

Research Paper

Comparison of ARIMA and SARIMA Time Series Models with Machine Learning Algorithms for Meteorological Drought Forecasting (Case study: Khuzestan Province)

Fereshteh Sadeghkhani ¹,Mohammad Ansari Ghojghar ^{2*}

¹ PhD Student, Department of reclamation of arid and mountainous regions, Faculty of Natural Resources, University of Tehran, Karaj, Iran (f.sadeghkhani78@ut.ac.ir)

² Assistant Professor, Department of reclamation of arid and mountainous regions, Faculty of Natural Resources, University of Tehran, Karaj, Iran. (Ansari.ghojghar@ut.ac.ir)



10.22125/iwe.2025.513573.1871

Received:
March 7, 2025
Accepted:
July 13, 2025
Available online:
August 24, 2025

Keywords:
Khuzestan,
Drought,
Machine
Learning,
Seasonal
Patterns, SPI.

Abstract

Regional changes in precipitation and surface air temperature lead to severe droughts and subsequent changes in hydrological patterns. Meteorological drought is an early warning system of drought conditions that is transferred to environmental drought and can seriously affect the aquatic ecosystem. Therefore, monitoring and predicting drought and creating an early warning and foresight system in drought-prone areas is inevitable. In the present study, the performance of ARIMA and SARIMA time series models was compared with ANFIS and ELM machine learning algorithms in order to predict meteorological drought in Khuzestan province. In order to evaluate the SPI meteorological drought index on time scales of 1, 3, 6 and 12 months, statistics and information of eight synoptic stations (Abadan, Bostan, Ahvaz, Bandar Mahshahr, Omidieh, Ramhormoz, Masjed Soleiman and Safiabad) (Dezful) was used from 1989 to 2020. Then, the time series and machine learning models based on SPI were implemented and finally the best model for predicting drought was extracted. RMSE, MAE, NS and R evaluation criteria were used to evaluate the efficiency and performance of the models. The results showed that ELM and ANFIS machine learning models had higher accuracy than ARIMA and SARIMA time series models in SPI forecasting and among the models studied, ELM model has the lowest scattering, the highest accuracy and also the highest correspondence with the first and third quarters. The model with the lowest RMSE and MAE values between 0.375 to 0.403 and 0.305 to 0.341, respectively, and the highest values of NS and R between 0.796 to 0.833 and 0.831, respectively. Up to 0.853, the best model was selected to predict the SPI index. Thus, it can be said that this model has shown more effective efficiency than other models studied. Also, based on the results of SPI, it was found that drought is in normal condition in the study area, but in the future, the situation can be worse, so the use of various modeling results in warning and warning systems can help in managing and reducing the damage caused by this destructive phenomenon. have an environment.

* **Corresponding Author:** Mohammad Ansari Ghojghar

Address: Assistant Professor, Arid and Mountainous Areas Restoration Group, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

Email: Ansari.ghojghar@ut.ac.ir
Tel: 09129675542

1. Introduction

Meteorological drought is a severe regional climate event with a long duration and wide impact range, which is the dominant factor in the occurrence of other types of drought. As an important link, the propagation from meteorological drought to hydrological drought has significant impacts on the water cycle, so accurate and efficient drought forecasting plays an important role in water resources management and planning at the basin scale. Forecasting the occurrence of drought remains a difficult but vital task for meteorologists and water resources managers and is an essential tool for implementing appropriate measures to reduce the negative impacts of drought. Due to the increasing frequency and severity of drought occurrence in Iran in recent years, drought monitoring and forecasting have received increasing attention. In recent years, many researchers have widely used mathematical and statistical models and machine learning methods to model and predict drought.

2. Materials and Methods

In this study, the performance of time series models and machine learning algorithms has been investigated by evaluating and predicting meteorological drought indices. For this purpose, using recorded precipitation data from eight synoptic stations (Abadan, Bostan, Bandar Mahshahr, Omidieh, Ramhormoz, Masjed Soleiman, and Safiabad (Dezful)) located in Khuzestan province over a 30-year period (1989 to 2020), the standardized precipitation index (SPI) was calculated and analyzed at time scales of one, three, six, and 12 months. Precipitation data were considered as input to the models to predict the drought index, and SPI values were predicted at different time scales using ARIMA and SARIMA time series models and ANFIS and ELM machine learning algorithms. In order to evaluate the models, the data was divided into two parts: training and testing. Of the available data, 80% was used for training and 20% for testing the models. In order to evaluate the accuracy and efficiency of the models under study, the evaluation criteria of root mean square error (RMSE), mean absolute error (MAE), Nash-Sutcliffe coefficient (NS), and correlation coefficient (R) were used.

3. Results

According to the results obtained, among the models studied, the ELM model has the lowest dispersion and in fact the highest accuracy and correspondence with the first quartile bisector. Thus, it can be said that the ELM model is more effective than other models in predicting the meteorological drought index. Among the models studied, the ANFIS model had an acceptable performance after the ELM model, but the ARIMA model showed a weaker performance in predictions. In general, although the machine learning models had a significant difference compared to the time series models, the time series models did not differ significantly from each other, nor did the machine learning models differ significantly from each other.

4. Discussion and Conclusion

Time series models and machine learning algorithms can play an important role in long-term forecasts of precipitation values at different time scales. Based on the results of the forecast at all stations studied, the Extreme Learning Machine (ELM) algorithm had higher accuracy in predicting SPI values than other models. The results of the present study indicate the high flexibility of machine learning algorithms in predicting long-term data, which has made machine learning models known as a powerful tool in simulation and forecasting. The study of drought and the prediction of its change trend makes it possible to have a clear understanding of the region based on the forecasts made in order to control the growing trend of drought. Therefore, it can be inferred that the information obtained from machine learning algorithms provides managers and officials with a relatively accurate understanding of the nature of drought before it occurs, so that they can minimize the damage caused by this destructive phenomenon by optimally managing early warning and warning systems during drought.

5. Six important references

- 1) Box, G.E.P. and Jenkins, G.M., (1976). "Time Series Analysis: Forecasting and Control", Holden-Day, San Francisco, 525.
- 2) McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In Proceedings of the 8th Conference on Applied Climatology. 17(22): 179-183).
- 3) Huang, G.-B., Zhu, Q.-Y., Siew, C.-K., 2006. Extreme learning machine: theory and applications. Neurocomputing 70(1), 489–501.

- 4) Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, 23(3), 665-685.
- 5) Durdu, O.F., 2010. Application of linear stochastic models for drought forecasting in the Buyuk Menderes river basin, western Turkey. Stochastic Environmental Research and Risk Assessment. 24 (8), 1145-1162.
- 6) Mishra, A.K., Desa, V.R., Singh, V.P., 2007. Drought forecasting using a hybrid stochastic and neural network model. J. Hydrol. Eng. 12 (6), 626-638.

مقایسه مدل‌های سری زمانی ARIMA و SARIMA با الگوریتم‌های یادگیری ماشین به منظور پیش‌بینی خشکسالی هواشناسی (مطالعه موردی: استان خوزستان)

فرشته صادق‌خانی^۱، محمد انصاری قوجقار^{۲*}

مقاله پژوهشی

تاریخ ارسال: ۱۴۰۳/۱۲/۱۸

تاریخ پذیرش: ۱۴۰۴/۰۴/۲۳

چکیده

تغییرات منطقه‌ای در بارش و دمای هوای سطحی منجر به خشکسالی‌های شدید و متعاقب آن تغییرات در الگوهای هیدرولوژیکی می‌شود. خشکسالی هواشناسی یک سیستم هشدار اولیه از شرایط خشکسالی است که به خشکسالی محیطی منتقل می‌شود و می‌تواند اکوسیستم آبی را به‌طور جدی تحت تأثیر قرار دهد. لذا پیش و پیش‌بینی خشکسالی و ایجاد یک سیستم هشدار اولیه و پیش‌آگاهی در مناطق مستعد خشکسالی، امری اجتناب‌ناپذیر است. در پژوهش حاضر، عملکرد مدل‌های سری زمانی ARIMA و SARIMA با الگوریتم‌های یادگیری ماشین ANFIS و ELM به منظور پیش‌بینی خشکسالی هواشناسی در استان خوزستان مورد مقایسه قرار گرفت. به منظور ارزیابی نمایه خشکسالی هواشناسی SPI در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه، آمار و اطلاعات هشت ایستگاه سینوپتیک (آبادان، بستان، اهواز، بندر ماهشهر، امیدیه، رامهرمز، مسجدسلیمان و صفی‌آباد (دزفول)) طی سال‌های ۱۹۸۹ تا ۲۰۲۰ به کار گرفته شد. سپس، مدل‌های سری زمانی و یادگیری ماشین بر مبنای SPI اجرا و در نهایت بهترین مدل برای پیش‌بینی خشکسالی استخراج شد. به منظور ارزیابی کارایی و عملکرد مدل‌ها از معیارهای ارزیابی RMSE، MAE، NS و R استفاده شد. نتایج نشان داد مدل‌های یادگیری ماشین ELM و ANFIS دقت بالاتری نسبت به مدل‌های سری زمانی ARIMA و SARIMA در پیش‌بینی SPI داشتند و از میان مدل‌های بررسی شده، مدل ELM کمترین پراکندگی، بیشترین دقت و همچنین بالاترین مطابقت را با نیم‌ساز ربع‌های اول و سوم دارد. مدل مذکور با کمترین مقدار RMSE و MAE به ترتیب بین ۰/۳۷۵ تا ۰/۴۰۳ و ۰/۳۰۵ تا ۰/۳۴۱ و بیشترین مقدار NS و R به ترتیب بین ۰/۷۹۶ تا ۰/۸۳۳ و ۰/۸۳۱ تا ۰/۸۵۳، بهترین مدل به منظور پیش‌بینی نمایه SPI انتخاب شد. بدین ترتیب می‌توان بیان نمود که این مدل کارایی موثرتری نسبت به سایر مدل‌های مورد بررسی از خود نشان داده است. همچنین، بر اساس نتایج SPI مشخص شد در منطقه مورد مطالعه، خشکسالی در وضعیت نرمالی قرار دارد ولی در آینده می‌تواند وضعیت وخیم‌تری به وجود آید لذا استفاده از نتایج مدل‌سازی‌های مختلف در سیستم‌های پیش‌آگاهی و هشدار دهنده می‌تواند کمک به‌سزایی در مدیریت و کاهش خسارات ناشی از این پدیده مخرب زیست‌محیطی به همراه داشته باشد.

واژه‌های کلیدی: خوزستان، خشکسالی، یادگیری ماشین، الگوهای فصلی، SPI.

۱. دانشجوی دکتری، گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: f.sadeghkhani78@ut.ac.ir

۲. استادیار، گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Ansari.ghojghar@ut.ac.ir. (*: نویسنده مسئول)



مقدمه

خشکسالی یکی از گسترده‌ترین و شدیدترین بلاهای طبیعی است که ترکیبی از بارندگی کمتر از حد نرمال، دمای بالاتر از حد نرمال و کاهش رطوبت نسبی است (Zhao et al., 2020) و آسیب‌های اجتماعی، اقتصادی و زیست-محیطی فراوانی را به همراه دارد (Wu et al., 2021). با توجه به روند افزایش تغییرپذیری بارندگی و دمای هوای سطحی، فراوانی، شدت و مدت خشکسالی‌ها در بسیاری از مناطق جهان در حال افزایش است (Su et al., 2024). خشکسالی به‌طور معمول به چهار نوع خشکسالی هواشناسی، خشکسالی هیدرولوژیکی، خشکسالی کشاورزی و خشکسالی اجتماعی - اقتصادی طبقه‌بندی می‌شود. خشکسالی هواشناسی که به عنوان رویدادهای اقلیمی شدید منطقه‌ای با مدت طولانی و دامنه تأثیر گسترده مشخص می‌شود، عامل غالب در وقوع سایر انواع خشکسالی است (Zhang et al., 2024). خشکسالی می‌تواند خسارات زیادی را به همراه داشته باشد. به عنوان یک پیوند مهم، انتشار از خشکسالی هواشناسی به خشکسالی هیدرولوژیکی تأثیرات قابل توجهی بر چرخه آب دارد، بنابراین پیش‌بینی دقیق و کارآمد خشکسالی نقش مهمی در مدیریت و برنامه‌ریزی منابع آب در مقیاس حوضه ایفا می‌کند (Fooladi et al., 2021).

در مناطق خشک و نیمه‌خشک به دلیل تغییرات اقلیمی و کمبود منابع آبی پیش‌بینی خشکسالی از اهمیت بالایی برخوردار است (En-Nagreg et al., 2024). ایران سرزمینی با شرایط آب و هوایی گوناگون است که پهنه‌ای وسیع از آن را دشت‌های خشک و نیمه‌خشک در بر گرفته‌اند و طی دهه‌های اخیر با کاهش میزان بارندگی و افزایش قابل توجه دما روبرو بوده است که در آینده نیز افزایش نرخ دما را تجربه خواهد کرد (Ghozat et al., 2023). این امر منجر به افزایش وقوع خشکسالی و در نتیجه کمبود منابع آب و گسترش بیابان‌زایی خواهد شد که به نوبه خود با اثرات منفی اجتماعی و اقتصادی همراه است (Keshavarz et al., 2013). پیش‌بینی وقوع خشکسالی همچنان یک وظیفه

دشوار اما حیاتی برای آب و هواشناسان و مدیران منابع آب است و ابزار ضروری برای اجرای اقدامات مناسب به منظور کاهش اثرات منفی خشکسالی به شمار می‌رود (Khadr, 2016). با توجه به افزایش فراوانی و شدت وقوع خشکسالی در ایران طی سال‌های اخیر، پایش و پیش‌بینی خشکسالی به‌طور فزاینده‌ای مورد توجه قرار گرفته است.

