

Comparative Evaluation of Statistical Models and Artificial Intelligence for Drought Prediction in Isfahan Synoptic Station

H. Zarepour¹, A.A. Vali^{2*}, H. Ghorbani³, S.J. Sadatinejad⁴, S.H. Alavinia⁵

1. PhD Student in Desert Management and Control, Department of Desertification, Faculty of Natural Resources and Earth Sciences, University of Kashan, Kashan, Iran.
2. Associate Professor, Department of Desertification, Faculty of Natural Resources and Earth Sciences, University of Kashan, Kashan, Iran.
3. Assistant Professor, Department of Statistics, Faculty of Mathematical Sciences, University of Kashan, Kashan, Iran.
4. Associate Professor, Department of New Energy and Environment, Faculty of Modern Science and Technology, University of Tehran, Tehran, Iran.
5. Assistant Professor, Department of Watershed Management, Faculty of Natural Resources and Earth Sciences, University of Kashan, Kashan, Iran.

* Corresponding Author: vali@kashanu.ac.ir

Received date: 18/12/2021

Accepted date: 25/01/2022



[10.22034/JDMAL.2022.545156.1361](https://doi.org/10.22034/JDMAL.2022.545156.1361)

Abstract

Meteorological drought is a complex natural disaster that occurs everywhere in the world. Predicting the occurrence and severity of drought can be effective in managing water crises and their impacts. The purpose of the current study is to select the most appropriate model from statistical models and artificial intelligence (artificial neural networks) to predict drought in Isfahan synoptic station during the span period of 1990-1920 using the Z-Score index (ZSI). In this study, the capability and efficiency of the SARIMA stochastic linear model and three advanced learning machine models of the Feedforward Neural Networks (FNNs), Multi-layer Perceptron (MLP), and Extreme Learning Machines (ELM) were evaluated based on Root Mean Squared Error (RMSE), Mean Absolute Square Error (MASE) and Mean Absolute Error (MAE). The results showed that among the many models made, the Feedforward Neural Networks (FNNs) model with RMSE of 0.33, MASE of 0.02, and MAE of 0.22 were selected as the best model. Using the superior model, precipitation for the period of 2025-2021 of Isfahan synoptic station was predicted, then based on the ZSI drought index, drought intensity of forecast precipitation data in 3, 6, 9, 12-month time scales, 18, and 24 months was calculated. The results of drought severity predicting showed that severe drought in 3 and 6 month time scales in 2021 and 2023 and in 9 and 18 month time scales in 2024, moderate drought in all time scales in 2024, and weak droughts occurred at the 3, 6, and 24-month time scales in 2024 and 2025, respectively. Overall, the results showed that the use of feed neural network model was more efficient. Since predicting drought at all time scales can reveals drought more accurately, this predicting in turn to facilitate the development of water resources management strategies for management of drought is effective.

Keywords: Extreme Learning Machines (ELM) Model; Feedforward Neural Networks (FNNs) Model; Multi-layer Perceptron (MLP) Model; SARIMA Mode; Z-score index (ZSI)





ارزیابی تطبیقی مدل‌های آماری و هوش مصنوعی برای پیش‌بینی خشکسالی در ایستگاه همدیدی اصفهان

هادی زارع‌پور^۱، عباسعلی ولی^{۲*}، حمید قربانی^۳، سیدجواد ساداتی نژاد^۴، سیدحسن علوی‌نیا^۵

۱. دانشجوی دکتری مدیریت و کنترل بیابان، گروه بیابان‌زدایی، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، ایران.
۲. دانشیار، گروه بیابان‌زدایی، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، ایران.
۳. استادیار، گروه آمار، دانشکده علوم ریاضی، دانشگاه کاشان، کاشان، ایران.
۴. دانشیار، گروه انرژی‌های نو و محیط زیست، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران.
۵. استادیار، گروه آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، ایران.

* نویسنده مسئول: Vali@kashanu.ac.ir

تاریخ دریافت: ۱۴۰۰/۰۹/۲۷ تاریخ پذیرش: ۱۴۰۰/۱۱/۰۵



[10.22034/JDMAL.2022.545156.1361](https://doi.org/10.22034/JDMAL.2022.545156.1361)

چکیده

خشکسالی هواشناسی رخدادی طبیعی، پیچیده و مخرب است که در کل کره زمین مشاهده می‌شود. پیش‌بینی وقوع و شدت خشکسالی می‌تواند در مدیریت بحران آب و خسارت ناشی از آن مؤثر باشد. هدف از پژوهش حاضر انتخاب مناسب‌ترین مدل، از بین مدل‌های آماری و هوش مصنوعی برای پیش‌بینی خشکسالی در ایستگاه همدیدی اصفهان در دوره آماری ۱۹۹۰ تا ۲۰۲۰، با استفاده از شاخص معیار استاندارد (ZSI) می‌باشد. در این مطالعه قابلیت و کارایی مدل خطی تصادفی SARIMA و سه مدل پیشرفته ماشین یادگیری؛ شبکه عصبی مصنوعی پیش‌خور (FNNs)، پرسپترون چندلایه (MLP)، ماشین‌های یادگیری افراطی (ELM)، بر اساس معیار ریشه میانگین مربعات خطا (RMSE)، میانگین مجذور خطای مطلق (MASE) و میانگین قدر مطلق خطاها (MAE) مورد ارزیابی قرار گرفت، نتایج نشان داد که از بین انبوه مدل‌های ساخته‌شده مدل شبکه عصبی مصنوعی پیش‌خور (FNN) با مقادیر RMSE برابر ۰/۳۳، MASE برابر ۰/۰۲ و MAE برابر ۰/۲۲ بهترین مدل پیش‌بینی است. با استفاده از مدل برتر، بارش ۶۰ ماه آینده ایستگاه همدیدی اصفهان از سال ۲۰۲۱ تا سال ۲۰۲۵ پیش‌بینی شد. سپس، شدت خشکسالی داده‌های بارش پیش‌بینی شده بر اساس شاخص خشکسالی ZSI در مقیاس‌های زمانی ۳، ۶، ۹، ۱۲، ۱۸ و ۲۴ ماهه محاسبه شد. نتایج ارزیابی شدت خشکسالی‌های پیش‌بینی شده نشان داد، در مقیاس‌های زمانی ۳ و ۶ ماهه در سال‌های ۲۰۲۱ و ۲۰۲۳ و در مقیاس‌های زمانی ۹ و ۱۸ ماهه در سال ۲۰۲۴ خشکسالی شدید، خشکسالی متوسط در همه مقیاس‌های زمانی در سال ۲۰۲۴ و خشکسالی ضعیف در مقیاس‌های زمانی ۳، ۶ و ۲۴ ماهه در سال‌های ۲۰۲۴ و ۲۰۲۵ اتفاق خواهد افتاد. در مجموع نتایج نشان داد که استفاده از مدل شبکه عصبی پیش‌خور دارای کارایی بیشتری است. از آن جا که پیش‌بینی انجام شده در همه مقیاس‌های زمانی می‌تواند خشکسالی را با وضوح بیشتری آشکار کند، این پیش‌بینی به‌نوبه خود برای تسهیل در توسعه راهبردهای مدیریت منابع آب مؤثر است.

