاضر از مدل جدید LSTM برای پیش‌بینی شاخص خشکسالی SPI استفاده می‌کند و مقایسه عملکرد این مدل با سایر مدل‌های پیش‌بینی کننده ضروری است. مدل شبکه عصبی یکی از مدل‌های پرکاربرد برای پیش‌بینی شاخص خشکسالی SPI است. مدل شبکه عصبی چند لایه از چندین لایه پنهان تشکیل شده است. لایه ورودی داده‌ها را دریافت می‌کند. لایه میانی داده‌ها را

جدول ۲- مشخصات آماری داده‌های ورودی در بازه زمانی

۲۰۲۳-۲۰۰۰

پارامتر	مینیمم	میانگین	ماکزیمم
PDO	-۲/۱۷	-۱/۵۵	-۱/۰۲
ENSO	-۲/۱۲	-۱/۳۳	-۱/۱۰
NAO	-۳/۲۵	-۱/۲۲	-۱/۰۵
IDO	-۲/۸۹	-۱/۴۶	-۱/۰۱

روش تحقیق

شاخص بارش استاندارد شده (SPI)

SPI شاخصی است که برای ارزیابی و اندازه‌گیری وضعیت خشکسالی براساس الگوی بارش استفاده می‌شود. شاخص بارش استاندارد شده براساس احتمال بارش برای هر بازه زمانی می‌باشد. نمایه بارندگی استاندارد پرکاربردترین شاخص در پایش خشکسالی است. شاخص بارش استاندارد شده بارش (SPI) را نخستین بار (Mckee et al., 1993) ارائه داده‌اند. برای محاسبه نمایه SPI از تابع چگالی توزیع گاما و گاهی از تابع پیرسون برای برازش داده‌های بلندمدت بارش استفاده می‌شود، که پس از انجام محاسبات لازم و تعیین پارامترهای مربوطه شاخص SPI به صورت مقادیر مثبت و منفی بیان می‌شود. مقادیر منفی شاخص SPI نشان‌دهنده خشکسالی و مقادیر مثبت نشان‌دهنده ترسالی است.

Parvin nia and Riahi Farsani, (2016) مقادیر SPI

معمولاً در بازه‌های زیر تفسیر می‌شوند:

2: SPI > +2: بسیار مرطوب، 1 < SPI ≤ +2: مرطوب، -1

1: SPI ≤ +1: نرمال، -1 ≤ SPI ≤ -2: خشکسال، - SPI <


2: بسیار خشکسال

مدل LSTM

مدل LSTM یک مدل یادگیری عمیق است که می‌تواند به طور مؤثری به پردازش سری‌های زمانی بپردازد. این مدل از سه دریچه تشکیل شده است (Ehteram et al., 2024). دریچه ورودی که مربوط به دریافت ورودی‌ها است. دریچه فراموشی، بخش‌هایی از ورودی‌ها را که دارای اهمیت پایینی است، حذف می‌کند و دریچه خروجی که به تولید خروجی‌ها می‌پردازد. مدل محاسباتی مدل LSTM بر اساس معادله‌های (۱) تا (۶) است (Ehteram et al., 2024).

پیش‌بینی شاخص خشکسالی است. این مدل یک رابطه خطی بین ورودی‌ها و متغیر خروجی فرض می‌کند. مدل مذکور دارای ضرایب رگرسیونی متعددی است.

پردازش می‌کند و لایه خروجی به تولید خروجی‌ها می‌پردازد. شبکه عصبی شعاعی از یک لایه پنهان تشکیل شده است که به پیش‌بینی خروجی‌ها می‌پردازد. مدل رگرسیون چندگانه یکی دیگر از مدل‌های مهم برای



شکل ۳- ساختار مدل LSTM همکارانه

تعیین می‌کند که مقدار اولیه یک پارامتر خاص چگونه انتخاب شود.