در سال‌های اخیر، بسیاری از محققان به‌طور گسترده از مدل‌های ریاضی و آماری و روش‌های یادگیری ماشین به منظور مدلسازی و پیش‌بینی خشکسالی استفاده کرده‌اند. حسینی موعاری و عراقی‌نژاد (۱۳۹۵) در مطالعه‌ای به بررسی کاربرد الگوریتم‌های هوش مصنوعی در پایش و پیش‌بینی خشکسالی در ایستگاه گنبد کاووس پرداختند. این پژوهشگران با به‌کارگیری شاخص بارش استاندارد شده (SPI)^۱ در سری‌های زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه و با استفاده از چهار الگوریتم یادگیری ماشین MLP^۲، ANFIS^۳، RBF^۴ و GRNN^۵ خشکسالی را بررسی و پیش‌بینی نمودند. نتایج آنها نشان داد مدل ANFIS در مقایسه با دیگر مدل‌ها بهترین عملکرد را داشته است. ارجمندی هرات و اسدی (۱۴۰۱) در مطالعه‌ای به مقایسه عملکرد مدل‌های سری زمانی SARIMA^۶ و SARIMAX^۷ به منظور پیش‌بینی بلندمدت خشکسالی ایستگاه همدیدی یزد در سری‌های زمانی یک، سه و شش ماهه پرداختند. آنها بیان داشتند مدل SARIMAX عملکرد بهتری نسبت به مدل SARIMA در پایش و پیش‌بینی خشکسالی دارد. قیصوری و همکاران (۱۴۰۱) در پژوهشی با استفاده از مدل‌های سری زمانی ARIMA^۸ و براساس نمایه SPI به پیش‌بینی خشکسالی هواشناسی در استان تهران پرداختند. نتایج آنها حاکی از آن بود که در منطقه مورد مطالعه، خشکسالی در وضعیت نزدیک به نرمال بوده و عملکرد مدل مورد بررسی در مدلسازی تغییرات اقلیمی رضایت‌بخش بوده است. Mishra و همکاران (۲۰۰۷) در پژوهشی عملکرد مدل‌های سری زمانی ARIMA و SARIMA و همچنین مدل‌های شبکه عصبی

5. General Regression Neural Network

6. Seasonal Autoregressive Integrated Moving Average

7. Seasonal Autoregressive Integrated Moving Average + exogenous variables

8. AutoRegressive Integrated Moving Average

^۱ Standardized Precipitation Index

^۲ Multi-Layer Perceptron

^۳ Adaptive Neuro-Fuzzy Inference System

^۴ Radial Basis Function

ماشین به صورت یکجا و همزمان به منظور پیش‌بینی شرایط خشکسالی در کشور انجام نشده است، پژوهش حاضر بر آن است با استفاده از نمایه SPI و آمار و اطلاعات هشت ایستگاه سینوپتیک واقع در استان خوزستان به مقایسه و ارزیابی عملکرد مدل‌های سری زمانی ARIMA و SARIMA با دو الگوریتم یادگیری ماشین ANFIS و ELM^۲ به منظور پیش‌بینی خشکسالی هواشناسی بپردازد.

مواد و روش‌ها

منطقه مورد مطالعه

استان خوزستان با وسعت حدود ۶۴ هزار کیلومتر مربع در جنوب غرب ایران و بین طول جغرافیایی ۴۷ درجه و ۳۹ دقیقه تا ۵۰ درجه و ۳۳ دقیقه شرقی و عرض جغرافیایی ۲۹ درجه و ۵۲ دقیقه تا ۳۲ درجه و ۵۹ دقیقه شمالی قرار دارد. استان خوزستان و سواحل مجاور آن از مناطق گرم دنیا هستند، به‌طوریکه متوسط گرمای سالانه آن از ۲۴ تا ۲۸ درجه سانتی‌گراد متغیر است. این استان با داشتن تنها چهار درصد از مساحت کل کشور، بیش از ۳۰ درصد آب‌های سطحی کشور را در خود جای داده است. از این رو در معادلات آبی کشور نقش به‌سزایی دارد.

در مطالعه حاضر به منظور ارزیابی و پیش‌بینی شاخص هواشناسی بارش استاندارد شده (SPI) از داده‌های بارش هشت ایستگاه هواشناسی سینوپتیک واقع در استان خوزستان استفاده شده است (شکل ۱). آمار و اطلاعات این ایستگاه‌ها در جدول ۱ ارائه شده است.

روش تحقیق

در این مطالعه با ارزیابی و پیش‌بینی شاخص‌های خشکسالی هواشناسی، عملکرد مدل‌های سری زمانی با الگوریتم‌های یادگیری ماشین مورد بررسی و مقایسه قرار گرفته است. بدین منظور با استفاده از داده‌های بارش ثبت شده هشت ایستگاه سینوپتیک (آبادان، بستان، بندرماهشهر، امیدیه، رامهرمز، مسجد سلیمان و صفی‌آباد (دزفول)) واقع در استان خوزستان طی دوره ۳۰ ساله (۱۹۸۹ تا ۲۰۲۰)، شاخص بارش استاندارد شده (SPI) در مقیاس زمانی ۱، ۳،

مصنوعی ترکیبی را به منظور پیش‌بینی خشکسالی در حوضه رودخانه Kansabati در شرق هند مورد بررسی قرار دادند. نتایج آنها نشان داد عملکرد مدل‌های شبکه عصبی مصنوعی در مدل‌سازی و پیش‌بینی خشکسالی بهتر بوده است. Durdu (۲۰۱۰) در مطالعه‌ای به پیش‌بینی مدل‌های سری زمانی ARIMA و SARIMA براساس نمایه SPI در حوضه رودخانه Buyuk Menderes واقع در غرب ترکیه طی سال‌های ۱۹۷۵ تا ۲۰۰۶ پرداختند. آنها براساس نتایج خود استدلال داشتند مدل‌های مورد بررسی برای پیش‌بینی SPI در مقیاس‌های زمانی مختلف از دقت معقولی برخوردار بوده‌اند. Alam و همکاران (۲۰۱۴) در مطالعه‌ای عملکرد مدل‌های ARIMA و SARIMA را به منظور پیش‌بینی خشکسالی هواشناسی در منطقه Bundelkhand واقع در هند مورد بررسی قرار دادند. نتایج آنها نشان داد براساس نمایه SPI و در مقیاس‌های زمانی ۳، ۶، ۹، ۱۲ و ۲۴ ماهه، خشکسالی در منطقه مورد مطالعه از نسبتاً زیاد تا بسیار زیاد متغیر بوده است. همچنین بیان نمودند مدل ARIMA برای سری SPI سه ماهه دقت خوبی داشته و به‌طور کلی داده‌های پیش‌بینی شده تطابق خوبی با داده‌های واقعی داشتند. HsinFu و HsinLi (۲۰۱۹) در مطالعه‌ای با استفاده از مدل ARIMA و بر مبنای SPI به بررسی و پیش‌بینی شرایط خشکسالی در جنوب تایوان پرداختند. نتایج آنها نشان داد پیش‌بینی خشکسالی با استفاده از مدل ARIMA از دقت کافی برخوردار است. En-Nagreg و همکاران (۲۰۲۴) در پژوهشی با استفاده از الگوریتم‌های یادگیری ماشین و داده‌های اقلیمی به پیش‌بینی خشکسالی هواشناسی در حوضه Upper Draa در مراکش طی سال‌های ۱۹۸۰ تا ۲۰۱۹ پرداختند. نتایج آنها نشان داد توزیع خشکسالی در حوضه مورد مطالعه یکنواخت نبوده و الگوریتم‌های یادگیری ماشین به‌طور موثر مقادیر SPEI^۱ را برای دوره‌های مشخص شده پیش‌بینی کرده‌اند.

با توجه به تغییرات اقلیمی طی چند سال اخیر و کاهش بارندگی در سطح کشور، مدل‌سازی و پیش‌بینی خشکسالی‌ها امری ضروری به‌نظر می‌رسد. از آنجا که تاکنون پژوهش‌های جامعی در خصوص مقایسه عملکرد مدل‌های مختلف سری زمانی و الگوریتم‌های فراکاوشی یادگیری

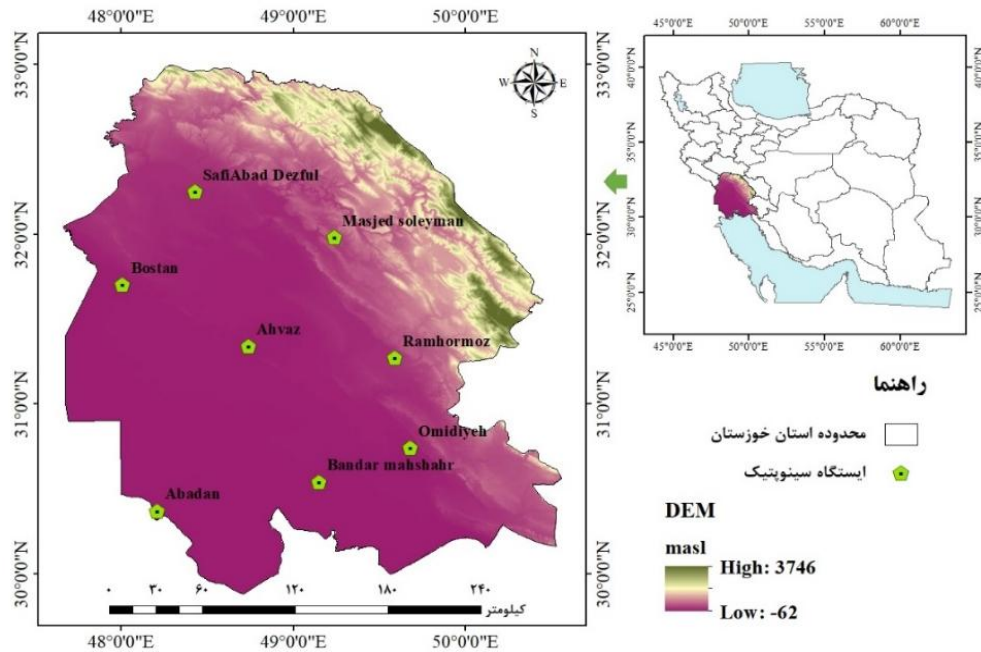
2. Extreme Learning Machine

1. Standardized Precipitation Evapotranspiration Index



مختلف با استفاده از مدل‌های سری زمانی؛ مدل خودهمبسته-میانگین متحرک یکپارچه (ARIMA) و مدل

۶ و ۱۲ ماهه محاسبه و تحلیل شد. داده‌های بارش به منظور پیش‌بینی شاخص خشکسالی به عنوان ورودی به مدل‌ها در نظر گرفته شد و مقادیر نمایه SPI در مقیاس‌های زمانی



شکل (۱): موقعیت جغرافیایی استان خوزستان و ایستگاه‌های مورد بررسی

جدول (۱): آمار و اطلاعات ایستگاه‌های سینوپتیک در استان خوزستان

| ردیف | نام ایستگاه | طول جغرافیایی (درجه) | عرض جغرافیایی (درجه) | ارتفاع از سطح دریا (متر) |
|------|------------------|----------------------|----------------------|--------------------------|
| ۱ | آبادان | ۴۸°۱۲'۵۳" | ۳۰°۲۲'۳۷" | ۶/۶ |
| ۲ | بستان | ۴۸°۰۰'۳۶" | ۳۱°۴۲'۲۸" | ۷/۸ |
| ۳ | اهواز | ۴۸°۴۴'۳۹" | ۳۱°۲۰'۴۴" | ۲۲/۵ |
| ۴ | بندر ماهشهر | ۴۹°۰۹'۳۶" | ۳۰°۳۳'۴۰" | ۶/۲ |
| ۵ | امیدیه | ۴۹°۴۰'۱۴" | ۳۰°۴۴'۳۲" | ۲۷ |
| ۶ | رامهرمز | ۴۹°۳۵'۴۷" | ۳۱°۱۶'۲۲" | ۱۵۰/۵ |
| ۷ | مسجد سلیمان | ۴۹°۱۴'۲۶" | ۳۲°۰۰'۰۳" | ۳۲۰/۵ |
| ۸ | صفی‌آباد (دزفول) | ۴۸°۲۵'۵۹" | ۳۲°۱۵'۵۸" | ۸۲/۹ |

تقسیم شدند، از بین داده‌های موجود ۸۰ درصد برای آموزش و ۲۰ درصد نیز برای آزمون مدل‌ها به کار گرفته شد. در ادامه به منظور ارزیابی دقت و کارایی مدل‌های مورد بررسی، از معیارهای ارزیابی ریشه میانگین مربعات خطا (RMSE)^۱، میانگین قدرمطلق خطا (MAE)^۲، ضریب

ترکیب فصلی خودهمبسته - میانگین متحرک یکپارچه (SARIMA) و الگوریتم‌های یادگیری ماشین؛ سیستم استنباط عصبی - فازی تطبیقی (ANFIS) و یادگیری ماشین افراطی (ELM) پیش‌بینی شدند. به منظور ارزیابی مدل‌ها، داده‌ها به دو بخش آموزش و آزمون

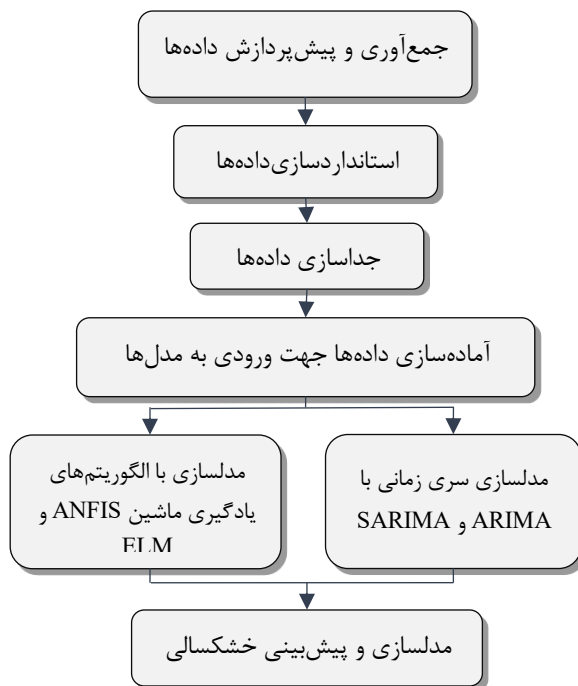
2. Mean Absolute Error

1 Root-Mean-Square Error

از شاخص‌های ارزیابی خشکسالی تعیین کرد. در مطالعه حاضر به دلیل اهمیت خشکسالی هواشناسی از نمایه خشکسالی SPI استفاده شده است.