واژگان کلیدی: شاخص معیار استاندارد؛ مدل ساریمان؛ شبکه عصبی مصنوعی پیش‌خور؛ پرسپترون چندلایه؛ ماشین‌های یادگیری افراطی



■ مقدمه

مهم‌ترین عارضه در تغییرپذیری شرایط اقلیمی، خشکسالی هواشناسی می‌باشد. اگرچه خشکسالی را پدیده‌ای تصادفی تلقی می‌کند، اما از ویژگی‌های عادی هر اقلیمی محسوب می‌شود که مشخصات آن در هر اقلیم به شکل متفاوت با اقلیم دیگر می‌دهد (۲۶). تحقیقات نشان داده است که فقدان تعریف دقیق و عینی در موقعیت‌های خاص مانعی بر سر راه درک خشکسالی بوده که منجر به عدم تصمیم‌گیری بهنگام و عدم اقدام مدیران، سیاست‌گذاران شده است (۶۰). خشکسالی می‌تواند سال‌ها ادامه داشته باشد و اثرات مخربی بر کشاورزی و منابع آب داشته باشد. ممکن است تعیین زمان شروع یا پایان خشکسالی دشوار باشد. خشکسالی می‌تواند کوتاه باشد، فقط چند ماه طول بکشد یا می‌تواند سال‌ها به طول بیانجامد که بعد از بازگشت شرایط آب و هوایی به حالت عادی و اولیه خشکسالی به پایان برسد (۲۵). از آنجایی‌که تأثیرات خشکسالی در ابتدا به‌کندی ظهور پیدا می‌کند، حتی ممکن است خشکسالی تا زمانی که تثبیت نشده باشد، به‌خوبی تشخیص داده نشود (۱۵).

از آنجا که منطقه اصفهان جزء مناطق خشک و نیمه‌خشک بیابانی محسوب می‌گردد و از دیگر سو در سال‌های اخیر انواع خشکسالی‌های اقلیمی، هیدرولوژیکی، کشاورزی و اقتصادی-اجتماعی در منطقه حادث گردیده است (۴۸). تجزیه و تحلیل تاریخ وقایع خشکسالی برای تعیین خطرات احتمالی بروز خشکسالی در آینده این منطقه بسیار مهم و ضروری می‌باشد (۳۰)، یکی از روش‌ها و ابزارهایی که برای بیان کمی خشکسالی‌ها مورد استفاده قرار می‌گیرد شاخص‌های خشکسالی می‌باشد (۳). که بر پایه آن‌ها می‌توان ریسک خشکسالی، تجزیه و تحلیل شدت، طول مدت خشکسالی را در مقیاس‌های زمانی مختلف برای گذشته و آینده ارزیابی و پیش‌بینی کرد. یکی از جامع‌ترین شاخص‌های خشکسالی، شاخص معیار استاندارد^۱ (ZSI) می‌باشد که در بررسی‌های خشکسالی و ترسالی کاربرد فراوانی دارد (۲۱). با پژوهش‌های مشخص

شد که شاخص‌ها توانایی خوبی برای پیش‌خشکسالی در مقیاس‌های متفاوت دارند و برتری شاخص ZSI نسبت به شاخص SPI به این دلیل است که شاخص ZSI نواقص آماری را در بین سری داده‌ها قبول می‌کند و چون برای محاسبه شاخص ZSI به تبدیل داده‌ها و برازش توزیع مانند گاما و یا پیرسون نوع III مطابق آنچه در SPI انجام می‌گردد، نیاز ندارد به همین دلیل محاسبات ساده‌تری دارد (۱، ۳۶، ۴۴). از نتایج ارزیابی این شاخص در مقیاس‌های زمانی کوتاه‌مدت برای اهداف کشاورزی و در مقیاس‌های زمانی بلندمدت برای اهداف هیدرولوژی مورد استفاده قرار می‌گیرد (۲۷).

پیش‌بینی خشکسالی نقش مهمی برای برنامه‌ریزی و مدیریت منابع آب در به حداقل رساندن پیامدهای منفی آن دارد (۱۹). روش‌های متداول در پیش‌بینی متغیرهای هواشناسی که امروزه مورد استفاده قرار می‌گیرد با توجه به احتمال خطای انسانی و دقت اندک و همچنین داشتن حجم انبوهی از داده‌ها و محاسبه‌های زیاد، دارای محدودیت می‌باشند (۱۹). امروزه محققان با ابداع و پیشرفت علمی چون روش‌های آماری و روش‌های هوشمند که ابزاری توانمند و انعطاف‌پذیر و مستقل از مدل‌های دینامیکی سیستم هستند گام‌هایی را در راه شناخت و پیش‌بینی پارامترهای مهم هواشناسی برداشته‌اند (۲۲، ۴۹). مدل‌های آماری برای پیش‌بینی خشکسالی هیدرولوژیک بر اساس روش‌های سری زمانی استفاده می‌شود (۱۰). مدل‌های رگرسیون و مدل‌های میانگین متحرک اتورگرسیون^۲ (ARMA) مدل‌های معمولی برای روش‌های سری زمانی آماری برای پیش‌بینی هستند. این مدل‌ها اساساً مدل‌های خطی هستند (۱۴). از آنجاکه پیش‌بینی بر اساس تحلیل سری‌های زمانی با کاربرد مفهوم مدل‌ها در منابع زیادی برای پیش‌بینی‌های کوتاه‌مدت مورد استفاده قرار گرفته است، این به دلیل همبستگی پیاپی^۳ بین مشاهدات موجود در سری‌های زمانی می‌باشد خود از ویژگی‌های اصلی سری‌های زمانی خود همبسته میانگین

³ Serial Correlation

¹ ZSI: Z-Score Index

² ARMA: Autoregressive Moving-Average

شبکه عصبی پیش‌خور^۴ (FNNs)، مدل پرسپترون چندلایه^۵ (MLP) و مدل ماشین‌های یادگیری افراطی^۶ (ELM) برای پیش‌بینی وقوع خشکسالی استفاده شد. نتایج نشان داده است مدل‌های پیش‌گفت از کارایی قابل قبولی در پیش‌بینی سری‌های زمانی بارش برخوردار هستند (۱۸). در بررسی‌هایی که به‌طور مجزا در مناطق و مقیاس‌های مختلفی انجام شده کارایی این مدل‌ها را تأکید و قابلیت پیش‌بینی این مدل‌ها نسبت به سایر مدل‌های دیگر مورد تأیید قرار است (۱۲، ۱۳، ۲۳، ۳۲، ۳۳، ۳۷، ۵۰، ۵۷، ۶۱).