در گام بعد مدل جدید LSTM همکارانه اجرا می‌گردد. یک تابع هدف وزن‌دار تعریف می‌شود. این تابع وزن‌دار هدف، از ترکیب دو تابع هدف تشکیل شده است. یک تابع هدف برای انتخاب ورودی‌ها و تابع دوم هدف برای تنظیم پارامترهای مدل است. از آنجایی که اولویت این توابع برای ما یکسان است، به هر تابع هدف ضریب تأثیر ۰/۵ داده می‌شود. معادله‌های (۱۰) و (۱۱) توابع هدف یک و دو را نشان می‌دهند. معادله (۱۲) نیز تابع هدف وزن‌دار را نشان می‌دهد.

$$RMSE = \sqrt{\frac{1}{I} \sum_{i=1}^I (OC_{es} - OC_{ob})^2} \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |RU_i^{es} - RU_i^{ob}| \quad (11)$$

$$F = W_1 RMSE + W_2 MAE \quad (12)$$

که در آن، OC_{ob} ، OC_{es} و I و W به ترتیب نشان دهنده مقدار مشاهداتی شاخص خشکسالی، مقدار پیش‌بینی شده شاخص خشکسالی، تعداد داده‌ها و وزن تابع هدف می‌باشند.

مدل LSTM هیبریدی برای پیش‌بینی شاخص خشکسالی

در گام نخست، داده‌های ورودی شامل سری‌های زمانی به داده‌های آموزش و آزمون تقسیم شدند. ۸۰ درصد داده‌های ورودی برای آموزش و ۲۰ درصد برای آزمون انتخاب شد. این تقسیم‌بندی به این دلیل انجام می‌گیرد که مدل خطای پیش‌بینی کمتری تولید می‌کند.

مطالعه حاضر از الگوریتم ژنتیک باینری برای تنظیم پارامترهای مدل LSTM و انتخاب ورودی استفاده می‌کند. هر کروموزوم دارای دو بخش است، بخش اول شامل ورودی‌های مدل‌ها و بخش دوم شامل مقادیر اولیه پارامترها است. کروموزوم‌ها به شکل رشته‌های باینری شامل مقادیر صفر و یک می‌باشند. به‌طور مثال، مقادیر یک در بخش اول نشان می‌دهد که یک پارامتر ورودی در مدل‌سازی استفاده شده است و مقادیر صفر در بخش اول نشان می‌دهد که یک پارامتر ورودی در مدل‌سازی استفاده نشده است. همچنین مقادیر صفر و یک در بخش دوم نشان‌دهنده تنظیمات اولیه پارامترهای مدل LSTM هستند. به‌عبارت دیگر، هر مقدار باینری در بخش دوم

$$U_{95\%} = 1.96 \left(SD^2 - RMSE^2 \right)^{0.5} \quad (15)$$

که در معادله های فوق، SPI_{es} ، $SPI_{i^{ob}}$ ، $SPI_{i^{ob}}$ و SD به ترتیب مقدار شاخص تخمینی خشکسالی، مقدار شاخص مشاهداتی خشکسالی، مقدار متوسط مشاهداتی شاخص خشکسالی و انحراف معیار است Allahverdipour and Sattari, (2023).

ریشه میانگین مربعات خطا RMSE: معیاری است که معمولاً برای ارزیابی دقت یک مدل پیش‌بینی استفاده می‌شود. RMSE کمتر نشان‌دهنده تناسب بهتر مدل با داده‌ها است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (SPI_{i^{ob}} - SPI_{i^{es}})^2} \quad (16)$$

میانگین خطای مطلق MAE: معیاری است که برای اندازه‌گیری میانگین اختلاف بین مقادیر واقعی و پیش‌بینی شده یک مدل استفاده می‌شود. مقدار MAE کمتر، تناسب بهتر مدل را با داده‌ها نشان می‌دهد.

$$MAE = \frac{1}{N} \sum_{i=1}^N \left| (SPI_{i^{es}} - SPI_{i^{ob}}) \right| \quad (17)$$

در این معادله SPI_{es} ، $SPI_{i^{ob}}$ ، $SPI_{i^{ob}}$ و N به ترتیب مقدار شاخص تخمینی خشکسالی، مقدار شاخص مشاهداتی خشکسالی، تعداد نمونه‌ها می‌باشد.

انتخاب ورودی‌ها

هدف از مطالعه حاضر، پیش‌بینی شاخص‌های خشکسالی سه‌ماهه، شش‌ماهه و نه‌ماهه SPI است که از شاخص‌های بزرگ مقیاس اقلیمی برای پیش‌بینی شاخص SPI استفاده می‌نماید. پژوهش‌های قبلی نشان داده‌اند که شاخص‌های بزرگ مقیاس اقلیمی تأثیر قابل توجهی بر SPI دارند. Mohammad-rezaei et al. (2020) به بررسی اثر شاخص‌های مختلف بر مقدار SPI پرداختند. نتایج بیانگر آن بود که شاخص‌های ENSO و PDO همبستگی بالایی با مقدار SPI در نواحی مختلف ایران دارند.