نش- ساتکلیف (NS)^۱ و ضریب همبستگی (R)^۲ استفاده شد.

از خصوصیات مهم خشکسالی شدت، تداوم، گستره و فراوانی آن می‌باشد که این ویژگی‌ها را می‌توان با استفاده



شکل (۲): مراحل پیش‌بینی و مدلسازی خشکسالی هواشناسی

(2022; Mashayekhi et al., 2020). نمایه SPI براساس

رابطه (۱) محاسبه می‌شود:

$$SPI = \frac{P + \mu(P)}{\sigma(P)} \quad (1)$$

که در آن، P مقدار بارش، $\mu(P)$ میانگین مقدار بارش برای یک بازه زمانی مشخص و $\sigma(P)$ انحراف معیار مقدار بارش است. در جدول ۱ رتبه‌بندی مقادیر نمایه SPI ارائه شده است که نشان می‌دهد چنانچه مقدار SPI بیشتر از یک باشد، معرف وضعیت ترسالی و اگر کمتر از ۱- باشد معرف وقوع خشکسالی است.

جدول (۲): رتبه‌بندی شدت خشکسالی و ترسالی بر اساس

نمایه SPI (McKee et al., 1993)

| وضعیت | مقادیر نمایه SPI |
|-------|------------------|
|-------|------------------|

شاخص بارش استاندارد شده (SPI)

شاخص بارش استاندارد شده، نمایه‌ای براساس احتمال بارش برای هر بازه زمانی است که در سال ۱۹۹۳ توسط McKee و همکارانش به منظور پایش خشکسالی ارائه شد (McKee et al., 1993). SPI به منظور هشدار اولیه و پایش شدت خشکسالی و به‌کارگیری آن در مقیاس‌های زمانی مختلف مورد توجه بسیاری از محققان قرار گرفته است. این نمایه تنها به اطلاعات بارندگی نیازمند است و در هر منطقه براساس بارش‌های طولانی مدت طی یک دوره مشخص محاسبه می‌شود (Hayes, 2006). برای محاسبه آن ابتدا توزیع آماری مناسب برای داده‌های بلندمدت بارش برآزش داده می‌شود و سپس تابع تجمعی توزیع با استفاده از احتمالات مساوی به توزیع نرمال تبدیل خواهد شد، به‌طوریکه استاندارد شده و متوسط آن برای هر منطقه و دوره مورد بررسی صفر شود (Kumar et al.,)



| | | | |
|-----------------|-------------------|-------------------|--------------------|
| $-1 < SPI < 1$ | نرمال | $-2 > SPI$ | خشکسالی بسیار شدید |
| $1 < SPI < 1/5$ | ترسالی ملایم | $-1/5 < SPI < -2$ | خشکسالی شدید |
| $1/5 < SPI < 2$ | ترسالی شدید | $-1 < SPI < -1/5$ | خشکسالی ملایم |
| $2 < SPI$ | ترسالی بسیار شدید | | |

زمانی استفاده می‌شود، به‌ویژه زمانی که داده‌ها، الگوهای فصلی یا چرخه‌ای مشخصی را نشان می‌دهند. این مدل براساس مفاهیم اصلی مدل ARIMA ساخته شده است و به دلیل انعطاف‌پذیری زیاد، ابزار مناسبی برای شبیه‌سازی و بهینه‌سازی انواع مختلف سری زمانی است. در مدل $SARIMA(P, D, Q)(p, d, q)$ که نسخه فصلی ARIMA است، q ، d و p به ترتیب نشان دهنده مرتبه‌های اتورگرسیون، تفاضل و میانگین متحرک غیر فصلی هستند. درحالی که D ، Q و P نمایانگر پارامترهای فصلی هستند که به ترتیب مرتبه‌های اتورگرسیون، تفاضل و میانگین متحرک فصلی را مشخص می‌کنند.

سری‌های زمانی اغلب دارای اثرات فصلی می‌باشند که اغلب از تفاضل‌گیری فصلی برای حذف اثرات فصلی استفاده می‌شود. با استفاده از توابع خودهمبستگی (ACF) و خودهمبستگی جزئی $(PACF)$ مدل‌های سری زمانی مناسب به داده‌ها برازش داده شد و با استفاده از رفتار این دو تابع، خواص ایستایی و فصلی بودن داده‌ها مورد بررسی قرار گرفت. (Box and Jenkins, 1976)

سیستم استنباط عصبی - فازی تطبیقی (ANFIS)

مدل ANFIS در سال ۱۹۹۳ توسط جانگ معرفی گردید (Jang, 1993). ANFIS یک شبکه عصبی چند لایه است که علاوه بر الگوریتم‌های یادگیری شبکه عصبی، از منطق فازی نیز بهره می‌گیرد. مدل ANFIS از پنج لایه تشکیل شده است؛ لایه ورودی اطلاعات، لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی وزن‌های قوانین به‌دست آمده، لایه محاسبه قوانین، لایه جمع‌بندی و خروجی شبکه (Jang, 1993). در شکل ۳ شماتیکی از مدل ANFIS نمایش داده شده است.

مدل خودهمبسته - میانگین متحرک یکپارچه (ARIMA)

مدلسازی سری‌های زمانی به منظور مهیا کردن یک روش تجربی سیستماتیک برای شبیه‌سازی و پیش‌بینی رفتار سیستم‌های متغیر آبی و برای تعیین دقت مورد انتظار پیش‌بینی‌ها، نمایش داده شده‌اند. مدل ARIMA مدل‌های غیر فصلی هستند که ترکیبی از عملگرهای خود همبسته و میانگین متحرک‌اند. مدل ARIMA عموماً از سه مدل زمانی پایه استخراج می‌شوند: مدل خودهمبسته (AR)، مدل میانگین متحرک (MA) و مدل ترکیبی خود همبسته - میانگین متحرک (ARMA). به‌طور کلی مدل‌های ARIMA دارای دو شکل کلی هستند: مدل فصلی $(P, D, Q)(p, d, q)$ و مدل ARIMA غیر فصلی (p, d, q) . D ، Q و P بخش‌های فصلی و p ، d و q بخش‌های غیر فصلی مدل هستند. شکل مدل $ARIMA(p, d, q)$ براساس رابطه ۲ نوشته می‌شود:

$$\varphi(B)\nabla^d Z_t = \theta(B)a_t \quad (2)$$

$$\theta(B) = 1 - \sum_{i=1}^P \theta_i B^i \quad (3)$$

$$\varphi(B) = 1 - \sum_{i=1}^q \varphi_i B^i \quad (4)$$


که در آن، Z_t سری زمانی مشاهداتی، θ_i و φ_i پارامترهای مدل، p و q مرتبه‌های مدل و B عملگر انتقال پسرو می‌باشد (Durdu, 2010).

مدل ترکیب فصلی خودهمبسته - میانگین متحرک یکپارچه (SARIMA)

این مدل در اوایل دهه ۱۹۷۰ توسط باکس و جنکینز معرفی شد. مدل SARIMA روش آماری شناخته‌شده‌ای است که به‌طور گسترده برای پیش‌بینی داده‌های سری

$$\beta = H^+Y \quad (10)$$

که در آن، H^+ ماتریس لایه پنهان معکوس شده موور- پنروس است و وزن‌های ورودی و مقادیر پنهان به‌طور تصادفی انتخاب و وزن‌های خروجی به صورت تحلیلی و آنالیز، تعیین می‌شوند (Huang et al., 2006).



شکل(۴): یک شبکه ELM با یک لایه پنهان (Eivazi et al., 2009)

حالت‌های پیش‌بینی

در این پژوهش، به منظور پیش‌بینی کمی خشکسالی از چهار حالت مختلف برای پیش‌بینی مقدار شاخص خشکسالی هواشناسی با پنجره‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه استفاده گردید. بر این اساس، حالت اول پیش‌بینی می‌کند که میزان SPI_{12} در زمان $t+1$ (آینده)، تابعی از میزان SPI_{12} در زمان t (حال) است. به عبارتی دیگر، مدل از داده‌های SPI_{12} در زمان t به عنوان ورودی استفاده کرده و با بهره‌گیری از الگوریتم‌های مدنظر، میزان SPI_{12} را در زمان $t+1$ پیش‌بینی می‌نماید. به‌طور مشابه، در سایر حالت‌ها بر حسب پنجره زمانی آنها این عمل انجام می‌پذیرد.


$$SPI_{12(t+1)} = f(SPI_{12(t)}) \quad \text{حالت اول (۱۱)}$$

$$SPI_{6(t+1)} = f(SPI_{6(t)}) \quad \text{حالت دوم (۱۲)}$$

$$SPI_{3(t+1)} = f(SPI_{3(t)}) \quad \text{حالت سوم (۱۳)}$$

$$SPI_{1(t+1)} = f(SPI_{1(t)}) \quad \text{حالت چهارم (۱۴)}$$

معیارهای ارزیابی



شکل (۳): شماتیک مدل استنباط عصبی - فازی تطبیقی (Ehteram et al., 2019) (ANFIS)

مدل یادگیری ماشین افراطی (ELM)

مدل ELM یک الگوریتم یادگیری ماشین است که در سال ۲۰۰۶ توسط Huang و همکارانش برای شبکه‌های عصبی پیشرو تک لایه استاندارد (SLFNs) ارائه گردید (Huang et al., 2006). تئوری بنیادی مدل ELM بیان می‌کند که برای N نمونه ورودی دلخواه $\in R^n \times R^n$ (x_k, y_k) با SLFNs M گره پنهان و یک تابع فعال‌ساز g در رابطه ۵ تعریف شده است.

$$y_k = \sum_{i=1}^M \beta_i g(x_k; c_i, w_i) \quad K = 1, 2, 3, \dots, N \quad (5)$$

که در آن $c_i \in R$ مقدار تصادفی تخصیص یافته گره پنهان i و $w_i \in R$ بردار وزن ورودی است که گره ورودی و گره پنهان i را بهم متصل می‌کند. β_i بردار وزنی است که گره پنهان i را به گره خروجی وصل می‌کند. $(x_k; c_i, w_i)$ خروجی گره پنهان i است، با توجه به نمونه ورودی x_k هر ورودی به‌طور تصادفی به گره‌های پنهان در شبکه ELM اختصاص می‌یابد. بنابراین معادله ۵ به صورت رابط ۶ تا ۱۰ می‌شود:

$$H\beta = Y \quad (6)$$

$$H = \begin{bmatrix} g(x_1; c_1, w_1) & \dots & g(x_1; c_M, w_M) \\ g(x_N; c_1, w_1) & \dots & g(x_N; c_M, w_M) \end{bmatrix}_{N \times M} \quad (7)$$

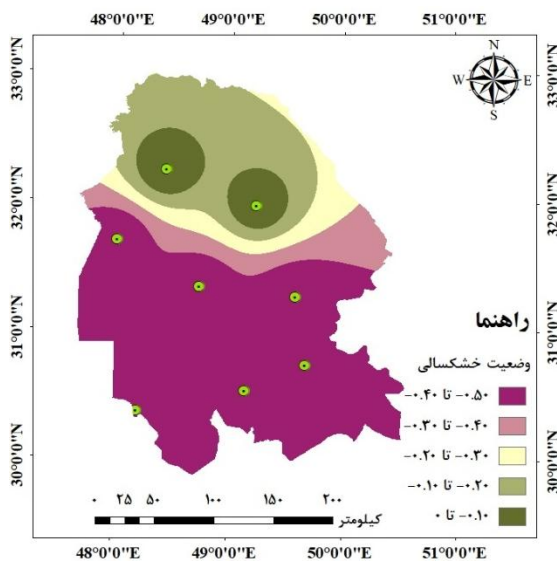
$$H\beta = (\beta_1^T, \beta_2^T, \dots, \beta_L^T)^T_{m \times M} \quad (8)$$

$$H\beta = (t_1^T, t_2^T, \dots, t_L^T)^T_{m \times M} \quad (9)$$



دزفول) واقع در استان خوزستان، شاخص بارش استاندارد شده (SPI) در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه محاسبه گردید. به منظور تعیین وضعیت خشکسالی با استفاده از مقادیر محاسباتی نمایه SPI نقشه پهنه‌بندی وضعیت خشکسالی برای منطقه تهیه شد.

در شکل ۵ وضعیت خشکسالی و ترسالی براساس مقادیر نمایه SPI برای استان خوزستان نشان داده شده است. با توجه به نقشه پهنه‌بندی خشکسالی، در استان خوزستان طی دوره زمانی ۳۰ ساله خشکسالی در وضعیت نرمال قرار دارد و این روند در تمامی ایستگاه‌های مورد بررسی قابل لمس است، اما در ایستگاه‌هایی که در شمال استان قرار دارند مانند ایستگاه مسجدسلیمان و صفی‌آباد (دزفول) به دلیل بالا بودن میزان رطوبت و بارش، روند خشکسالی از وضعیت نرمال به سمت ترسالی تغییر پیدا کرده است.