از آنجا که مطالعه‌ای به‌طور هم‌زمان قابلیت مدل‌های SARIMA، FNN، MLP و ELM را در منطقه خشک و نیمه‌خشک بیابانی ایستگاه همدیدی اصفهان مورد بررسی قرار دهد و از داده‌های پیش‌بینی شده این مدل‌ها، خشکسالی را با شاخص ZSI در مقیاس‌های زمانی مختلف مورد بررسی قرار دهد پژوهشی انجام نشده است، لذا ضرورت این پژوهش در پیش‌بینی بارش و خشکسالی در ایستگاه همدیدی اصفهان به‌عنوان عامل مهم و تأثیرگذار در مدیریت منابع آب و کاهش پیامدهای منفی حیاتی منطقه مورد مطالعه مشخص گردید. هدف از پژوهش حاضر مقایسه و ارزیابی قابلیت مدل‌های SARIMA، FNN، MLP و ELM برای پیش‌بینی بارش ایستگاه همدیدی اصفهان می‌باشد. مناسب‌ترین مدل برای پیش‌بینی بارش ۵ سال آینده بر اساس کمترین مقادیر شاخص جذر میانگین مربعات خطا^۷ (RMSE)، میانگین مجذور خطای مطلق^۸ (MASE) و میانگین قدر مطلق خطا^۹ (MAE) انتخاب شد. سپس با استفاده از شاخص ZSI، شدت خشکسالی در مقیاس‌های زمانی ۳، ۶، ۹، ۱۲، ۱۸ و ۲۴ ماهه ارزیابی شد. تا بتوان با استفاده از نتایج پژوهش حاضر گامی در مسیر توسعه روش‌های مدیریتی منابع آب برای جلوگیری از ایجاد خشکسالی و مدیریت بهتر آن در آینده انجام داد.

متحرک تلفیق‌شده فصلی^۱ (SARIMA) می‌باشد (۲۰، ۵۸). با استفاده از مدل‌های سری زمانی SARIMA بهترین برازش برای هر مدل به دست می‌آید. مدل مذکور بر پایه معیار آکائیک^۲ (AIC) انتخاب می‌شود (۴۲). از بین مدل‌های برازش داده‌شده، بر اساس آزمون نکویی برازش، مدل برتر انتخاب می‌شود. مقایسه بین آمار واقعی و آمار تولیدشده، همچنین حدود اطمینان داده‌های تولیدشده برای تأیید مدل انتخاب‌شده، صورت گرفته و در پایان مدل مورد استفاده برای پیش‌بینی بارش و بررسی روند خشکسالی در آینده مورد استفاده قرار می‌گیرد (۲۸).

از آنجا که بسیاری از فرآیندهای هیدرولوژیک به‌شدت غیرخطی و غیرایستایی بوده و تابع قوانین فرآیندهای تصادفی هستند (۵۶). در دهه‌های اخیر سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد (۶). شبکه‌های عصبی مصنوعی^۳ (ANN) توانایی زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرثابت در هیدرولوژی و مهندسی منابع آب به دلیل خاصیت غیرخطی ذاتی و انعطاف‌پذیری برای مدل‌سازی از خود نشان داده‌اند (۵۹). برخی از مزایای شبکه‌های عصبی مصنوعی عبارت‌اند از: ۱- آن‌ها قادرند رابطه بین متغیرهای ورودی و خروجی را بدون ملاحظات فیزیکی به‌طور واضح تشخیص دهند. ۲- حتی زمانی که داده‌های ورودی حاوی نویز و خطاهای اندازه‌گیری باشند، به‌خوبی کار می‌کنند. ۳- آن‌ها می‌توانند در طول زمان با راه‌حل‌ها سازگار شوند تا شرایط در حال تغییر را جبران کنند. ۴- آن‌ها دارای سایر ویژگی‌های ذاتی پردازش اطلاعات هستند و پس از انجام آموزش بر روی داده‌های ورودی، به‌راحتی قابل استفاده می‌باشند (۱۷).

با توجه به اینکه نتایج نشان داده است روش‌های داده محور بر اساس کاربرد شبکه‌های عصبی مصنوعی دارای قابلیت‌های خوبی در زمینه پیش‌بینی قابل اعتماد در خشکسالی هستند (۴). در پژوهش حاضر با توجه به ماهیت غیرخطی سری‌های زمانی بارش، از مدل SARIMA و مدل

^۵ MLP: Multi-layer Perceptron

^۶ ELM: Extreme Learning Machines

^۷ RMSE: Root Mean Squared Error

^۸ MASE: Mean Absolute Square Error

^۹ MAE: Mean Absolute Error

^۱ SARIMA: Seasonal Autoregressive Integrated Moving - Average

^۲ AIC: Akaike Information Criterion

^۳ Artificial Neural Network

^۴ FNNs: Feed-Forward Neural Network

■ مواد و روش

منطقه مورد بررسی

ایستگاه همدیدی اصفهان در مختصات عرض جغرافیایی $۵۱^{\circ} ۷۰' ۱۷''$ شمالی و طول جغرافیایی $۱۵^{\circ} ۳۲' ۴۳''$ شرقی قرار دارد (شکل ۱). میانگین بارندگی و ارتفاع متوسط ایستگاه باران‌سنجی اصفهان به ترتیب برابر ۱۲۰ mm/y و ۱۵۵۰ m از سطح دریا می‌باشد (۴۵). استان اصفهان دارای پنج زیر منطقه اقلیمی شامل اقلیم نیمه‌بیابانی، استپی، نیمه‌استپی، کوه‌های مرتفع و جنگل‌های خشک است (۳۰). منطقه مورد بررسی پژوهش حاضر در منطقه خشک و نیمه‌بیابانی واقع شده، در این منطقه برخی گونه‌های مقاوم به خشکی استقرار دارند مناطق پست این منطقه را اراضی شور تشکیل می‌دهد (۴۵).

در پژوهش حاضر برای پیش‌بینی خشکسالی ایستگاه همدیدی اصفهان از داده‌های بارش ماهانه برای دوره ۱۹۹۰ تا ۲۰۲۰ که از سازمان هواشناسی کشور اخذ شده بود استفاده شد (۳۵). ابتدا آزمون همگنی داده‌ها به روش آزمون گردش حول میانگین یا ران‌تست^۱ که یکی از متداول‌ترین آزمون‌های غیرنموداری برای تأیید همگنی داده‌هاست (۴۶) در نرم‌افزار R محاسبه شد.