Rezaei et al. (2023) ارتباط قابل توجهی را بین خشکسالی‌های دو تا هفت ساله و هشت تا دوازده ساله با شاخص ENSO مشاهده نمودند. بنابراین در مطالعه حاضر از شاخص‌های زیر برای پیش‌بینی مقدار SPI استفاده شد:

از اپراتورهای انتخاب، بازترکیب و جهش برای به‌روزرسانی پاسخ‌ها استفاده می‌شود. اپراتور انتخاب به عنوان یکی از اجزاء اصلی الگوریتم ژنتیک، برای انتخاب بهترین کروموزوم‌ها استفاده می‌گردد (Aote et al., 2023).

در این روش، کروموزوم‌هایی که بهترین عملکرد را بر اساس تابع هدف تعریف شده داشته باشند، به نسل بعدی انتقال می‌یابند (Skobtsov et al., 2024).

در گام بعدی، از اپراتور بازترکیب (Crossover) برای تولید کروموزوم‌های جدید استفاده می‌شود. بازترکیب باعث ترکیب ویژگی‌های کروموزوم‌های والد به شکلی تصادفی می‌گردد تا کروموزوم‌های جدید با خصوصیات بهبودیافته به وجود آید. اپراتور جهش^۱ نیز برای ایجاد تنوع در جمعیت استفاده می‌شود. فرآیند انتخاب، بازترکیب و جهش چندین بار تکرار می‌شود تا مدل LSTM بهبود یابد و مقدار خطای پیش‌بینی شاخص خشکسالی به حداقل برسد. این تکرارها تا زمانی ادامه می‌یابند که مدل به یک سطح رضایت‌بخش از دقت در پیش‌بینی دست یابد.

در نهایت، بهترین کروموزوم، که شامل بهینه‌ترین ورودی‌ها و تنظیمات پارامترها است، برای پیش‌بینی شاخص خشکسالی استفاده می‌شود.

مطالعه حاضر همچنین از شاخص‌های زیر (معادلات (۱۳) تا (۱۵)) برای ارزیابی دقت مدل‌ها استفاده می‌نماید.

شاخص میانگین درصد مطلق خطای متقارن

$$SMAPE = \frac{1}{N} \sum_{i=1}^N \frac{|SPI_{ob} - SPI_{es}|}{\frac{(|SPI_{es}| + |SPI_{ob}|)}{2}} \quad (13)$$

در این معادله SPI_{es} ، $SPI_{i^{ob}}$ ، $SPI_{i^{ob}}$ و N به ترتیب مقدار شاخص تخمینی خشکسالی، مقدار شاخص مشاهداتی خشکسالی، تعداد نمونه‌ها می‌باشد. هرچه مقدار SMAPE کوچکتر باشد، دقت پیش‌بینی یک مدل بهتر است.

شاخص Willmott's Index of Agreement (WI)

$$WI = 1 - \frac{\sum_{i=1}^N (SPI_{i^{ob}} - SPI_{i^{es}})^2}{\sum_{i=1}^N (|SPI_{i^{ob}} - \bar{SPI}_{ob}| + |SPI_{i^{es}} - \bar{SPI}_{ob}|)} \quad (14)$$

WI از ۰ تا ۱ متغیر است. مقدار بالاتر شاخص WI نشان دهنده عملکرد بهتر مدل است.

Uncertainty at 95%: (U95)

جدول ۳ مشخصات مدل‌ها را نشان می‌دهد که با استفاده از الگوریتم ژنتیک باینری تنظیم شده‌اند.

انتخاب بهترین ترکیب ورودی

الگوریتم ژنتیک باینری برای انتخاب ورودی‌ها استفاده شد. جدول ۴ بیانگر ورودی‌های انتخاب شده بر اساس تأخیرهای مختلف زمانی است. نتایج نشان می‌دهد که الگوریتم ژنتیک باینری، شاخص IOD را با تأخیر دوازده و یازده ماهه، شاخص ENSO را با تأخیر دوازده، یازده و ده‌ماهه و شاخص NAO را با تأخیر دوازده، یازده و ده‌ماهه را به عنوان ورودی‌ها انتخاب نمود (t: زمان تأخیر).