شکل (۵): نقشه پهنه‌بندی وضعیت خشکسالی در استان خوزستان

اولین قدم در مدل‌سازی و پیش‌بینی سری‌های زمانی، شناسایی ویژگی‌های مهمی نظیر همبستگی، الگوهای فصلی، تغییرات دوره‌ای در الگوهای فصلی، روند و ایستایی یا غیرایستایی داده‌هاست. وجود همبستگی در میان داده‌های سری زمانی، امکان اجرای مدل‌سازی و پیش‌بینی مقادیر بعدی سری زمانی را فراهم می‌کند. در این مطالعه، وجود همبستگی با ترسیم منحنی‌های ACF و PACF برای

در پژوهش حاضر، به منظور ارزیابی دقت و کارایی مدل‌های برازش داده شده و بررسی ارتباط بین داده‌های مشاهداتی و پیش‌بینی شده از معیارهای ارزیابی از جمله ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب نش- ساتکلیف (NS) و ضریب همبستگی (R) براساس روابط ۱۶ تا ۱۹ استفاده شد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i - y_i|^2} \quad (16)$$

$$0 \leq RMSE < \infty$$

$$MAE = \frac{1}{N} \sum |x_i - y_i| \quad (17)$$

$$0 \leq MAE < \infty$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad (18)$$

$$-\infty < NS \leq 1$$

$$R = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (19)$$

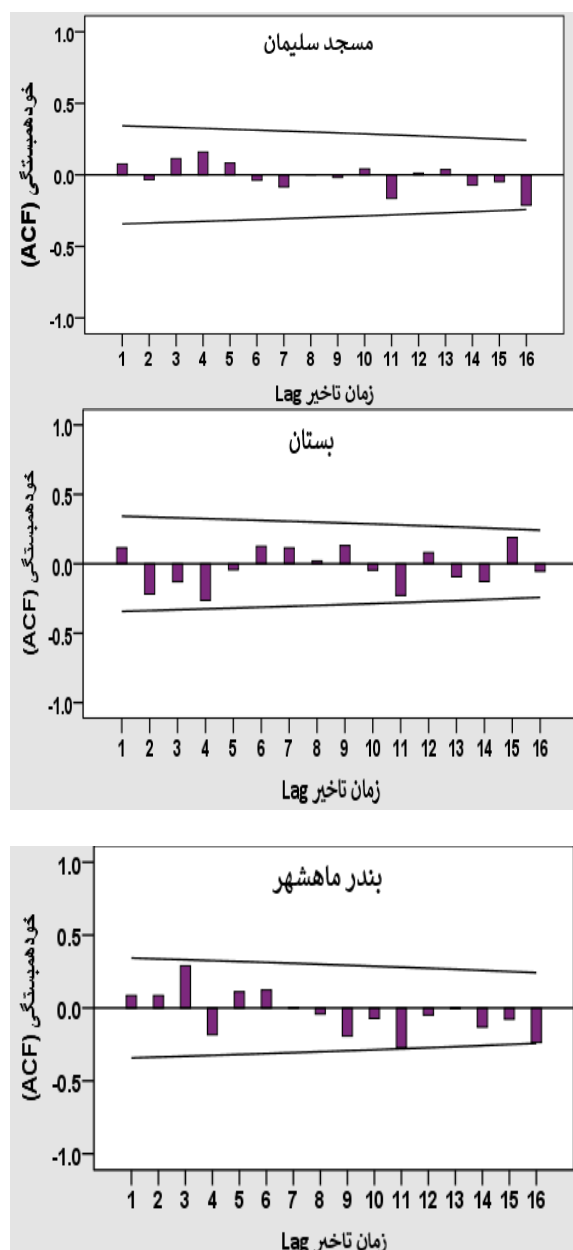
$$0 \leq R \leq 1$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و مقادیر پیش‌بینی شده در گام‌های زمانی i ، N تعداد گام‌های زمانی و \bar{x} و \bar{y} به ترتیب میانگین مقادیر مشاهداتی و مقادیر پیش‌بینی شده است. بر این اساس، هر چه مقادیر ضریب نش- ساتکلیف و ضریب همبستگی به یک نزدیک‌تر و هر چه مقادیر میانگین مربعات خطا و میانگین قدر مطلق خطا به صفر نزدیک‌تر باشند، نشان دهنده دقت بالای مدل است. بنابراین، بر این اساس، مدلی که RMSE و MAE کمتر و NS و R بیشتری داشته باشد کارایی و مطلوبیت بیشتری دارد.

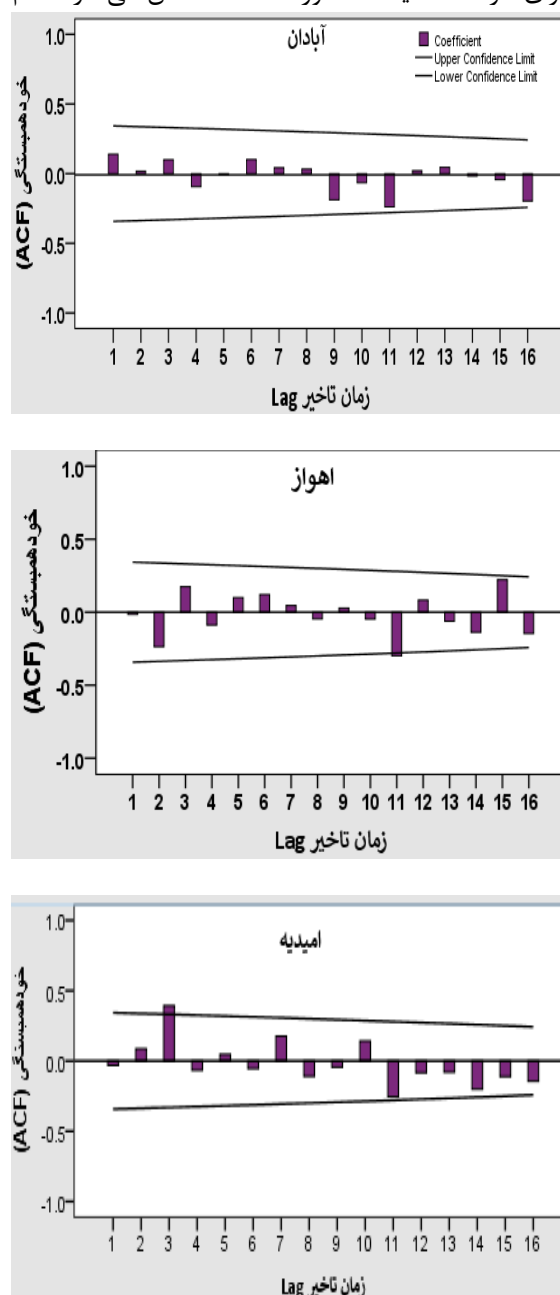
نتایج و بحث

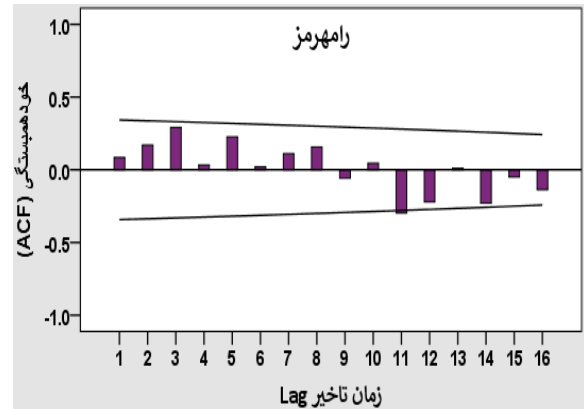
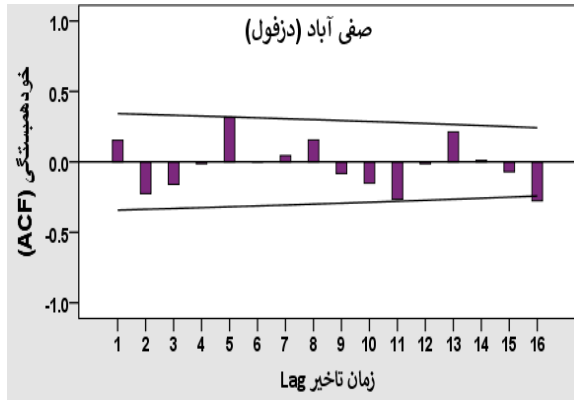
در مطالعه حاضر به منظور پیش‌بینی خشکسالی هواشناسی طی سال‌های ۱۹۸۹ تا ۲۰۲۰ در محدوده استان خوزستان، عملکرد مدل‌های سری زمانی ARIMA و SARIMA با مدل‌های یادگیری ماشین ELM و ANFIS مورد بررسی و مقایسه قرار گرفت. بدین منظور با استفاده از داده‌های بارش ایستگاه‌های سینوپتیک آبادان، بستان، بندر ماهشهر، امیدیه، رامهرمز، مسجد سلیمان و صفی‌آباد

بسیار مهم در تجزیه و تحلیل سری‌های زمانی بررسی ایستایی یا غیر ایستایی میانگین سری‌های زمانی است. با توجه به شکل‌های ۶ و ۷، نمودارهای ACF و PACF حکایت از ایستایی داده‌های همه سری‌های زمانی به غیر از ایستگاه امیدیه دارد. با توجه به تعداد زیاد شکل‌های SPI، صرفاً منحنی‌های ACF و PACF نمایه SPI با پنجره زمانی ۱۲ ماهه آورده شده است. این در حالی است که سایر پنجره‌های زمانی نیز از الگوی ۱۲ ماهه پیروی می‌کنند.

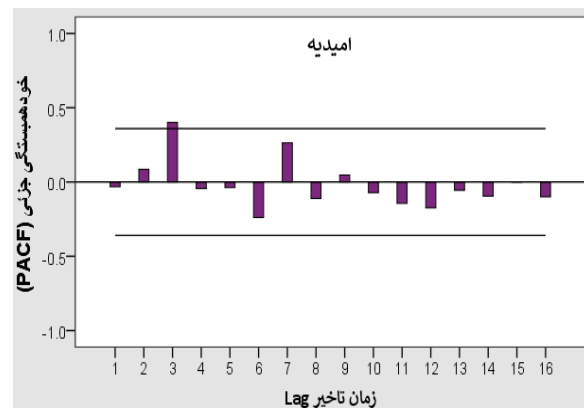


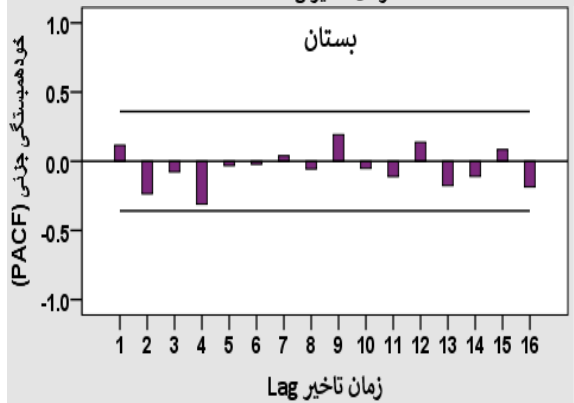





هر ایستگاه با فاصله اطمینان ۹۵ درصد (خطوط همگرا) بررسی شد (شکل‌های ۶ و ۷). اگر مقدار همبستگی مشاهده شده در خارج از این محدوده واقع شود، مقدار همبستگی در سطح خطای ۵ درصد به‌طور معنی‌داری با صفر اختلاف دارد. همانطور که در منحنی‌های ACF و PACF ایستگاه‌های استان خوزستان مشاهده می‌شود، وقفه‌های زمانی معنی‌دار بیانگر وجود همبستگی بین داده‌های نمایه SPI است که اجرای مدلسازی و پیش‌بینی مقادیر آینده SPI را برای هر هشت ایستگاه مورد مطالعه ممکن می‌سازد. گام





شکل (۶): نمودار خودهمبستگی (ACF) در ایستگاه‌های مطالعاتی





شکل (۷): نمودار خودهمبستگی جزئی (PACF) در ایستگاه‌های مطالعاتی

جدول (۳): نتایج آزمون Dickey-Fuller

| نام ایستگاه | P-Value |
|-------------------|---------|
| آبادان | ۰/۰۱۲ |
| بستان | ۰/۰۱۷ |
| اهواز | ۰/۰۹ |
| بندر ماهشهر | ۰/۰۵۶ |
| امیدیه | ۰/۳۷۱ |
| رامهرمز | ۰/۰۲۵ |
| مسجد سلیمان | ۰/۰۴۲ |
| صافی آباد (دزفول) | ۰/۰۳۵ |

پس از تعیین مقادیر SPI برای هر ایستگاه در مقیاس‌های زمانی مختلف، مقادیر پیش‌بینی شده این نمایه با استفاده از مدل‌های مورد نظر برای هر ایستگاه استخراج گردید. به منظور پیاده‌سازی مدل‌ها برای پیش‌بینی مقادیر SPI از زبان برنامه‌نویسی R استفاده شد.

مقایسه عملکرد مدل‌های سری زمانی با الگوریتم‌های یادگیری ماشین

در داده‌های غیر فصلی و سالانه، معمولاً با یکبار تفاضل‌گیری درجه اول داده‌ها ایستا می‌شوند؛ لذا با توجه به پنجره‌های زمانی نمایه SPI، با تفاضل‌گیری درجه اول ($D=1$) داده‌های ایستگاه امیدیه ایستا شدند. با توجه به توابع خودهمبستگی و خودهمبستگی جزئی، محدوده تغییرات اوتورگرسیون و میانگین متحرک تعیین و با استفاده از معیارهای ارزیابی مناسب، بهترین مدل سری زمانی برای هر ایستگاه مشخص شد. همچنین آزمون Dickey-Fuller برای تشخیص ایستایی یا نایستایی سری‌های زمانی بر روی مجموعه داده‌های آموزشی استفاده شد (جدول ۳). در آزمون Dickey-Fuller، سطح معنی‌داری برای احتمال $P\text{-Value} \leq 0.05$ در نظر گرفته شد. فرض H_0 این آزمون نایستایی سری زمانی را بررسی می‌کند. بر اساس این آزمون، صرفاً سری زمانی ایستگاه امیدیه نایستا است که نتایج نمودارهای ACF و PACF را تایید می‌کند.