روش انجام پژوهش

شاخص معیار استاندارد یا (ZSI)

در این پژوهش از شاخص ZSI برای ایستگاه مورد مطالعه بر پایه آمار بلندمدت بارندگی ۳۰ ساله، در مقیاس‌های زمانی مختلف نظیر یک دوره سه‌ماهه، شش‌ماهه و غیره استفاده شد. مراحل محاسبه شاخص معیار استاندارد به صورت زیر می‌باشد (۲۱):

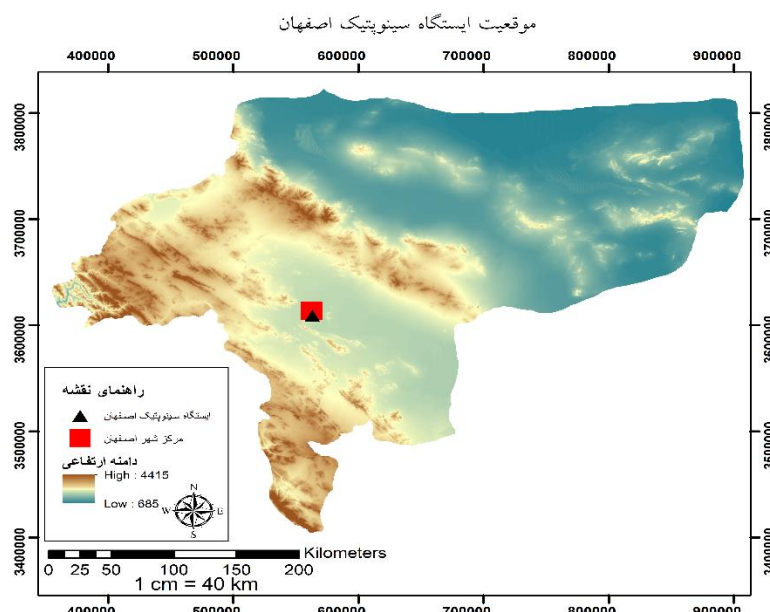
۱- مرتب نمودن سری زمانی داده‌های بارندگی به صورت صعودی.

۲- تعیین میانگین و انحراف استاندارد سری زمانی داده‌ها.

۳- تعیین شاخص معیار استاندارد برای هر یک از دوره‌های آماری.

برای محاسبه شاخص معیار استاندارد (ZSI) از رابطه ۱ استفاده شد که X_i میزان بارش دوره، \bar{X} میانگین بارش دوره، S انحراف معیار بارش در هر مقیاس زمانی است (۸). دامنه تغییرات و طبقه‌بندی ZSI برای بیان شدت خشکسالی در جدول ۱ ارائه شده است.

$$Z = \frac{X_i - \bar{X}}{S} \quad (1)$$



شکل ۱. موقعیت جغرافیایی ایستگاه همدیدی اصفهان در استان اصفهان

¹ Run Test

جدول ۱. طبقه‌بندی خشکسالی بر اساس شاخص ZSI (۸).

| شاخص معیار استاندارد شده (ZSI) | طبقات شدت خشکسالی |
|--------------------------------|--------------------|
| +۱ تا صفر | نرمال |
| -۱ تا صفر | خشکسالی ضعیف |
| -۱/۵ تا -۱ | خشکسالی متوسط |
| -۲ تا -۱/۵ | خشکسالی شدید |
| کمتر از -۲ | خشکسالی بسیار شدید |

مدل آماری

مدل سری زمانی SARIMA

به‌منظور پیش‌بینی داده‌های بارش از میان مدل‌های مختلف سری زمانی، از مدل SARIMA استفاده گردید. مدل‌های عمومی فصلی SARIMA به‌اختصار به‌صورت $SARIMA(p, d, q)(P, D, Q)_s$ نمایش داده می‌شوند که s مؤلفه فصلی و (p, d, q) معرف بخش غیرفصلی مدل و $(P, D, Q)_s$ معرف بخش فصلی مدل است (رابطه ۲) (۹):

$$\Phi_P(B^S)\phi_P(B)\nabla_S^D \nabla^D X_t = \Theta_Q(B^S)\theta_Q(B)a_t, \quad (2)$$

که در آن X_t مشاهدات متوالی سری زمانی و a_t فرایند نوفه سفید^۱ و $\nabla^d X_1 = (1 - B)^d X_1$, $B^d X_1 = X_{1-d}$ و $\nabla_S X_1 = X_1 - X_{1-s}$ به ترتیب چندجمله‌ای‌های AR و MA غیرفصلی از درجه p و q برحسب B و $\Theta_P(B^S)$ و $\theta_Q(B^S)$ نیز به ترتیب چندجمله‌ای‌های AR و MA فصلی از درجه P و Q برحسب B^S هستند (رابطه ۳ و ۴):

$$\begin{aligned} \phi_P(B) &= 1 - \phi_1 B - \dots - \phi_P B^P, \\ \theta_Q(B) &= 1 - \theta_1 B - \dots - \theta_Q B^Q. \end{aligned} \quad (3)$$

$$\begin{aligned} \Phi_P(B^S) &= 1 - \Phi_1 B^S - \dots - \Phi_P B^{Ps}, \\ \Theta_Q(B^S) &= 1 + \Theta_1 B^S - \dots - \Theta_Q B^{Qs}. \end{aligned} \quad (4)$$

p درجه خود همبسته غیرفصلی، d درجه تفاضل‌گیری، q درجه میانگین متحرک غیرفصلی، P درجه

خود همبسته فصلی، D درجه تفاضل‌گیری فصلی، Q درجه میانگین متحرک فصلی، s طول فصل است (۳۸، ۳۹، ۵۱). برای ساخت این مدل، چهار مرحله: شناسایی مدل، برازش الگو، ارزیابی درستی الگو و پیش‌بینی باید انجام گیرد (۳۰).

برای شناسایی و برازش بهترین مدل، چندین مدل SARIMA با مرتبه‌های متفاوت با استفاده از نرم‌افزار R به داده‌ها برازش و مناسب‌ترین مدل توسط معیار اطلاع آکائیک و معیار اطلاع بیزی^۲ (BIC) (رابطه ۵) انتخاب شد. معیار انتخاب بهترین مدل داشتن کمترین مقدار AIC است (رابطه ۶) (۳۴).

$$AIC = n \left(\ln \left(\frac{2\pi RSS}{n} \right) + 1 \right) + 2m, \quad (5)$$

$$BIC = n \left(\ln \left(\frac{2\pi RSS}{n} \right) + 1 \right) + m \ln(n), \quad (6)$$


که در آن‌ها n تعداد مشاهدات، $m = (p + q + P + Q)$ تعداد پارامترهای برآورد شده مدل و RSS مجموع مربعات باقیمانده موردنظر می‌باشد (۵۲).

مدل شبکه‌های عصبی مصنوعی

۱ - مدل شبکه عصبی پیش‌خور (FNNs)

مدل شبکه عصبی پیش‌خور که نوعی مدل شبکه عصبی مصنوعی با سه لایه برای اهداف پیش‌بینی است (شکل ۳) (۳۷).