در ادامه مقادیر ضریب همبستگی این ورودی‌ها با شاخص SPI برای صحت‌سنجی ورودی‌های انتخاب شده کنترل شد که در جدول ۵ ارائه شده است. همان‌گونه که مشاهده می‌شود، تمام ورودی‌ها دارای ضریب همبستگی بالایی با شاخص SPI-3، SPI-6 و SPI-9 می‌باشند.

مقایسه عملکرد مدل‌ها

جدول ۶، عملکرد مدل‌ها را در مرحله آزمون نشان می‌دهد. مدل LSTM همکارانه، مقدار شاخص RMSE سایر مدل‌ها را $1/7-1/4$ درصد برای پیش‌بینی شاخص SPI-3 کاهش داده و به بالاترین مقدار WI برای پیش‌بینی شاخص‌های SPI-3، SPI-6 و SPI-9 دست یافته است. مدل LSTM همکارانه، مقدار SMAPE سایر مدل‌ها را به میزان $25-50$ درصد برای پیش‌بینی SPI-6 کاهش می‌دهد و مقدار شاخص MAE سایر مدل‌ها را به میزان $2/6-9/9$ درصد برای پیش‌بینی SPI-9 بهبود داده است. نتایج کلی عملکرد مدل‌ها نشان می‌دهد که مدل LSTM همکارانه و LSTM دارای بهترین عملکرد در پیش‌بینی شاخص SPI در مقیاس‌های سه، شش و نه ماهه هستند.

شکل ۴ نمودار جعبه‌ای مدل‌های مختلف را نشان می‌دهد. مقدار میانه SPI-3، SPI-6 و SPI-9 بر اساس داده‌های مشاهداتی معادل با $0/54$ ، $0/78$ و $0/95$ می‌باشد. مقدار میانه SPI-3، SPI-6 و SPI-9 بر اساس مدل LSTM همکارانه معادل با $0/23$ ، $0/67$ و $0/85$ است. همچنین مقادیر بیشینه و کمینه نمودار جعبه‌ای مدل LSTM همکارانه انطباق بالایی با مقادیر مشاهداتی دارد.

شاخص نوسان دهه‌ای اقیانوس آرام (PDO)^۱: یک الگوی تغییرات اقلیمی است که در مقیاس دهه‌ای (۲۰ تا ۳۰ ساله) رخ می‌دهد و بر دمای سطح آب اقیانوس آرام در نیمکره شمالی تأثیر می‌گذارد. این شاخص بر اساس تغییرات دمای سطح دریا (SST) در ناحیه شمالی اقیانوس آرام می‌باشد (Rezaei et al., 2023).

شاخص نوسان جنوبی ال‌نینیو (ENSO)^۲ یک پدیده جوی-اقیانوسی است که شامل تغییرات دوره‌ای در دمای سطح آب اقیانوس آرام استوایی و الگوهای فشار جوی مرتبط با آن می‌شود. ENSO در دو فاز اصلی رخ می‌دهد: ال‌نینیو و لانینا همراه با یک فاز خنثی که شرایط نرمال را نشان می‌دهد (Nguyen et al., 2023).

شاخص نوسان اطلس شمالی (NAO)^۳ یک الگوی جوی مهم است که تغییرات فشار هوا در اقیانوس اطلس شمالی را نشان می‌دهد و تأثیرات گسترده‌ای بر شرایط آب و هوایی در نیمکره شمالی به ویژه اروپا، آمریکای شمالی و بخش‌هایی از شمال آفریقا دارد. این شاخص با توجه به تفاوت فشار بین منطقه‌ای با فشار بالای هوا در آژورس (جزایر آژور) و منطقه‌ای با فشار پایین در ایسلند تعریف می‌شود (Jurasz et al., 2024).

شاخص نوسان اقیانوس هند (IOD)^۴ یک الگوی اقلیمی است که به تغییرات دوره‌ای در دمای سطح آب اقیانوس هند و تأثیرات جوی مرتبط با آن اشاره دارد. این شاخص به صورت تفاوت دمای سطح دریا بین بخش غربی و شرقی اقیانوس هند اندازه‌گیری می‌شود و تأثیرات مهمی بر الگوهای بارش و شرایط جوی در مناطق مختلف، به ویژه در شرق آفریقا، جنوب آسیا و استرالیا دارد. IOD دارای دو فاز اصلی است: فاز مثبت و فاز منفی (Wang et al., 2024).