ترتیب می‌توان بیان نمود استفاده از پنجره‌های زمانی بلند مدت در مدل‌سازی و پیش‌بینی نمایه SPI سبب افزایش عملکرد و بهبود خروجی مدل‌ها می‌شود.

به‌طور کلی، مدل‌های سری زمانی و الگوریتم‌های یادگیری ماشین می‌توانند با دقت معقولی شاخص خشکسالی هواشناسی را تخمین بزنند که این مهم در سایر مطالعات از جمله حسینی موعاری و عراقی‌نژاد (۱۳۹۵)، Mishra و همکاران (۲۰۰۷)، Durdu (۲۰۱۰)، Alam و همکاران (۲۰۱۴) و HsinFu و HsinLi (۲۰۱۹) نیز گزارش شده است. بر اساس جداول ۶ و ۷ و با توجه به نتایج الگوریتم‌های یادگیری ماشین ANFIS و ELM، در همه ایستگاه‌ها مقادیر RMSE و MAE در مقیاس‌های مختلف نسبت به مدل‌های سری زمانی ARIMA و SARIMA کاهش یافته و مقادیر NS و R نیز با افزایش روبرو بوده است. به عبارت دیگر، به‌کارگیری الگوریتم‌های یادگیری ماشین موجب کاهش میزان خطا و افزایش دقت نتایج پیش‌بینی SPI نسبت به مدل‌های سری زمانی شده است. از این رو می‌توان نتیجه گرفت استفاده از الگوریتم‌های یادگیری ماشین با توجه به افزایش دقت و صحت نتایج، منطقی‌تر به نظر می‌رسد. نتایج پیش‌بینی نمایه SPI حاکی از عملکرد مناسب الگوریتم یادگیری ماشین ELM در هشت ایستگاه سینوپتیک مورد بررسی در استان خوزستان است. افزون بر این، مدل مذکور با کمترین مقدار RMSE و MAE و بیشترین مقدار NS و R بهترین مدل به منظور پیش‌بینی نمایه خشکسالی هواشناسی SPI در این استان است. در بین مدل‌های مورد بررسی الگوریتم ANFIS بعد از مدل ELM از عملکرد قابل قبولی برخوردار بوده، اما مدل ARIMA عملکرد ضعیف‌تری نسبت به سایر مدل‌ها در پیش‌بینی SPI از خود نشان داد. به‌طور کلی، با وجود اینکه مدل‌های یادگیری ماشین در مقایسه با مدل‌های سری زمانی دارای اختلاف معنی‌داری بوده اما مدل‌های سری زمانی نسبت به یکدیگر و همچنین مدل‌های یادگیری ماشین نسبت به هم اختلاف معنی‌داری نداشتند. در مطالعه Durdu (۲۰۱۰) نیز این مسئله نشان داده شده که مدل‌های سری زمانی ARIMA و SARIMA برای پیش‌بینی نمایه SPI در مقیاس‌های زمانی مختلف هر دو از دقت معقولی برخوردار بوده و نسبت به هم اختلاف

در این مطالعه، کارایی و عملکرد مدل‌های سری زمانی و الگوریتم‌های یادگیری ماشین در پیش‌بینی مقادیر نمایه SPI با استفاده از معیارهای ارزیابی RMSE، MAE، NS و R مورد مقایسه قرار گرفت. مقادیر حاصل از برآورد معیارهای ارزیابی به منظور تعیین بهترین مدل برای برآورد مقادیر SPI در استان خوزستان در جداول ۴ تا ۷ ارائه شده است.

مطابق جداول ۴ تا ۷ و با عنایت به نتایج معیارهای ارزیابی، در همه ایستگاه‌ها به‌طور نسبی نمایه SPI در مقیاس ۱۲ ماهه و ۶ ماهه نتایج بهتری در پیش‌بینی مدل‌ها نسبت به ترکیب‌های ۳ ماهه و ۱ ماهه از خود نمایش داده است. با توجه به جدول ۴، مقادیر میانگین مربعات خطا و قدر مطلق خطا در ایستگاه آبادان برای ترکیب ۱۲ ماهه، در مدل‌های سری زمانی ARIMA به ترتیب ۰/۴۷۶ و ۰/۳۹۱، مقادیر ضریب نش-سانکلیف و ضریب همبستگی به ترتیب ۰/۵۰۹ و ۰/۵۳۷ بوده است. نتایج جدول ۵ برای مدل SARIMA نشان می‌دهد در پنجره زمانی ۱۲ ماهه در ایستگاه آبادان مقادیر RMSE و MAE به ترتیب ۰/۴۵۱ و ۰/۳۷۳ و مقادیر NS و R به ترتیب برابر با ۰/۵۷۶ و ۰/۶۰۳ است. همان‌طور که مشخص است طبق مقایسه جداول شماره ۴ و ۵، می‌توان بیان نمود که مدل باکس جنکینز SARIMA در مقایسه با سری زمانی ARIMA نتایج بهتری به منظور مدل‌سازی و پیش‌بینی نمایه SPI در پنجره‌های زمانی مختلف از خود نشان داده است. جدول ۶ نتایج پیش‌بینی نمایه SPI را در هشت ایستگاه با استفاده از مدل ANFIS نشان می‌دهد. در این روش نیز استفاده از پنجره‌های زمانی بلند مدت در پیش‌بینی SPI، کارایی و بازدهی بیشتری داشته است. برای مثال در ایستگاه صفی‌آباد (دزفول) مقادیر NS و R از ۰/۶۹۷ و ۰/۷۰۱ در پنجره زمانی ۱ ماهه به ۰/۶۹۹ و ۰/۷۰۳ در پنجره زمانی ۱۲ ماهه افزایش یافته است. همچنین، در جدول ۷ بر اساس نتایج حاصل از معیارهای ارزیابی برای مدل ELM در ایستگاه‌های سینوپتیک ترکیب ۱۲ ماهه بهترین عملکرد را داشته است. از این رو می‌توان نتیجه گرفت که استفاده از پنجره‌های زمانی بلند مدت نتایج بهتر و دقیق‌تری نسبت به پنجره‌های کوتاه مدت دارد که این موضوع با مطالعه حسینی موعاری و عراقی‌نژاد (۱۳۹۵) همخوانی دارد. بدین

نمایه SPI در همه ایستگاه‌ها، با خطی به شیب ۴۵ درجه ارزیابی شد. همانطور که مشاهده می‌شود مدل ARIMA با کمترین دقت و بیشترین پراکندگی نسبت به سایر مدل‌ها، بیشترین اختلاف و فاصله را با نیم‌ساز ربع‌های اول و سوم دارد. الگوریتم یادگیری ماشین ELM نیز با کمترین پراکندگی و بیشترین تطابق نسبت به نیم‌ساز ربع‌های اول و سوم، بالاترین کارایی و بازده را در میان دیگر مدل‌ها دارد. بدین ترتیب می‌توان بیان داشت مدل ELM کارایی موثرتری نسبت به دیگر مدل‌ها در پیش‌بینی شاخص خشکسالی هواشناسی دارد. با توجه به یافته‌های بدست آمده می‌توان الگوریتم ELM را به عنوان ابزاری قدرتمند به منظور پیش‌بینی شاخص خشکسالی هواشناسی معرفی کرد که در برنامه‌ریزی و مدیریت بهینه منابع آب و مخاطرات زیست‌محیطی می‌تواند موثر واقع شود.

معنی‌داری نداشته‌اند. با توجه به اینکه ضریب نش-ساتکلیف و ضریب همبستگی عملکرد و دقت مدل را نشان می‌دهند، افزایش مقادیر این دو معیار به منزله بهبود عملکرد مدل در پیش‌بینی است. لذا در ایستگاه‌های آبادان و بستان در مقیاس‌های زمانی مختلف، مدل‌ها بیشترین دقت را در پیش‌بینی مقادیر واقعی داشتند و ایستگاه صفی‌آباد (دزفول) دارای خطای بیشتر نسبت به ایستگاه‌های آبادان و بستان می‌باشد. این روند در سایر ایستگاه‌های مورد مطالعه نیز به همین صورت می‌باشد. نتایج نشان داده که در ایستگاه‌هایی که در شمال استان خوزستان قرار دارند مانند ایستگاه مسجد سلیمان و صفی‌آباد (دزفول) مدل‌سازی و پیش‌بینی ضعیف‌تر بوده ولی در جنوب و غرب استان در ایستگاه‌های آبادان و بستان نتایج بهتر و دقیق‌تر بوده است. در واقع، با عنایت به نقشه پهنه‌بندی خشکسالی استان خوزستان (شکل ۵)، هر چه از شمال استان که وضعیت نرمال رو به ترسالی دارد به سمت مناطق جنوبی‌تر یا به عبارتی خشک‌تر برویم نتایج مدل‌سازی و پیش‌بینی‌ها بهتر و دقیق‌تر شده است.

شکل ۸، مقادیر مشاهداتی و پیش‌بینی شده نمایه SPI ۱۲ ماهه را توسط مدل‌های سری زمانی و یادگیری ماشین برای مجموعه داده‌های آزمون ایستگاه‌های سینوپتیک استان خوزستان به‌طور نمونه نشان می‌دهد. در این شکل رابطه میان مقادیر مشاهداتی و پیش‌بینی شده