² BIC: Bayesian Information Criterion¹ White Noise



شکل ۲. یک شبکه FNN با سه لایه (۳۷)

همان طور که در رابطه ۷ نشان داده شده است:

$$y_j = f_j \left(\sum_{i=1}^n W_{ij} I_i + \beta_j \right) \quad (9)$$

$$S_j = \sum_{i=1}^n W_{i,j} I_i + \beta_i \quad (7)$$

پس از ساخت شبکه عصبی، مجموعه وزن‌های شبکه به تقریبی نتایج موردنظر تنظیم می‌شود. این فرایند با بهره‌گیری از خوارزمیک تمرینی برای انطباق وزنه‌ها تا زمانی که معیارهای خطا برآورده شود انجام شد (۱۶).


که در آن، n تعداد کل نورون‌های ورودی است، W_{ij} وزن اتصال ارتباط I_j به نورون j و β_j وزن بایاس است (۱۶). سپس گره یا نورون مصنوعی ضرب‌ها را اضافه می‌کند و جمع را به یک تابع انتقال می‌فرستد، برای نمونه تابع سیگموئید ارائه شده است (رابطه ۸):

۲- مدل پرسپترون چندلایه (MLP)

مدل پرسپترون چندلایه (MLP) شامل لایه ورودی، لایه پنهان، و لایه خروجی است (۴۷). یک شبکه MLP با یک لایه پنهان واحد، شبکه‌ای است که دارای برخی وزنه‌هایی است که بین لایه‌ها به هم متصل می‌شوند (شکل ۳). مقادیر خروجی شبکه چندلایه پرسپترون از طریق مراحل زیر محاسبه شد.

$$f_j(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

خروجی نورون j (رابطه ۹):



شکل ۳. یک شبکه MLP با یک لایه پنهان واحد (۵۵)

خروجی متغیر بایاس است (۵۵).

ابتدا مجموع وزن‌ها به صورت زیر در رابطه (۱۰)

محاسبه شد (۵۵):

$$S_j = \sum_{i=1}^n w_{ij}x_i + \beta_i. \quad (10)$$

که در آن x_i متغیر ورودی است، w_{ij} وزن بین متغیر ورودی x_i و نورون j و β_i وزن بایاس متغیر ورودی است. دوم، مقادیر خروجی نورون‌ها در لایه‌های پنهان از مقادیر دریافتی جمع وزنی (معادله (۱۰)) با استفاده از یک تابع فعال‌سازی تولید شد. یک انتخاب رایج از چنین تابعی یک تابع سیگموئید به شرح رابطه ۱۱ محاسبه شد:

$$f_j(x) = \frac{1}{1 + e^{-s_j}}. \quad (11)$$

که در آن f_j تابع سیگموئید برای نورون j و S_j مجموع وزن‌ها است. در نهایت خروجی نورون j به صورت رابطه ۱۲ محاسبه شد:

$$y_j = \sum_{i=1}^n w_{ij}f_j + \beta_j. \quad (12)$$

که در آن y_j خروجی نورون j ، w_{ij} وزن بین متغیر خروجی y_i و نورون j ، f_j تابع فعال‌سازی نورون j و β_j

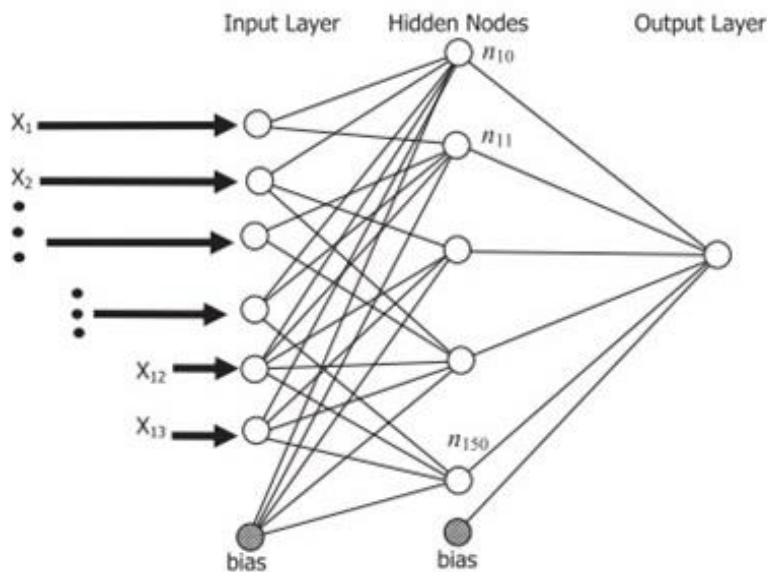
۳- مدل ماشین‌های یادگیری افراطی (ELM)

مدل دیگری که در این پژوهش استفاده شد مدل ماشین‌های یادگیری افراطی (ELM) است. تئوری بنیادی مدل ELM بیان می‌کند که برای N نمونه ورودی مجزای دلخواه $(x_k, y_k) \in R^n \times R^n$ ، شبکه عصبی پیش‌نگر تک لایه استاندارد (SLFNs) با M گره پنهان و یک تابع g فعال‌ساز در رابطه ۱۳ تعریف شده است (۱۲). الگو ساختار مکان‌نگر شبکه ELM در شکل ۴ نشان می‌دهد.

$$y_K = \sum_{i=1}^M \beta_i g(x_K; c_i, a_i) \quad K = 1, 2, 3, \dots, N \quad (13)$$

که در آن $C_i \in R$ مقدار تصادفی تخصیص یافته i امین گره پنهان و $w_i \in R$ وزن ورودی تخصیص یافته به طور اتفاقی بردار اتصال i امین گره پنهان و گره‌های ورودی است. β_i بردار وزنی است که گره پنهان i ام را به گره خروجی وصل می‌کند.

$g(w_k; c_i, w_i)$ خروجی i ام گره پنهان است، با توجه به نمونه ورودی x_k . هر ورودی به طور تصادفی به گره‌های پنهان در شبکه ELM اختصاص می‌یابد. بنابراین از معادله ۱۴ می‌توان به معادلات ۱۵ و ۱۶ زیر رسید:



شکل ۴. یک شبکه ELM با یک لایه پنهان (۱۳)

معیارهای ارزیابی

در پایان برای بررسی دقیق‌تر کفایت مدل برازش شده برای پیش‌بینی مقادیر (داده‌های واقعی) از دیگر شاخص‌های ارزیابی مانند میانگین قدر مطلق خطاها (MAE)، میانگین مجذور خطای مطلق (MASE) و شاخص جذر میانگین مربعات خطا (RMSE) استفاده شد، مقادیر کمتر این شاخص‌ها نشان از بهتر بودن مدل دارد (روابط ۲۱ - ۱۹) (۴۱، ۵۷).