نتایج و بحث

تنظیم پارامترهای مدل‌ها

مطالعه حاضر از مدل‌های LSTM همکارانه، مدل شبکه عصبی چندلایه (MLP)، مدل شبکه عصبی شعاعی (RBFNN) و مدل رگرسیون چندگانه برای پیش‌بینی شاخص SPI در گام‌های زمانی مختلف استفاده می‌نماید.

1- Pacific Decadal Oscillation-1
2- El Niño-Southern Oscillation
3- North Atlantic Oscillation
4- Indian Ocean Dipole

جدول ۳- مشخصات مدل های پیش بینی کننده

مدل	پارامترها
LSTM	تعداد لایه میانی: ۵، تعداد نورون هر لایه پنهان: ۱۰، نرخ یادگیری: ۰/۰۰۱
MLP	تعداد لایه پنهان: ۱، تعداد نورون هر لایه پنهان: ۴
RBFNN	تعداد لایه پنهان: ۱، تعداد نورون هر لایه پنهان: ۴
MLR	-

جدول ۴- ورودی های انتخاب شده بر اساس الگوریتم ژنتیک باینری (ورودی های انتخاب شده با رنگ تیره نشان داده شده است)

شاخص	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1
IOD												
PDO												
ENSO												
NAO												

جدول ۵- مقادیر ضریب همبستگی بین شاخص های SPI و ورودی های مدل

شاخص	IOD (t-12)	IOD (t-11)	PDO (t-12)	PDO (t-11)	ENSO (t-12)
SPI-3	۰/۹۵	۰/۹۴	۰/۹۲	۰/۹۲	۰/۹۱
SPI-6	۰/۹۴	۰/۹۳	۰/۹۲	۰/۹۰	۰/۸۹
SPI-9	۰/۹۱	۰/۹۰	۰/۹۲	۰/۹۱	۰/۸۹
شاخص	ENSO (t-11)	ENSO (t-12)	PDO (t-12)	PDO (t-12)	PDO (t-12)
SPI-3	۰/۹۶	۰/۹۲	۰/۹۰	۰/۸۹	۰/۸۸
SPI-6	۰/۹۴	۰/۹۱	۰/۸۹	۰/۸۸	۰/۸۸
SPI-9	۰/۹۳	۰/۹۲	۰/۹۰	۰/۸۹	۰/۸۸


جدول ۶- بررسی عملکرد مدل ها در پیش بینی شاخص SPI در مقیاس های سه، شش و نه ماهه

SPI-3				مدل
WI	SMAPE	MAE	RMSE	
۰/۹۸	۳	۰/۷۴۵	۰/۹۸۱	Collaborative LSTM
۰/۹۶	۵	۰/۸۱۲	۰/۹۹۸	LSTM
۰/۹۵	۸	۱/۱۲	۱/۰۲	MLP
۰/۹۴	۱۱	۱/۱۸	۱/۱۱	RBFNN
۰/۹۲	۱۲	۱/۲۱	۱/۱۴	MLR
SPI-6				مدل
WI	SMAPE	MAE	RMSE	
۰/۹۷	۶	۰/۷۵۵	۰/۹۸۴	Collaborative LSTM
۰/۹۶	۸	۰/۸۱۰	۰/۹۸۹	LSTM
۰/۹۵	۹	۰/۸۱۴	۱/۰۴	MLP
۰/۹۴	۱۱	۰/۸۱۷	۱/۱۰	RBFNN
۰/۹۲	۱۲	۰/۸۱۹	۱/۱۵	MLR
SPI-9				مدل
WI	SMAPE	MAE	RMSE	
۰/۹۶	۸	۰/۸۲۳	۰/۹۷۸	Collaborative LSTM
۰/۹۵	۹	۰/۸۴۵	۰/۹۸۹	LSTM
۰/۹۴	۱۱	۰/۸۶۸	۱/۱۲	MLP
۰/۹۲	۱۲	۰/۸۹۸	۱/۲۴	RBFNN
۰/۹۱	۱۴	۰/۹۱۲	۱/۳۴	MLR


پیش‌بینی کننده قوی دارد. مدل MLR به دلیل استفاده از روابط خطی، قادر به پیش‌بینی دقیق خشکسالی نیست. نتایج پژوهش حاضر نشان می‌دهد که الگوریتم باینری ژنتیک به عنوان یک الگوریتم مؤثر انتخاب ویژگی توانسته به خوبی ورودی‌های مدل‌ها را با تأخیرهای مختلف انتخاب نماید. بنابراین مدل LSTM همکارانه و الگوریتم باینری ژنتیک می‌تواند به ابزارهای قوی برای پیش‌بینی خشکسالی با رویکرد کاهش عدم قطعیت در خروجی‌ها استفاده شود.