جدول (۴): نتایج آماری داده‌های ورودی به مدل ARIMA به منظور پیش‌بینی نمایه SPI

| نام ایستگاه | شماره ترکیب | مجموعه داده آموزش | | | | مجموعه داده آزمون | | | |
|---------------------|-------------------|-------------------|-------|-------|-------|-------------------|-------|-------|-------|
| | | RMSE | MAE | NS | R | RMSE | MAE | NS | R |
| آبادان | SPI ₁₂ | ۰/۴۴۶ | ۰/۳۷۳ | ۰/۵۲۱ | ۰/۵۴۵ | ۰/۴۷۶ | ۰/۳۹۱ | ۰/۵۰۹ | ۰/۵۳۷ |
| | SPI ₆ | ۰/۴۴۷ | ۰/۳۷۲ | ۰/۵۱۹ | ۰/۵۴۴ | ۰/۴۷۷ | ۰/۳۸۹ | ۰/۵۰۸ | ۰/۵۳۹ |
| | SPI ₃ | ۰/۴۳۹ | ۰/۳۷۴ | ۰/۵۱۸ | ۰/۵۴۳ | ۰/۴۷۸ | ۰/۳۹۱ | ۰/۵۰۷ | ۰/۵۴۱ |
| | SPI ₁ | ۰/۴۵۱ | ۰/۳۷۵ | ۰/۵۱۸ | ۰/۵۴۲ | ۰/۴۷۹ | ۰/۳۹۱ | ۰/۵۰۷ | ۰/۵۳۶ |
| بستان | SPI ₁₂ | ۰/۴۵۳ | ۰/۳۷۵ | ۰/۵۱۸ | ۰/۵۴۱ | ۰/۴۷۹ | ۰/۳۹۴ | ۰/۵۰۶ | ۰/۵۳۵ |
| | SPI ₆ | ۰/۴۵۵ | ۰/۳۷۵ | ۰/۵۱۷ | ۰/۵۴۳ | ۰/۴۷۶ | ۰/۳۹۲ | ۰/۵۰۵ | ۰/۵۳۴ |
| | SPI ₃ | ۰/۴۵۶ | ۰/۳۷۱ | ۰/۵۱۶ | ۰/۵۳۹ | ۰/۴۷۴ | ۰/۳۹۲ | ۰/۵۰۴ | ۰/۵۳۳ |
| | SPI ₁ | ۰/۴۶۱ | ۰/۳۶۹ | ۰/۵۱۵ | ۰/۵۴۰ | ۰/۴۷۵ | ۰/۳۹۳ | ۰/۵۰۳ | ۰/۵۳۳ |
| اهواز | SPI ₁₂ | ۰/۴۶۲ | ۰/۳۶۷ | ۰/۵۱۴ | ۰/۵۴۳ | ۰/۴۷۹ | ۰/۳۹۵ | ۰/۵۰۳ | ۰/۵۳۱ |
| | SPI ₆ | ۰/۴۶۲ | ۰/۳۷۶ | ۰/۵۱۳ | ۰/۵۴۲ | ۰/۴۸۱ | ۰/۳۹۶ | ۰/۵۰۲ | ۰/۵۲۸ |
| | SPI ₃ | ۰/۴۶۲ | ۰/۳۷۷ | ۰/۵۱۲ | ۰/۵۴۱ | ۰/۴۸۲ | ۰/۳۹۷ | ۰/۵۰۱ | ۰/۵۲۷ |
| | SPI ₁ | ۰/۴۶۳ | ۰/۳۷۷ | ۰/۵۱۴ | ۰/۵۳۹ | ۰/۴۸۳ | ۰/۳۹۸ | ۰/۴۹۹ | ۰/۵۲۶ |
| بندر ماهشهر | SPI ₁₂ | ۰/۴۶۴ | ۰/۳۷۸ | ۰/۵۱۷ | ۰/۵۳۹ | ۰/۴۷۷ | ۰/۳۹۸ | ۰/۴۹۸ | ۰/۵۲۵ |
| | SPI ₆ | ۰/۴۶۵ | ۰/۳۷۹ | ۰/۵۱۱ | ۰/۵۳۸ | ۰/۴۷۹ | ۰/۳۹۹ | ۰/۴۹۷ | ۰/۵۲۴ |
| | SPI ₃ | ۰/۴۶۶ | ۰/۳۷۹ | ۰/۵۰۹ | ۰/۵۳۷ | ۰/۴۸۱ | ۰/۴۰۱ | ۰/۴۹۶ | ۰/۵۲۳ |
| | SPI ₁ | ۰/۴۶۷ | ۰/۳۷۹ | ۰/۵۰۸ | ۰/۵۳۶ | ۰/۴۸۴ | ۰/۴۰۲ | ۰/۴۹۵ | ۰/۵۲۳ |
| امیدیه | SPI ₁₂ | ۰/۴۶۷ | ۰/۳۸۱ | ۰/۵۰۷ | ۰/۵۳۵ | ۰/۴۸۴ | ۰/۴۰۳ | ۰/۴۹۵ | ۰/۵۲۳ |
| | SPI ₆ | ۰/۴۶۸ | ۰/۳۷۸ | ۰/۵۰۶ | ۰/۵۳۴ | ۰/۴۸۴ | ۰/۴۰۴ | ۰/۴۹۴ | ۰/۵۲۱ |
| | SPI ₃ | ۰/۴۶۹ | ۰/۳۸۲ | ۰/۵۰۵ | ۰/۵۳۳ | ۰/۴۸۵ | ۰/۴۰۵ | ۰/۴۹۳ | ۰/۵۲۱ |
| | SPI ₁ | ۰/۴۷۱ | ۰/۳۸۳ | ۰/۵۰۴ | ۰/۵۳۲ | ۰/۴۸۷ | ۰/۴۰۶ | ۰/۴۹۲ | ۰/۵۱۹ |
| رامهرمز | SPI ₁₂ | ۰/۴۷۲ | ۰/۳۸۴ | ۰/۵۰۳ | ۰/۵۳۱ | ۰/۴۸۸ | ۰/۴۰۷ | ۰/۴۹۲ | ۰/۵۱۹ |
| | SPI ₆ | ۰/۴۷۳ | ۰/۳۸۵ | ۰/۵۰۲ | ۰/۵۲۹ | ۰/۴۸۹ | ۰/۴۰۸ | ۰/۴۹۲ | ۰/۵۱۸ |
| | SPI ₃ | ۰/۴۷۴ | ۰/۳۸۶ | ۰/۵۰۱ | ۰/۵۲۸ | ۰/۴۹۱ | ۰/۴۰۹ | ۰/۴۹۱ | ۰/۵۱۷ |
| | SPI ₁ | ۰/۴۷۵ | ۰/۳۸۷ | ۰/۵۰۳ | ۰/۵۲۷ | ۰/۴۹۲ | ۰/۴۰۹ | ۰/۴۹۱ | ۰/۵۱۶ |
| مسجدسلیمان | SPI ₁₂ | ۰/۴۷۶ | ۰/۳۸۷ | ۰/۵۰۴ | ۰/۵۲۶ | ۰/۴۹۳ | ۰/۴۱۱ | ۰/۴۸۹ | ۰/۵۱۴ |
| | SPI ₆ | ۰/۴۷۷ | ۰/۳۸۸ | ۰/۵۰۵ | ۰/۵۲۶ | ۰/۴۹۴ | ۰/۴۱۲ | ۰/۴۸۸ | ۰/۵۱۳ |
| | SPI ₃ | ۰/۴۸۱ | ۰/۳۸۹ | ۰/۵۰۶ | ۰/۵۲۴ | ۰/۴۹۷ | ۰/۴۱۳ | ۰/۴۸۷ | ۰/۵۱۳ |
| | SPI ₁ | ۰/۴۸۲ | ۰/۳۹۱ | ۰/۵۰۷ | ۰/۵۲۳ | ۰/۵۰۱ | ۰/۴۱۴ | ۰/۴۸۶ | ۰/۵۱۱ |
| صفی آباد (دزفول) | SPI ₁₂ | ۰/۴۸۳ | ۰/۳۹۲ | ۰/۵۰۵ | ۰/۵۲۲ | ۰/۴۸۷ | ۰/۴۱۵ | ۰/۴۸۵ | ۰/۵۰۹ |
| | SPI ₆ | ۰/۴۸۵ | ۰/۳۹۳ | ۰/۵۰۴ | ۰/۵۲۱ | ۰/۵۰۲ | ۰/۴۱۶ | ۰/۴۸۴ | ۰/۵۰۸ |
| | SPI ₃ | ۰/۴۸۷ | ۰/۳۹۴ | ۰/۵۰۳ | ۰/۵۱۹ | ۰/۵۰۴ | ۰/۴۱۷ | ۰/۴۸۳ | ۰/۵۰۸ |
| | SPI ₁ | ۰/۴۸۸ | ۰/۳۹۵ | ۰/۵۰۲ | ۰/۵۱۸ | ۰/۴۹۶ | ۰/۴۱۸ | ۰/۴۸۲ | ۰/۵۰۷ |

جدول (۵): نتایج آماری داده‌های ورودی به مدل SARIMA به منظور پیش‌بینی نمایه SPI

| نام ایستگاه | شماره ترکیب | مجموعه داده آموزش | | | | مجموعه داده آزمون | | | |
|---------------------|-------------------|-------------------|-------|-------|-------|-------------------|-------|-------|-------|
| | | R | NS | MAE | RMSE | R | NS | MAE | RMSE |
| آبادان | SPI ₁₂ | ۰/۶۲۱ | ۰/۵۹۱ | ۰/۳۵۳ | ۰/۴۳۵ | ۰/۶۰۳ | ۰/۵۷۶ | ۰/۳۷۳ | ۰/۴۵۱ |
| | SPI ₆ | ۰/۶۲۱ | ۰/۵۹۰ | ۰/۳۴۹ | ۰/۴۳۶ | ۰/۶۰۴ | ۰/۵۷۷ | ۰/۳۷۴ | ۰/۴۵۱ |
| | SPI ₃ | ۰/۶۱۹ | ۰/۵۸۹ | ۰/۳۵۵ | ۰/۴۳۶ | ۰/۶۰۴ | ۰/۵۷۸ | ۰/۳۷۲ | ۰/۴۴۹ |
| | SPI ₁ | ۰/۶۲۳ | ۰/۵۹۳ | ۰/۳۵۴ | ۰/۴۳۷ | ۰/۶۰۲ | ۰/۵۷۹ | ۰/۳۷۲ | ۰/۴۴۷ |
| بستان | SPI ₁₂ | ۰/۶۲۴ | ۰/۵۹۴ | ۰/۳۴۸ | ۰/۴۳۷ | ۰/۶۰۱ | ۰/۵۷۶ | ۰/۳۷۲ | ۰/۴۵۳ |
| | SPI ₆ | ۰/۶۲۵ | ۰/۵۸۹ | ۰/۳۴۸ | ۰/۴۳۷ | ۰/۶۰۱ | ۰/۵۷۶ | ۰/۳۷۵ | ۰/۴۵۴ |
| | SPI ₃ | ۰/۶۱۸ | ۰/۵۸۸ | ۰/۳۵۷ | ۰/۴۲۹ | ۰/۵۹۹ | ۰/۵۷۵ | ۰/۳۶۹ | ۰/۴۵۵ |
| | SPI ₁ | ۰/۶۱۸ | ۰/۵۸۷ | ۰/۳۵۷ | ۰/۴۲۸ | ۰/۵۹۸ | ۰/۵۷۵ | ۰/۳۶۹ | ۰/۴۵۶ |
| اهواز | SPI ₁₂ | ۰/۶۱۸ | ۰/۵۸۶ | ۰/۳۵۷ | ۰/۴۴۱ | ۰/۵۹۷ | ۰/۵۷۴ | ۰/۳۷۶ | ۰/۴۵۷ |
| | SPI ₆ | ۰/۶۱۷ | ۰/۵۸۵ | ۰/۳۵۸ | ۰/۴۳۹ | ۰/۶۰۳ | ۰/۵۷۳ | ۰/۳۷۵ | ۰/۴۵۸ |
| | SPI ₃ | ۰/۶۱۶ | ۰/۵۸۵ | ۰/۳۵۹ | ۰/۴۳۹ | ۰/۵۹۷ | ۰/۵۷۲ | ۰/۳۷۷ | ۰/۴۵۹ |
| | SPI ₁ | ۰/۶۱۵ | ۰/۵۸۵ | ۰/۳۶۱ | ۰/۴۴۲ | ۰/۵۹۶ | ۰/۵۷۱ | ۰/۳۷۷ | ۰/۴۶۱ |
| بندر ماهشهر | SPI ₁₂ | ۰/۶۱۴ | ۰/۵۸۴ | ۰/۳۶۲ | ۰/۴۴۳ | ۰/۵۹۵ | ۰/۵۶۹ | ۰/۳۷۸ | ۰/۴۶۲ |
| | SPI ₆ | ۰/۶۱۳ | ۰/۵۸۳ | ۰/۳۶۳ | ۰/۴۴۴ | ۰/۵۹۴ | ۰/۵۶۸ | ۰/۳۷۹ | ۰/۴۶۲ |
| | SPI ₃ | ۰/۶۱۷ | ۰/۵۸۲ | ۰/۳۶۴ | ۰/۴۴۵ | ۰/۵۹۳ | ۰/۵۶۷ | ۰/۳۸۱ | ۰/۴۶۳ |
| | SPI ₁ | ۰/۶۱۲ | ۰/۵۸۱ | ۰/۳۶۵ | ۰/۴۴۶ | ۰/۵۹۲ | ۰/۵۶۶ | ۰/۳۸۲ | ۰/۴۶۳ |
| امیدیه | SPI ₁₂ | ۰/۶۱۹ | ۰/۵۷۹ | ۰/۳۶۶ | ۰/۴۴۷ | ۰/۵۹۱ | ۰/۵۶۵ | ۰/۳۸۲ | ۰/۴۶۴ |
| | SPI ₆ | ۰/۶۱۱ | ۰/۵۷۸ | ۰/۳۶۷ | ۰/۴۴۷ | ۰/۵۸۹ | ۰/۵۶۴ | ۰/۳۸۳ | ۰/۴۶۵ |
| | SPI ₃ | ۰/۶۰۹ | ۰/۵۸۳ | ۰/۳۶۸ | ۰/۴۴۷ | ۰/۵۸۸ | ۰/۵۶۳ | ۰/۳۸۵ | ۰/۴۶۵ |
| | SPI ₁ | ۰/۶۱۳ | ۰/۵۷۶ | ۰/۳۶۹ | ۰/۴۴۸ | ۰/۵۸۷ | ۰/۵۶۲ | ۰/۳۸۶ | ۰/۴۶۵ |
| رامهرمز | SPI ₁₂ | ۰/۶۰۸ | ۰/۵۷۶ | ۰/۳۷۱ | ۰/۴۴۹ | ۰/۵۸۷ | ۰/۵۶۱ | ۰/۳۸۷ | ۰/۴۶۳ |
| | SPI ₆ | ۰/۶۰۸ | ۰/۵۷۵ | ۰/۳۷۲ | ۰/۴۵۱ | ۰/۵۸۶ | ۰/۵۶۰ | ۰/۳۸۸ | ۰/۴۵۹ |
| | SPI ₃ | ۰/۶۰۸ | ۰/۵۷۴ | ۰/۳۷۳ | ۰/۴۵۲ | ۰/۵۸۵ | ۰/۵۵۹ | ۰/۳۸۹ | ۰/۴۶۴ |
| | SPI ₁ | ۰/۶۰۷ | ۰/۵۷۳ | ۰/۳۷۵ | ۰/۴۵۳ | ۰/۵۸۴ | ۰/۵۵۸ | ۰/۳۹۱ | ۰/۴۶۵ |
| مسجدسلیمان | SPI ₁₂ | ۰/۶۰۶ | ۰/۵۷۲ | ۰/۳۷۶ | ۰/۴۵۴ | ۰/۵۸۳ | ۰/۵۵۷ | ۰/۳۹۲ | ۰/۴۶۶ |
| | SPI ₆ | ۰/۶۰۵ | ۰/۵۷۱ | ۰/۳۷۷ | ۰/۴۵۵ | ۰/۵۸۵ | ۰/۵۵۸ | ۰/۳۹۳ | ۰/۴۶۷ |
| | SPI ₃ | ۰/۶۰۴ | ۰/۵۶۹ | ۰/۳۷۹ | ۰/۴۵۶ | ۰/۵۹۱ | ۰/۵۵۵ | ۰/۳۹۴ | ۰/۴۶۸ |
| | SPI ₁ | ۰/۶۰۳ | ۰/۵۶۸ | ۰/۳۸۱ | ۰/۴۵۷ | ۰/۵۹۲ | ۰/۵۶۱ | ۰/۳۹۵ | ۰/۴۶۹ |
| صفی آباد (دزفول) | SPI ₁₂ | ۰/۶۰۲ | ۰/۵۶۷ | ۰/۳۸۲ | ۰/۴۵۷ | ۰/۵۹۳ | ۰/۵۶۲ | ۰/۳۹۶ | ۰/۴۷۱ |
| | SPI ₆ | ۰/۶۰۱ | ۰/۵۶۶ | ۰/۳۸۳ | ۰/۴۵۸ | ۰/۵۸۸ | ۰/۵۵۴ | ۰/۳۹۷ | ۰/۴۷۲ |
| | SPI ₃ | ۰/۶۰۱ | ۰/۵۶۵ | ۰/۳۸۴ | ۰/۴۵۹ | ۰/۵۸۵ | ۰/۵۵۳ | ۰/۳۹۸ | ۰/۴۷۳ |
| | SPI ₁ | ۰/۵۹۹ | ۰/۵۶۴ | ۰/۳۸۵ | ۰/۴۶۱ | ۰/۵۸۴ | ۰/۵۵۲ | ۰/۳۹۹ | ۰/۴۷۴ |