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - f_t|, \quad (19)$$

$$MASE = \frac{1}{n} \sum_{t=1}^n \left(\frac{|y_t - f_t|}{\frac{1}{n-1} \sum_{t=2}^n |y_t - f_{t-1}|} \right), \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n |y_t - f_t|^2}, \quad (21)$$

که در آن y_t مقادیر مشاهده‌ای، f_t مقادیر پیش‌بینی و n تعداد مشاهدات می‌باشد (۵۳). هرچند معیارهای خطای مطلق (AEM) مانند میانگین قدر مطلق خطاها MAE میانگین مربعات خطاها^۳ (MSE) و RMSE معیارهای مهمی برای بررسی کیفیت مدل هستند و بهترین مقدار متصور برای آن‌ها صفر می‌باشد ولی این معیارها علیرغم اینکه در مقالات به‌وفور از آن‌ها استفاده می‌شود دارای عیوب زیر می‌باشند. اولین و اصلی‌ترین عیب آن‌ها وابسته بودنشان به معیار اندازه‌گیری است، یعنی با تغییر واحد اندازه‌گیری بارش از میلی‌متر به اینچ می‌توان مقدار RMSE را کاهش داد. عیب دیگر آن‌ها این است که به‌شدت تحت تأثیر مقادیر پرت (حدی) در مشاهده‌ها هستند. یعنی اگر داده‌ها دارای یک نقطه پرت از نوع داده بزرگ باشند، حالتی که در عمل بیشتر پیش می‌آید باید از نامناسب بودن مدل به استناد بزرگ بودن RMSE اجتناب کرد. به همین دلیل باید از

$$H\beta = Y \quad (4)$$

$$H = \begin{bmatrix} g(x_{1.} : c_{1.} a_1) & \dots & g(x_{1.} : c_{M.} a_M) \\ g(x_{N.} : c_{i.} a_i) & \dots & g(x_{N.} : c_{M.} a_M) \end{bmatrix}_{N \times M} \quad (5)$$

$$H\beta = (\beta_1^T \beta_2^T \dots \beta_L^T)^T_{m \times M} \quad (6)$$

و خروجی (Y) از رابطه ۱۷ به قرار زیر است:

$$Y = (t_1^T t_2^T \dots t_L^T)^T_{m \times M} \quad (17)$$

وزن‌های خروجی با یافتن راه‌حل‌های حداقل مربعات برای سامانه‌های خطی فوق‌الذکر به‌دست آمد که مطابق رابطه ۱۸ محاسبه شد:

$$\beta = H^+ Y \quad (18)$$

که در آن H^+ معکوس تعمیم‌یافته موور-پنروس ماتریکس لایه پنهان H است و وزن‌های ورودی و مقادیر پنهان به‌طور تصادفی انتخاب شد، و وزن‌های خروجی به‌صورت تحلیلی و آنالیز شده تعیین شدند (۱۲).

پیش‌بینی

به‌منظور ارزیابی مدل، داده‌های بارش مربوط به سال‌های آماری ۱۹۹۰-۲۰۲۰ را به دو بخش آموزش یا واسنجی^۱ ۱۹۹۰-۲۰۱۷ و آزمون یا اعتبارسنجی^۲ ۲۰۲۰-۲۰۱۷ تقسیم شدند و از داده‌های قسمت آموزش برای برازش مدل استفاده نماییم. ابتدا با استفاده از این مدل برازش شده، داده‌های قسمت آموزش را پیش‌بینی کردیم (شکل ۶). سپس با استفاده از داده‌های آزمون به مقایسه مقادیر پیش‌بینی‌شده با استفاده از مدل‌ها و داده‌ها می‌پردازند (شکل ۷ و نمودارهای سمت راست شکل ۱۱-۸) (۳۲، ۴۱).

^۳MSE: Mean Square Errors

^۱ Train

^۲ Test

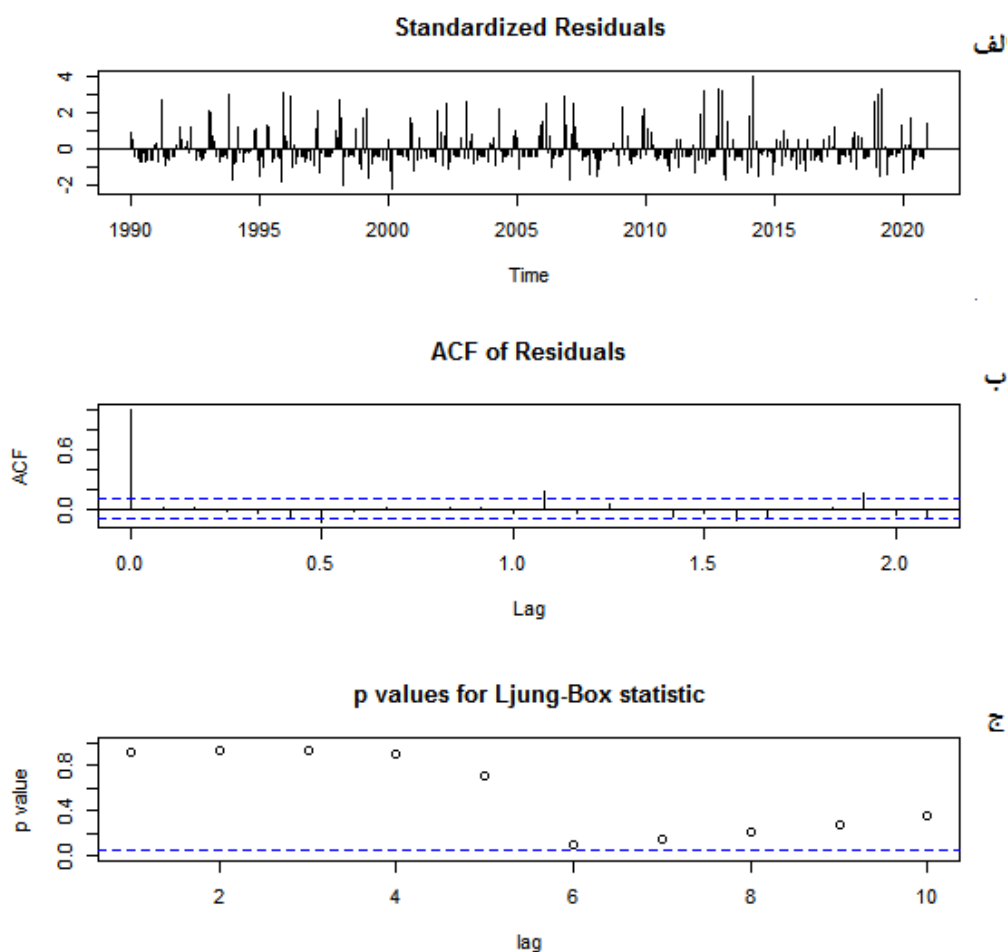
مدل‌های مختلف سری زمانی و به کارگیری معیار اطلاعاتی آکائیک، سری زمانی SARIMA با توجه قابلیت بالای مدل‌سازی به‌عنوان بهترین سری زمانی جهت پیش‌بینی بارش ماهانه ایستگاه همدیدی اصفهان می‌باشد که با نتایج پژوهش‌های انجام‌شده در حوزه سلماس (۱۰) و سطح ایران (۳۴) مشابه می‌باشد. همچنین برای ارزیابی عملکرد بهترین مدل انتخاب‌شده، از معیارهای MAE, RMSE, BIC و MASE نیز استفاده شده است (جدول ۲). نتیجه مشابهی نیز توسط سایر پژوهشگران به‌دست آمده است (۱۵).