شکل ۵ مقادیر U95 مدل‌های مختلف را نشان می‌دهد. به طور واضح مدل LSTM همکارانه از سایر مدل‌ها مقدار U95 کمتری دارد. بنابراین می‌توان نتیجه گرفت که خروجی‌های مدل LSTM همکارانه عدم قطعیت کمتری از سایر مدل‌ها دارد.

نتایج تحقیق حاضر نشان می‌دهد که مدل LSTM همکارانه به دلیل انتقال مؤثر اطلاعات از حافظه به درجه دارای عملکرد مؤثرتری نسبت به سایر مدل‌ها می‌باشد. پیش‌بینی خشکسالی تحت تأثیر شاخص‌های بزرگ مقیاس اقلیمی موضوعی پیچیده است که نیاز به مدل‌های



شکل ۴- نمودار جعبه‌ای مدل‌های مختلف و داده‌های مشاهداتی



شکل ۵- مقدار U95 برای مدل‌های مختلف در پیش‌بینی مقادیر SPI در مقیاس‌های زمانی سه، شش و نه

مدل‌ها را به میزان ۶/۱-۲/۱ درصد، ۵/۱-۱/۱ درصد و ۵/۲-۱۱ درصد برای پیش‌بینی SPI-3، SPI-6 و SPI-9 که بهترین بهبود داد. از نظر مقادیر خطا (RMSE) که مهمترین معیار مقایسه مدل‌ها هست، تفاوت قابل توجهی بین نتایج مدل LSTM با مدل ترکیبی جدید در SPI6 و SPI9 وجود ندارد و تفاوت مقادیر خطا در حد هزارم است. تنها در SPI3 تفاوت خطا بیشتر و حدود ۰/۲ است. به عبارت دیگر مدل ترکیبی در SPI3 نتایج را بهبود داده است. تحقیقات‌های بعدی می‌تواند به ارتقاء مؤثر مدل از طریق ترکیب با سایر مدل‌های یادگیری عمیق بپردازد. ترکیب مدل LSTM همکارانه با سایر مدل‌های یادگیری عمیق به این مدل اجازه می‌دهد تا الگوهای پیچیده‌تر در سری‌های زمانی ورودی را به طور دقیق پیش‌بینی کند. علاوه بر این، مدل LSTM همکارانه می‌تواند برای پیش‌بینی خشکسالی در اقلیم‌های مختلف ارزیابی شود. این مدل ترکیبی با توجه به استفاده از الگوریتم ژنتیک برای تنظیم پارامترها و انتخاب ورودی‌ها، به‌طور معمول عملکرد بهتری نسبت به مدل‌های معمولی LSTM دارد.

تقدیر و تشکر

نویسندگان از سازمان هواشناسی کشور به دلیل در اختیار قرار دادن داده و اطلاعات و از دانشگاه کاشان به دلیل حمایت مالی این تحقیق تشکر می‌نمایند.

تضاد منافع نویسندگان

به تایید همه نویسندگان، در مقاله حاضر هیچ‌گونه تضاد منافع وجود ندارد.

از نظر مقادیر خطا (RMSE) که مهمترین معیار مقایسه مدل‌ها هست، تفاوت قابل توجهی بین نتایج مدل LSTM با مدل ترکیبی جدید در SPI6 و SPI9 وجود ندارد و تفاوت مقادیر خطا در حد هزارم است. تنها در SPI3 تفاوت خطا بیشتر و حدود ۰/۲ است. به عبارت دیگر مدل ترکیبی تنها در SPI3 نتایج را بهبود داده است.