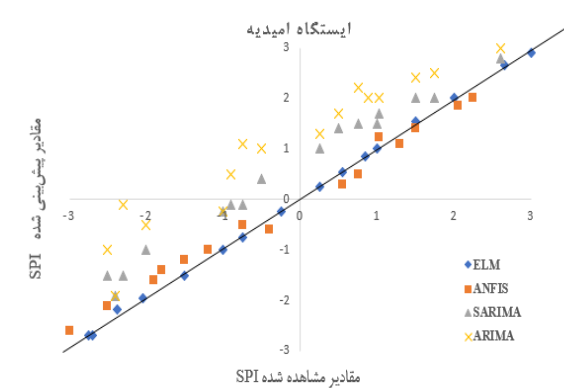




جدول (۶): نتایج آماری داده‌های ورودی به مدل ANFIS به منظور پیش‌بینی نمایه SPI

| نام ایستگاه | شماره ترکیب | مجموعه داده آموزش | | | | مجموعه داده آزمون | | | |
|---------------------|-------------------|-------------------|-------|-------|-------|-------------------|-------|-------|-------|
| | | R | NS | MAE | RMSE | R | NS | MAE | RMSE |
| آبادان | SPI ₁₂ | ۰/۷۴۱ | ۰/۷۳۵ | ۰/۳۲۵ | ۰/۴۰۵ | ۰/۷۲۳ | ۰/۷۱۷ | ۰/۳۴۸ | ۰/۴۱۷ |
| | SPI ₆ | ۰/۷۴۳ | ۰/۷۳۳ | ۰/۳۲۴ | ۰/۴۰۶ | ۰/۷۲۲ | ۰/۷۱۶ | ۰/۳۴۷ | ۰/۴۱۸ |
| | SPI ₃ | ۰/۷۴۲ | ۰/۷۳۲ | ۰/۳۲۳ | ۰/۴۰۶ | ۰/۷۲۱ | ۰/۷۱۶ | ۰/۳۴۶ | ۰/۴۲۲ |
| | SPI ₁ | ۰/۷۴۲ | ۰/۷۳۲ | ۰/۳۲۲ | ۰/۴۰۷ | ۰/۷۲۱ | ۰/۷۱۶ | ۰/۳۴۵ | ۰/۴۱۸ |
| بستان | SPI ₁₂ | ۰/۷۴۱ | ۰/۷۳۱ | ۰/۳۲۱ | ۰/۴۰۹ | ۰/۷۲۱ | ۰/۷۱۹ | ۰/۳۴۴ | ۰/۴۱۹ |
| | SPI ₆ | ۰/۷۳۹ | ۰/۷۳۷ | ۰/۳۲۱ | ۰/۴۰۳ | ۰/۷۲۵ | ۰/۷۲۱ | ۰/۳۴۳ | ۰/۴۲۱ |
| | SPI ₃ | ۰/۷۳۸ | ۰/۷۲۹ | ۰/۳۱۹ | ۰/۴۰۷ | ۰/۷۲۴ | ۰/۷۲۱ | ۰/۳۴۲ | ۰/۴۲۲ |
| | SPI ₁ | ۰/۷۳۷ | ۰/۷۳۴ | ۰/۳۱۸ | ۰/۴۰۷ | ۰/۷۲۳ | ۰/۷۲۲ | ۰/۳۴۱ | ۰/۴۲۳ |
| اهواز | SPI ₁₂ | ۰/۷۳۶ | ۰/۷۳۱ | ۰/۳۱۸ | ۰/۴۰۷ | ۰/۷۲۲ | ۰/۷۱۵ | ۰/۳۳۹ | ۰/۴۲۴ |
| | SPI ₆ | ۰/۷۳۵ | ۰/۷۳۱ | ۰/۳۱۷ | ۰/۴۰۸ | ۰/۷۲۱ | ۰/۷۱۵ | ۰/۳۳۸ | ۰/۴۲۵ |
| | SPI ₃ | ۰/۷۳۴ | ۰/۷۳۱ | ۰/۳۱۶ | ۰/۴۰۹ | ۰/۷۱۹ | ۰/۷۱۴ | ۰/۳۳۷ | ۰/۴۲۶ |
| | SPI ₁ | ۰/۷۳۳ | ۰/۷۲۹ | ۰/۳۱۵ | ۰/۴۱۱ | ۰/۷۱۸ | ۰/۷۱۳ | ۰/۳۳۶ | ۰/۴۲۷ |
| بندر ماهشهر | SPI ₁₂ | ۰/۷۳۳ | ۰/۷۲۸ | ۰/۳۱۴ | ۰/۴۱۲ | ۰/۷۱۷ | ۰/۷۱۲ | ۰/۳۳۶ | ۰/۴۲۸ |
| | SPI ₆ | ۰/۷۳۲ | ۰/۷۲۷ | ۰/۳۱۳ | ۰/۴۰۳ | ۰/۷۱۶ | ۰/۷۱۲ | ۰/۳۳۵ | ۰/۴۲۹ |
| | SPI ₃ | ۰/۷۳۱ | ۰/۷۲۶ | ۰/۳۱۲ | ۰/۴۱۳ | ۰/۷۱۵ | ۰/۷۱۱ | ۰/۳۳۴ | ۰/۴۳۱ |
| | SPI ₁ | ۰/۷۳۵ | ۰/۷۲۵ | ۰/۳۱۲ | ۰/۴۱۴ | ۰/۷۱۴ | ۰/۷۱۰ | ۰/۳۳۲ | ۰/۴۳۳ |
| امیدیه | SPI ₁₂ | ۰/۷۳۷ | ۰/۷۲۴ | ۰/۳۱۱ | ۰/۴۱۵ | ۰/۷۱۳ | ۰/۷۰۹ | ۰/۳۳۱ | ۰/۴۳۴ |
| | SPI ₆ | ۰/۷۳۸ | ۰/۷۲۳ | ۰/۳۰۹ | ۰/۴۱۶ | ۰/۷۱۲ | ۰/۷۰۸ | ۰/۳۲۹ | ۰/۴۳۵ |
| | SPI ₃ | ۰/۷۳۵ | ۰/۷۲۲ | ۰/۳۰۸ | ۰/۴۱۷ | ۰/۷۱۲ | ۰/۷۰۷ | ۰/۳۲۸ | ۰/۴۳۶ |
| | SPI ₁ | ۰/۷۳۵ | ۰/۷۲۱ | ۰/۳۰۷ | ۰/۴۱۸ | ۰/۷۱۲ | ۰/۷۰۶ | ۰/۳۲۷ | ۰/۴۳۷ |
| رامهرمز | SPI ₁₂ | ۰/۷۳۴ | ۰/۷۲۰ | ۰/۳۰۶ | ۰/۴۱۸ | ۰/۷۱۱ | ۰/۷۰۵ | ۰/۳۲۶ | ۰/۴۳۹ |
| | SPI ₆ | ۰/۷۳۳ | ۰/۷۱۹ | ۰/۳۰۵ | ۰/۴۲۱ | ۰/۷۰۹ | ۰/۷۰۴ | ۰/۳۲۵ | ۰/۴۴۱ |
| | SPI ₃ | ۰/۷۳۲ | ۰/۷۱۸ | ۰/۳۰۴ | ۰/۴۲۲ | ۰/۷۰۸ | ۰/۷۰۳ | ۰/۳۲۴ | ۰/۴۴۲ |
| | SPI ₁ | ۰/۷۳۱ | ۰/۷۱۷ | ۰/۳۰۲ | ۰/۴۲۳ | ۰/۷۰۸ | ۰/۷۰۲ | ۰/۳۲۳ | ۰/۴۴۳ |
| مسجد سلیمان | SPI ₁₂ | ۰/۷۳۰ | ۰/۷۱۶ | ۰/۳۰۱ | ۰/۴۲۴ | ۰/۷۰۶ | ۰/۷۰۲ | ۰/۳۲۲ | ۰/۴۴۴ |
| | SPI ₆ | ۰/۷۲۹ | ۰/۷۱۵ | ۰/۳۰۶ | ۰/۴۲۵ | ۰/۷۰۶ | ۰/۷۰۲ | ۰/۳۲۱ | ۰/۴۴۵ |
| | SPI ₃ | ۰/۷۲۸ | ۰/۷۱۴ | ۰/۳۰۴ | ۰/۴۲۶ | ۰/۷۰۵ | ۰/۷۰۱ | ۰/۳۱۹ | ۰/۴۴۶ |
| | SPI ₁ | ۰/۷۲۷ | ۰/۷۱۳ | ۰/۳۰۴ | ۰/۴۲۵ | ۰/۷۰۴ | ۰/۷۰۱ | ۰/۳۱۸ | ۰/۴۴۷ |
| صفی آباد (دزفول) | SPI ₁₂ | ۰/۷۲۶ | ۰/۷۱۲ | ۰/۳۰۴ | ۰/۴۲۶ | ۰/۷۰۴ | ۰/۶۹۹ | ۰/۳۱۷ | ۰/۴۴۸ |
| | SPI ₆ | ۰/۷۲۵ | ۰/۷۱۱ | ۰/۳۰۲ | ۰/۴۲۷ | ۰/۷۰۳ | ۰/۶۹۸ | ۰/۳۱۷ | ۰/۴۴۸ |
| | SPI ₃ | ۰/۷۲۴ | ۰/۷۱۰ | ۰/۳۰۱ | ۰/۴۲۸ | ۰/۷۰۲ | ۰/۶۹۷ | ۰/۳۱۹ | ۰/۴۵۱ |
| | SPI ₁ | ۰/۷۲۳ | ۰/۷۰۹ | ۰/۳۰۱ | ۰/۴۲۹ | ۰/۷۰۱ | ۰/۶۹۷ | ۰/۳۱۶ | ۰/۴۴۹ |