برای بررسی کفایت مدل برازش شده بر اساس مدل SARIMA، ارزیابی باقیمانده‌ها برای ایستگاه همدیدی اصفهان گزارش شده است (شکل ۵)، که نشان‌دهنده عدم همبستگی درمانده‌های مدل برازش شده به داده‌های این ایستگاه می‌باشد. نتایج مذکور، با نتایج پژوهش انجام‌شده در استان گلستان (۵۸) مشابه است.

معیارهایی استفاده کرد که به واحد اندازه‌گیری وابسته نیستند که معروف‌ترین آن‌ها میانگین قدر مطلق درصد خطا (MAPE) است که البته آن نیز داری ضعف‌های مختص خود است. به‌عنوان نمونه این معیار فقط برای داده‌های اندازه‌گیری شده با مقیاس نسبی (یعنی داده‌هایی که صفر واقعی دارند) قابل استفاده است و دیگر اینکه این معیار برای وقتی مقادیر پیش‌بینی شده بیش از مقدار واقعی هستند نسبت به وقتی این مقادیر کمتر از مقدار واقعی هستند، جریمه بیشتری در نظر می‌گیرد (۲۵).

نتایج و بحث

مدل‌سازی سری زمانی برای ایستگاه همدیدی اصفهان با طول دوره آماری ۱۹۹۰-۲۰۱۷ انجام شد. بهترین مدل با توجه به معیار AIC انتخاب شده است. در بررسی



شکل ۵. (الف): نمودار باقی‌مانده‌های استاندارد شده، (ب): نمودار خود همبستگی همراه فاصله اطمینان ۹۵٪ از باقی‌مانده‌ها، (ج): نمودار مقادیر معناداری آزمون لیونگ - باکس ایستگاه اصفهان

زود هنگام نرون‌ها می‌گردد (۶۲) نرمال‌سازی زمانی که دامنه تغییرات ورودی‌ها زیاد باشد کمک زیادی به آموزش بهتر و سریع‌تر مدل می‌کند، نرمال‌سازی داده‌ها برای ورود به شبکه عصبی مصنوعی انجام شد (رابطه ۲۲).

$$x_n = \frac{x_o - x_{min}}{x_{max} - x_{min}} \quad (22)$$


که x_n داده‌های نرمال شده، x_o داده‌های اولیه و x_{min} و x_{max} کمینه و بیشینه داده‌های اولیه را نشان می‌دهد (۵۴).

در نرم‌افزار R با استفاده از داده‌های آموزش بهترین مدل برای مدل‌های SARIMA، FNN، MLP و ELM برازش داده شد که مقادیر MASE، MAE و RMSE بهترین مدل برازش داده شده مشخص شد (جدول ۲) (شکل ۶-۹). در مرحله بعد، ساختار مناسب شبکه عصبی، تابع محرک، تعداد نرون‌ها، تعداد لایه‌های پنهان، لایه‌های ورودی و خروجی انتخاب شد. سپس، برای تعیین بهترین ورودی‌های شبکه پس از سعی و خطای فراوان، ساختاری با استفاده از میانگین بارش سالیانه برای پیش‌بینی بارش سالیانه انتخاب شد (۳۳).


مقایسه و ارزیابی مدل‌های آماری و شبکه‌های عصبی مصنوعی در پژوهش حاضر به منظور مقایسه نتیجه مدل‌های SARIMA، FNN، MLP و ELM برای پیش‌بینی بارش ایستگاه همدیدی اصفهان از داده‌های بارش ماهانه دوره ۱۹۹۰ تا ۲۰۲۰ با نرم‌افزار R انجام شد. به عنوان خروجی در مدل‌ها با توجه به پارامتر ورودی بارش در ایستگاه مورد بررسی، ۸۰٪ از داده‌ها به عنوان آموزش و ۲۰٪ از داده‌ها به عنوان آزمون به صورت تصادفی، که گستره وسیعی از داده‌ها را پوشش دهد، انتخاب شد (۳۱) نکته مهم در آموزش شبکه‌های عصبی مصنوعی نرمال‌سازی داده‌ها قبل از استفاده در مدل‌ها می‌باشد. با توجه به این که استان اصفهان جزء مناطق خشک و نیمه‌بیابانی کشور محسوب می‌شود، نوسان‌های شدید بارش از سالی به سال دیگر و حتی در ماه‌های مختلف یک سال کاملاً مشهود می‌باشد. نوسان‌های شدید بارش و به تبع آن پراکندگی زیاد داده‌ها منجر به پیچیدگی در فرایند آموزش و توانایی مدل شد و دقت و سرعت شبکه را کاهش می‌دهد (۵۴). برای دوری از چنین شرایطی و ب یکسان کردن ارزش داده‌ها برای شبکه، نرمال‌سازی داده‌ها انجام شد که این کار مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع

جدول ۲. بهترین مدل برازش شده و معیارهای ارزیابی خطای پیش‌بینی مربوط به داده‌های آموزش در ایستگاه همدیدی اصفهان


| ردیف | مدل | AIC | BIC | RMSE | MAE | MASE |
|------|------------------------------------|---------|---------|-------|------|------|
| ۱ | SARIMA(۱,۰,۰)(۲,۰,۰) _{۱۲} | ۲۶۶۴/۷۳ | ۲۶۸۲/۹۱ | ۱۲/۵۲ | ۹/۱۵ | ۰/۸۷ |
| ۲ | FNN | - | - | ۰/۳۳ | ۰/۳۳ | ۰/۰۲ |
| ۳ | MLP | - | - | ۳/۴۲ | ۲/۲۲ | ۰/۲۴ |
| ۴ | ELM | - | - | ۱۲/۳۰ | ۸/۶۹ | ۰/۸۲ |




شکل ۶. بهترین مدل برازش شده با داده‌های آموزش با استفاده از مدل SARIMA



شکل ۷. بهترین مدل برازش شده با داده‌های آموزش با استفاده از مدل FNN



شکل ۸. بهترین مدل برازش شده با داده‌های آموزش با استفاده از مدل MLP




شکل ۹. بهترین مدل برازش شده با داده‌های آموزش با استفاده از مدل ELM

توجه به نتایج پژوهش حاضر، مدل شبکه عصبی پیش‌خور (FNNs) به‌عنوان مدل برتر انتخاب شد. نتایج مشابه نیز توسط سایر پژوهشگران به دست آمده است (۳۲، ۴۳، ۵۷). با انطباق نمودارهای پیش‌بینی بارش مدل‌های SARIMA، FNN، MLP و ELM که به‌واسطه بهترین مدل برازش شده بر داده‌های آموزش ۲۰۲۰ - ۲۰۱۷ ایستگاه همدیدی اصفهان به دست آمد، کفایت مدل‌های برازش شده مورد ارزیابی قرار گرفت (شکل ۱۰).