نتیجه‌گیری

خشکسالی یکی از بلایای طبیعی است که زندگی انسان و اکوسیستم را تحت تأثیر قرار می‌دهد؛ بنابراین پیش‌بینی خشکسالی می‌تواند نقشی حیاتی در کاهش خسارات ناشی از آن داشته باشد. مطالعه حاضر با ارائه مدل جدید LSTM تحت عنوان LSTM همکارانه و همچنین توسعه الگوریتم ژنتیک باینری می‌تواند گام مؤثری را برای پیش‌بینی خشکسالی بردارد. مدل LSTM همکارانه از سه درجه محاسباتی بیشتر نسبت به مدل LSTM تشکیل شده است که وظیفه انتقال اطلاعات از حافظه به درجه‌های مدل را دارند. در این مطالعه، مدل LSTM همکارانه برای پیش‌بینی SPI-3، SPI-6 و SPI-9 در شمال استان اصفهان استفاده شد. الگوریتم ژنتیک باینری برای تنظیم پارامترهای مدل‌ها و انتخاب ورودی‌ها استفاده شد. نتایج نشان داد که الگوریتم ژنتیک باینری به طور مؤثری بهترین ورودی‌ها را از بین شاخص‌های اقلیمی با تأخیر زمانی مختلف انتخاب نمود. علاوه بر این، نتایج نشان داد که مدل LSTM همکارانه از دقت بیشتری نسبت به سایر مدل‌ها در پیش‌بینی شاخص خشکسالی SPI برخوردار بود. به طور مثال، مدل LSTM همکارانه مقدار WI سایر

- radiation data. *Energy Conversion and Management*, 305, 118267. DOI: 10.1016/j.enconman.2024.118267
5. Gyaneshwar, A., Mishra, A., Chadha, U., Raj Vincent, P.M.D., Rajinikanth, V., Pattukandan Ganapathy, G. and Srinivasan, K., 2023. A Contemporary Review on Deep Learning Models for Drought Prediction. *Sustainability*, 15(7), 6160. DOI:10.3390/su15076160
 6. Jurasz, J., Guezgouz, M., Campana, P. E., Kaźmierczak, B., Kuriqi, A., Bloomfield, H., Hingray, B., Canales, F. A., Hunt, J. D., Sterl, S. and Elkadeem, M. R., 2024. Complementarity of wind and solar power in North Africa: Potential for alleviating energy droughts and impacts of the North Atlantic Oscillation. *Renewable and Sustainable Energy Reviews*, 191, pp. 114181. DOI: 10.1016/j.rser.2023.114181
 7. Kheyruri, Y., Sharafati, A. and Neshat, A., 2023. Predicting agricultural drought using meteorological and ENSO parameters in different regions of Iran based on the LSTM model. *Stochastic Environmental Research and Risk Assessment*, 37(9), 3599-3613. DOI :10.1007/s00477-023-02465-6
 8. McKee, T. B., Doesken, N. J. and Kleist, J., 1993. The Relationship of Drought Frequency and Duration to Time Scales'. *Journal of the American Meteorological Society*, 17(22), 179-183.
 9. Mohammad-Rezaei, M., Soltani, S. and Modarres, R., 2020. Evaluating The Effect of Ocean- Atmospheric Indices on Drought in Iran. *Theoretical and Applied Climatology*, 140, 219-230. DOI: 10.1007/s00704-019-03058-6
 10. Nandgude, N., Singh, T. P., Nandgude, S. and Tiwari, M., 2023. Drought Prediction: A Comprehensive Review of Different Drought Prediction Models and Adopted Technologies. *Sustainability*, 15(15), 11684. DOI: 10.3390/su151511684
 11. Nguyen, T. T. H., Li, M. H., Vu, T. M. and Chen, P. Y., 2023. Multiple drought indices and their teleconnections with ENSO in various spatiotemporal scales over the Mekong River Basin. *Science of the Total Environment*, 854, 158589. DOI: 10.1016/j.scitotenv.2022.158589
 12. Pande, C. B., Costache, R., Sammen, S. S., Noor, R. and Elbeltagi, A., 2023. Combination of data-driven models and best subset regression for predicting the standardized precipitation index (SPI) at the Upper Godavari Basin in India. *Theoretical and Applied Climatology*, 152, 535-558. DOI: 10.1007/s00704-023-04426-z
 13. Parvin nia, M. and Riahi Farsani, M., 2016. Drought survey of Shahrekord plain using

دست‌رسی به داده‌ها

همه اطلاعات و نتایج در قالب نمودار، جدول، معادله و رابطه ذکر شده است.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به شرح ذیل اعلام می‌شود:
نویسنده اول: جمع‌آوری اولیه داده‌ها، تهیه نقشه‌ها و توضیح مدل‌ها و تهیه متن
نویسنده دوم راهنمایی، ویرایش، کنترل نتایج و بازبینی متن
نویسنده سوم: تحلیل داده‌ها، تجزیه و تحلیل آماری و بازبینی متن

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر عملی رعایت نموده‌اند و این موضوع مورد تایید همه آنها می‌باشد.