جدول (۷): نتایج آماری داده‌های ورودی به مدل ELM به منظور پیش‌بینی نمایه SPI

| نام ایستگاه | شماره ترکیب | مجموعه داده آموزش | | | | مجموعه داده آزمون | | | |
|----------------------|-------------------|-------------------|-------|-------|-------|-------------------|-------|-------|-------|
| | | R | NS | MAE | RMSE | R | NS | MAE | RMSE |
| آبادان | SPI ₁₂ | ۰/۸۷۱ | ۰/۸۱۱ | ۰/۲۸۱ | ۰/۳۵۶ | ۰/۸۵۳ | ۰/۸۳۳ | ۰/۳۰۵ | ۰/۳۷۵ |
| | SPI ₆ | ۰/۸۷۲ | ۰/۸۱۱ | ۰/۲۸۲ | ۰/۳۵۷ | ۰/۸۵۲ | ۰/۸۳۲ | ۰/۳۰۵ | ۰/۳۷۶ |
| | SPI ₃ | ۰/۸۷۱ | ۰/۸۱۲ | ۰/۲۸۳ | ۰/۳۵۷ | ۰/۸۵۱ | ۰/۸۳۱ | ۰/۳۰۶ | ۰/۳۷۷ |
| | SPI ₁ | ۰/۸۷۱ | ۰/۸۰۹ | ۰/۲۸۴ | ۰/۳۵۸ | ۰/۸۵۰ | ۰/۸۳۱ | ۰/۳۰۷ | ۰/۳۷۹ |
| بستان | SPI ₁₂ | ۰/۸۶۹ | ۰/۸۰۸ | ۰/۲۸۵ | ۰/۳۵۹ | ۰/۸۴۹ | ۰/۸۲۹ | ۰/۳۰۷ | ۰/۳۸۱ |
| | SPI ₆ | ۰/۸۶۸ | ۰/۸۰۷ | ۰/۲۷۹ | ۰/۳۶۱ | ۰/۸۴۸ | ۰/۸۳۹ | ۰/۳۰۸ | ۰/۳۸۲ |
| | SPI ₃ | ۰/۸۶۷ | ۰/۸۰۶ | ۰/۲۸۶ | ۰/۳۶۲ | ۰/۸۴۷ | ۰/۸۴۱ | ۰/۳۰۹ | ۰/۳۸۳ |
| | SPI ₁ | ۰/۸۶۷ | ۰/۸۰۶ | ۰/۲۸۷ | ۰/۳۶۳ | ۰/۸۴۶ | ۰/۸۳۱ | ۰/۳۰۹ | ۰/۳۸۴ |
| اهواز | SPI ₁₂ | ۰/۸۶۵ | ۰/۸۰۶ | ۰/۲۸۷ | ۰/۳۶۴ | ۰/۸۴۵ | ۰/۸۲۹ | ۰/۳۰۹ | ۰/۳۸۵ |
| | SPI ₆ | ۰/۸۶۵ | ۰/۸۰۵ | ۰/۲۸۷ | ۰/۳۶۵ | ۰/۸۴۹ | ۰/۸۲۹ | ۰/۳۱۱ | ۰/۳۸۶ |
| | SPI ₃ | ۰/۸۶۵ | ۰/۸۰۴ | ۰/۲۸۸ | ۰/۳۶۵ | ۰/۸۴۸ | ۰/۸۲۹ | ۰/۳۰۵ | ۰/۳۸۷ |
| | SPI ₁ | ۰/۸۶۴ | ۰/۸۰۳ | ۰/۲۸۹ | ۰/۳۶۶ | ۰/۸۴۷ | ۰/۸۲۸ | ۰/۳۱۲ | ۰/۳۸۴ |
| بندر ماهشهر | SPI ₁₂ | ۰/۸۶۳ | ۰/۸۰۲ | ۰/۲۹۱ | ۰/۳۶۷ | ۰/۸۵۵ | ۰/۸۲۷ | ۰/۳۱۳ | ۰/۳۸۵ |
| | SPI ₆ | ۰/۸۶۲ | ۰/۸۰۱ | ۰/۲۸۵ | ۰/۳۶۸ | ۰/۸۴۶ | ۰/۸۲۶ | ۰/۳۱۳ | ۰/۳۷۹ |
| | SPI ₃ | ۰/۸۶۱ | ۰/۸۰۰ | ۰/۲۸۴ | ۰/۳۶۸ | ۰/۸۴۵ | ۰/۸۲۵ | ۰/۳۱۴ | ۰/۳۸۶ |
| | SPI ₁ | ۰/۸۵۹ | ۰/۷۹۷ | ۰/۲۹۲ | ۰/۳۷۱ | ۰/۸۴۴ | ۰/۸۲۴ | ۰/۳۰۳ | ۰/۳۸۷ |
| امیدیه | SPI ₁₂ | ۰/۸۵۸ | ۰/۷۹۶ | ۰/۲۹۳ | ۰/۳۷۲ | ۰/۸۴۳ | ۰/۸۲۴ | ۰/۳۱۵ | ۰/۳۸۷ |
| | SPI ₆ | ۰/۸۵۷ | ۰/۷۹۵ | ۰/۲۹۴ | ۰/۳۷۳ | ۰/۸۴۲ | ۰/۸۳۱ | ۰/۳۱۷ | ۰/۳۸۹ |
| | SPI ₃ | ۰/۸۵۶ | ۰/۷۹۴ | ۰/۲۹۵ | ۰/۳۷۴ | ۰/۸۴۲ | ۰/۸۲۲ | ۰/۳۱۶ | ۰/۳۹۱ |
| | SPI ₁ | ۰/۸۵۵ | ۰/۷۹۳ | ۰/۲۹۶ | ۰/۳۷۵ | ۰/۸۴۲ | ۰/۸۲۱ | ۰/۳۱۹ | ۰/۳۹۲ |
| رامهرمز | SPI ₁₂ | ۰/۸۵۴ | ۰/۷۹۲ | ۰/۳۰۱ | ۰/۳۷۵ | ۰/۸۴۱ | ۰/۸۲۱ | ۰/۳۱۹ | ۰/۳۹۳ |
| | SPI ₆ | ۰/۸۵۹ | ۰/۷۹۱ | ۰/۲۹۷ | ۰/۳۷۵ | ۰/۸۴۰ | ۰/۸۱۹ | ۰/۳۲۱ | ۰/۳۹۴ |
| | SPI ₃ | ۰/۸۵۳ | ۰/۷۸۹ | ۰/۲۹۸ | ۰/۳۷۶ | ۰/۸۳۹ | ۰/۸۰۸ | ۰/۳۲۰ | ۰/۳۹۵ |
| | SPI ₁ | ۰/۸۵۳ | ۰/۷۸۸ | ۰/۲۹۹ | ۰/۳۷۷ | ۰/۸۳۳ | ۰/۸۰۵ | ۰/۳۲۳ | ۰/۳۹۶ |
| مسجد سلیمان | SPI ₁₂ | ۰/۸۵۳ | ۰/۷۸۶ | ۰/۳۰۱ | ۰/۳۷۸ | ۰/۸۳۸ | ۰/۸۰۴ | ۰/۳۲۴ | ۰/۳۹۶ |
| | SPI ₆ | ۰/۸۵۲ | ۰/۷۸۵ | ۰/۳۰۲ | ۰/۳۷۹ | ۰/۸۳۷ | ۰/۸۰۳ | ۰/۳۲۵ | ۰/۳۹۷ |
| | SPI ₃ | ۰/۸۵۱ | ۰/۷۸۴ | ۰/۳۰۳ | ۰/۳۸۱ | ۰/۸۳۶ | ۰/۸۰۲ | ۰/۳۲۶ | ۰/۳۹۷ |
| | SPI ₁ | ۰/۸۵۰ | ۰/۷۸۳ | ۰/۳۰۴ | ۰/۳۸۲ | ۰/۸۳۵ | ۰/۸۰۱ | ۰/۳۲۷ | ۰/۳۹۸ |
| صفی آباد (دز فول) | SPI ₁₂ | ۰/۸۴۹ | ۰/۷۸۲ | ۰/۳۰۵ | ۰/۳۸۳ | ۰/۸۳۴ | ۰/۸۰۱ | ۰/۳۲۸ | ۰/۳۹۹ |
| | SPI ₆ | ۰/۸۴۷ | ۰/۷۸۱ | ۰/۳۰۶ | ۰/۳۸۴ | ۰/۸۳۳ | ۰/۷۹۹ | ۰/۳۲۹ | ۰/۴۰۱ |
| | SPI ₃ | ۰/۸۴۷ | ۰/۷۸۰ | ۰/۳۰۷ | ۰/۳۸۵ | ۰/۸۳۲ | ۰/۷۹۸ | ۰/۳۳۱ | ۰/۴۰۳ |
| | SPI ₁ | ۰/۸۴۶ | ۰/۷۷۹ | ۰/۳۰۸ | ۰/۳۸۷ | ۰/۸۳۱ | ۰/۷۹۶ | ۰/۳۴۱ | ۰/۴۰۳ |



شکل (۸): مقایسه مقادیر مشاهداتی و پیش‌بینی شده نمایه SPI با استفاده از مدل‌های سری زمانی و یادگیری ماشین

نتیجه گیری

ماشین در پیش‌بینی داده‌های بلند مدت می‌باشد که این امر موجب شده تا مدل‌های یادگیری ماشین به عنوان ابزاری قدرتمند در شبیه‌سازی و پیش‌بینی‌ها شناخته شوند. مطالعه خشکسالی و پیش‌بینی تغییرات آن، این امکان را فراهم می‌سازد که بتوان براساس پیش‌بینی‌های انجام شده، درک روشنی از منطقه به منظور کنترل روند رو به رشد خشکسالی داشت. به همین جهت می‌توان چنین استنباط نمود که اطلاعات حاصل از الگوریتم‌های یادگیری ماشین، شناخت نسبتاً دقیقی از ماهیت خشکسالی را قبل از وقوع آن در اختیار مدیران و مسئولین قرار می‌دهد تا با مدیریت بهینه سیستم‌های پیش‌آگاهی و هشدار دهنده در زمان وقوع خشکسالی، خسارات ناشی از این پدیده مخرب را به حداقل ممکن برسانند.

لذا پیشنهاد می‌شود به منظور افزایش دقت و کارایی هر چه بیشتر الگوریتم‌های یادگیری ماشین از مدل‌های ترکیبی و همچنین از دیگر عوامل هواشناسی از جمله رطوبت نسبی، حداکثر دما، سرعت باد و ... به‌طور همزمان در محاسبات استفاده شود تا نتایج دقیق‌تری در پیش‌بینی و ارزیابی خشکسالی به ویژه خشکسالی هواشناسی ارائه شود.

خشکسالی هواشناسی اولین مرحله از شروع یک دوره خشکسالی گسترده و آغاز یک بحران چندبعدی و پیچیده است که در صورت تداوم، می‌تواند بنیان‌های اکولوژیکی و اقتصادی یک منطقه را آسیب‌پذیر سازد. در مناطق خشک و نیمه‌خشک الگوی تغییرات آب و هوایی یک عامل بازدارنده در توسعه پایدار این مناطق محسوب می‌شود لذا ارائه یک روش کارآمد به منظور پیش‌بینی خشکسالی هواشناسی می‌تواند در مدیریت بهینه منابع آبی و کاهش خسارات ناشی از این پدیده مخرب زیست‌محیطی حائز اهمیت باشد. مدل‌های سری زمانی و الگوریتم‌های یادگیری ماشین می‌توانند نقش مهمی در پیش‌بینی مقادیر بارش در مقیاس زمانی مختلف داشته باشند. در مطالعه حاضر عملکرد مدل‌های سری زمانی با الگوریتم‌های یادگیری ماشین به منظور پیش‌بینی خشکسالی هواشناسی مورد مقایسه قرار گرفت. براساس نتایج حاصل از پیش‌بینی در همه ایستگاه‌های مورد بررسی، الگوریتم یادگیری ماشین افراطی (ELM) با کمترین مقدار RMSE و MAE و بیشترین مقدار NS و R نسبت به دیگر مدل‌ها از دقت بالاتری در پیش‌بینی مقادیر نمایه SPI برخوردار بود. نتایج پژوهش حاضر حاکی از انعطاف‌پذیری بالای الگوریتم‌های یادگیری

منابع

- ارجمندی هرات، زهره و اسدی، محمد امین. ۱۴۰۱. مقایسه عملکرد مدل‌های سری زمانی SARIMA و SARIMAX در پیش‌بینی بلندمدت خشکسالی. نشریه مدیریت بیابان، سال دهم، شماره سوم، صفحات ۱۶-۱.
- حسینی موغاری، سید محمد و عراقی نژاد، شهاب. ۱۳۹۵. کاربرد شبکه‌های عصبی کاربرد شبکه‌های عصبی آماری، فازی و پرسپترون در پیش‌بینی خشکسالی (مطالعه موردی: ایستگاه گنبد کاووس). نشریه آب و خاک (علوم و صنایع کشاورزی)، جلد ۳۰، شماره ۱، صفحات ۲۵۹-۲۴۷.
- قیصوری، مرتضی. کله‌هوئی، مهین. صابری، عارف. و محمدی، پروین. ۱۴۰۱. به‌کارگیری مدل‌های سری زمانی ARIMA در پیش‌بینی خشکسالی هواشناسی استان تهران. نشریه ترویج و توسعه آبخیزداری، سال دهم، شماره ۳۶، صفحات ۷۱-۶۰.

Alam, N.M., Mishra, P.K., Jana, C., Adhikary, P.P., 2014. Stochastic model for drought forecasting for Bundelkhand region in Central India. Indian J. Agric. Sci. 84 (1), 79-84.

Box, G.E.P. and Jenkins, G.M., (1976). "Time Series Analysis: Forecasting and Control", Holden-Day, San Francisco, 525.

Durdu, O.F., 2010. Application of linear stochastic models for drought forecasting in the Buyuk Menderes river basin, western Turkey. Stochastic Environmental Research and Risk Assessment. 24 (8), 1145-1162.

Ehteram, M., Afan, H.A., Dianatikhah, M., Ahmed, A.N., Fai, C.M., Hossain, M.S., Allawi, M.F., Elshafie, A., Ehteram, M., Afan, H.A., 2019. Assessing the Predictability of an Improved ANFIS Model for Monthly Streamflow Using Lagged Climate Indices as Predictors. *Water*, 11, 11-30.

Eivazi, M., Mosaedi, A., & Dehghani, A. A. (2009). Comparison of Different Approaches for Predicting SPI. *Water and Soil Conservation*, 16(2), 145-167.

En-Nagre, Kh., Aqnouy, M., Ouarka, A., Naqvi, S.A.A., Bouizrou, I., El-Messari, J.E.S., Tariq, A., Soufan, W., Li, W., El-Askary, H., 2024. Assessment and prediction of meteorological drought using machine learning algorithms and climate data. *Climate Risk Management* 45, 100630.

Fooladi, M., Golmohammadi, M.H., Safavi, H.R., Singh, V.P., 2021. Fusion-based framework for meteorological drought modeling using remotely sensed datasets under climate change scenarios: Resilience, vulnerability, and frequency analysis. *Journal of Environmental Management*, 297, 113283.

Ghozat, A., Sharafati, A., Asadollah, S.B.H.S., Motta, D., 2023. A novel intelligent approach for predicting meteorological drought based on satellite-based precipitation product: Application of an EMD-DFA-DBN hybrid model. *Computers and Electronics in Agriculture* 211, 107946.

Hayes, M. 2006. Drought Indices. National Drought Mitigation Center. <http://www.southernclimate.org/documents/Memphis-2011/Indices>.

HsinFu, Y. and HsinLi, H. 2019. Stochastic Model for Drought Forecasting in the Southern Taiwan Basin. Department of Resources of Engineering, National Cheng Kung University. 11.10, 2041.

Huang, G.-B., Zhu, Q.-Y., Siew, C.-K., 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70 (1), 489-501.

Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23 (3), 665-685.

Keshavarz, M., Karami, E., Vanclay, F., 2013. The social experience of drought in rural Iran. *Land use policy* 30 (1), 120-129.

Khadr, M., 2016. Forecasting of meteorological drought using Hidden Markov Model (case study: The upper Blue Nile river basin, Ethiopia). *Ain Shams Engineering Journal*. 7, 47-56.

Kumar, R., Kumar, A., Shankhwar, A.K., Vishkarma, D.K., Sachan, A., Singh, P.V., Jahangeer, J., Verma, A., Kumar, V., 2022. Modelling of meteorological drought in the foothills of Central Himalayas: A case study in Uttarakhand State, India. *Ain Shams Engineering Journal*. 13, 101595.

McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology*. 17 (22), 179-183.

Mishra, A.K., Desa, V.R., Singh, V.P., 2007. Drought forecasting using a hybrid stochastic and neural network model. *J. Hydrol. Eng.* 12 (6), 626-638.

Su, T., Liu, D., Cui, X., Dou, X., Lei, B., Cheng, X., Yuan, M., Chen, R., 2024. Prediction of DEDI index for meteorological drought with the VMD-CBiLSTM hybrid model. *Journal of Hydrology* 641, 131805.

Wu, C., Yeh, P.J.F., Chen, Y.Y., Lv, W., Hu, B.X., Huang, G., 2021. Copula-based risk evaluation of global meteorological drought in the 21st century based on CMIP5 multi-model ensemble projections. *Journal of Hydrology* 598, 126265.

Zhang, X., Wu, Z., Wang, H., He, Ch., Zhang, F., Zhou, Y., 2024. Urban meteorological drought comprehensive index based on a composite fuzzy matter element moment estimation weighting model. *iScience* 27, 110798.

Zhao, Ch., Brissette, F., Chen, J., Martel, J-L., 2020. Frequency change of future extreme summer meteorological and hydrological droughts over North America. *Journal of Hydrology*, 584, 124316.