منابع

1. Allahverdipour, P. and Sattari, M. T., 2023. Comparing the performance of the multiple linear regression classic method and modern data mining methods in annual rainfall modeling (Case study: Ahvaz city). *Water and Soil Management and Modeling*, 3(2), pp. 125-142. DOI:10.22098/mmws.2022.11337.1120 [in Persian].
2. Aote, S. S., Pimpalshende, A., Potnurwar, A. and Lohi, S., 2023. Binary Particle Swarm Optimization with an improved genetic algorithm to solve multi-document text summarization problem of Hindi documents. *Engineering Applications of Artificial Intelligence*, 117, pp. 105575. DOI:10.1016/j.engappai.2022.105575
3. Danandeh Mehr, A., Rikhtehgar Ghiasi, A., Yaseen, Z. M., Sorman, A. U. and Abualigah, L., 2023. A novel intelligent deep learning predictive model for meteorological drought forecasting '. *Journal of Ambient Intelligence and Humanized Computing*, 14(8), pp. 10441-10455. DOI :10.1007/s11356-021-15325-z
4. Ehteram, M., Afshari Nia, M., Panahi, F. and Farrokhi, A., 2024. Read-First LSTM model: A new variant of long short term memory neural network for predicting solar

- standardized precipitation index and gamma distribution, 1(2), pp. 41-50 [in Persian].
14. Rezaei, A., 2023. Teleconnections between ocean-atmosphere circulations and historical integrated drought in the Middle East and North Africa. *Environmental Monitoring and Assessment*, 195(755), 1-21. DOI: 10.1007/s10661-023-11386-4
 15. Shah, W., Chen, J., Ullah, I. and Shah, M. H., 2024. Application of RNN-LSTM in Predicting Drought Patterns in Pakistan: A Pathway to Sustainable Water Resource Management. *Water*, 16(11), 1492. DOI : 10.3390/w16111492
 16. Skobtsov, V. Yu., Sokolov, B. V., Zhang, W. A., and Fu M., 2024. Hybrid neural network models for monitoring time series data of complex objects. *Journal of Instrument Engineering* 67(2), pp. 200-204. (in Russian) DOI: 10.17586/0021-3454-2024-67-2-200-204
 17. Taylan, E. D., 2024. An Approach for Future Droughts in Northwest Türkiye: SPI and LSTM Methods. *Sustainability*, 16(16), 6905. DOI :10.3390/su16166905
 18. Vo, T. Q., Kim, S. H., Nguyen, D. H. and Bae, D. H., 2023. LSTM-CM: a hybrid approach for natural drought prediction based on deep learning and climate models. *Stochastic Environmental Research and Risk Assessment*. 37(6), 2035-2051. DOI: 10.1007/s00477-022-02378-w
 19. Wang, G., Cai, W., Santoso, A., Abram, N., Ng, B., Yang, K. and Li, X., 2024. The Indian Ocean Dipole in a warming world. *Nature Reviews Earth & Environment*, 5(8), 588–604. DOI: 10.1038/s43017-024-00573-7
 20. Wu, Z., Yin, H., He, H. and Li, Y., 2022. Dynamic-LSTM hybrid models to improve seasonal drought predictions over China. *Journal of Hydrology*, 615(1), 128706. DOI: 10.1016/j.jhydrol.2022.128706
 21. Xu, D., Zhang, Q., Ding, Y. and Zhang, D., 2022. Application of a hybrid ARIMA-LSTM model based on the SPEI for drought forecasting. *Environmental Science and Pollution*, 29(3), 4128-4144.
 22. Zhang, N., Dai, X., Ehsan, M. A. and Deksissa, T., 2020. Development of a drought prediction system based on long short-term memory networks LSTM. *Springer International Publishin*, 17, 142-153. DOI: 10.1007/978-3-030-64221-1_13