به‌منظور مدل‌سازی از داده‌های آزمون از مدل‌های تصادفی خطی SARIMA و غیرخطی FNN، MLP و ELM با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شد و بهترین مدل با استفاده از داده‌های آزمون ۲۰۲۰-۲۰۱۷، برای هر یک از مدل‌ها برازش داده شد. در نهایت مقایسه و ارزیابی عملکرد بهترین مدل‌های برازش شده در بین مدل‌های SARIMA، FNN، MLP و ELM بر اساس کمترین مقادیر MAE، MASE و RMSE انجام شد (جدول ۳). با

جدول ۳. مقایسه مدل‌های آماری و شبکه عصبی مصنوعی بر اساس معیارهای ارزیابی با داده‌های آزمون در ایستگاه همدیدی اصفهان


| ردیف | مدل | RMSE | MAE | MASE |
|------|--------|-------|------|------|
| ۱ | SARIMA | ۱۲/۷۴ | ۹/۳۱ | ۰/۸۸ |
| ۲ | FNN | ۰/۴۷ | ۰/۳۵ | ۰/۰۳ |
| ۳ | MLP | ۴/۳۳ | ۲/۹۳ | ۰/۲۸ |
| ۴ | ELM | ۱۲/۴۴ | ۸/۸۰ | ۰/۸۳ |




شکل ۱۰. انطباق نمودارهای ارزیابی کفایت پیش‌بینی مدل‌های SARIMA، FNN، MLP و ELM در ایستگاه همدیدی اصفهان

۵ سال آینده ۲۰۲۱ - ۲۰۲۵ و نمودارهای ۱۲، ۱۴، ۱۶ و ۱۸ معرف قابلیت مدل در پیش‌بینی مقادیر داده‌های آزمون ۲۰۲۰ - ۲۰۱۷ است.


مقادیر پیش‌بینی شده توسط بهترین مدل برازش شده برای هر یک از مدل‌ها مشخص شد (شکل ۱۱-۱۸). نمودارهای ۱۱، ۱۳، ۱۵ و ۱۷ معرف پیش‌بینی بارش برای



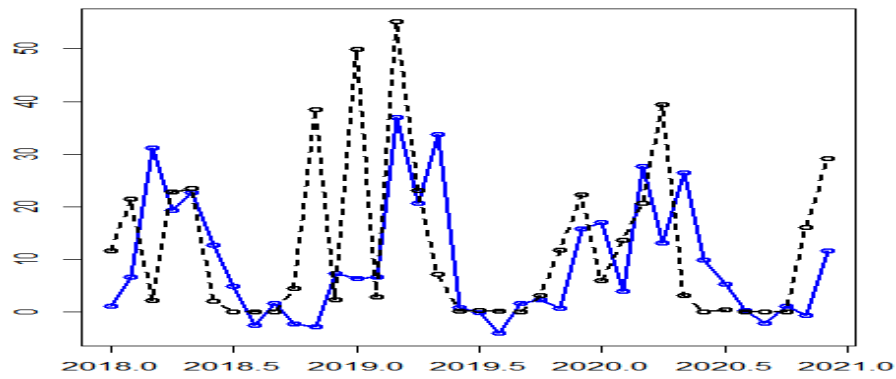
شکل ۱۱. پیش‌بینی بارش برای ایستگاه اصفهان با مدل SARIMA




شکل ۱۲. ارزیابی کفایت پیش‌بینی بارش ایستگاه اصفهان با مدل SARIMA




شکل ۱۳. پیش‌بینی بارش برای ایستگاه اصفهان با مدل FNN




شکل ۱۴. ارزیابی کفایت پیش‌بینی بارش ایستگاه اصفهان با مدل FNN



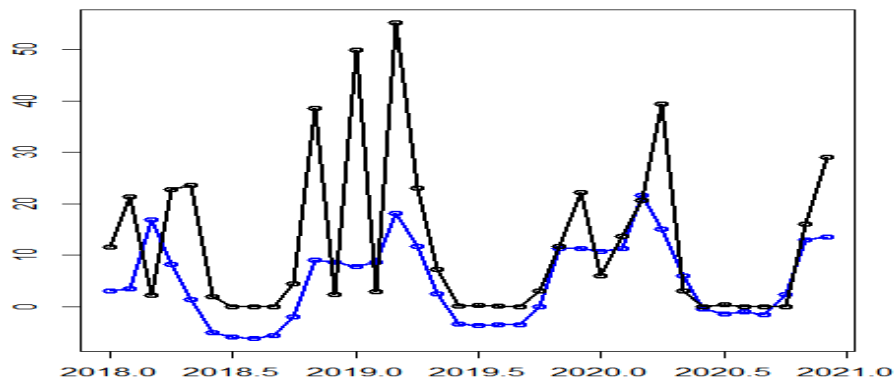
شکل ۱۵. پیش‌بینی بارش برای ایستگاه اصفهان با مدل MLP



شکل ۱۶. ارزیابی کفایت پیش‌بینی بارش ایستگاه اصفهان با مدل MLP



شکل ۱۷. پیش‌بینی بارش برای ایستگاه اصفهان با مدل ELM



شکل ۱۸. ارزیابی کفایت پیش‌بینی بارش ایستگاه اصفهان با مدل ELM

دارای عملکرد مناسب برای داده‌های با حجم بالا و همچنین دقت زیاد برای محاسبه داده‌های با حجم کم می‌باشد. معایب مدل این مدل شامل: وابستگی هر کدام از متغیرهای مستقل به متغیرهای وابسته مشخص نیست، از طرفی محاسبه و تشخیص دقیق آن بسیار پیچیده است.

مزایای اصلی استفاده از مدل ماشین‌های یادگیری افراطی این است که برخلاف شبکه عصبی پیش‌نگر تمام پارامترهای این مدل نظیر مقادیر لایه‌های پنهان و وزن‌های ورودی نیاز به تنظیم قبلی ندارند و همچنین ظرفیت منحصر به فرد آن در پردازش تطبیقی غیرخطی دارد. این موجب برتری این مدل نسبت به دیگر مدل‌های شبکه عصبی سنتی می‌باشد (۱۲). مهم‌ترین عیب این مدل این نکته است که با توجه به اینکه در این مدل هنگام برازش بهترین مدل از گره‌های پایین رده و پنهان کمی استفاده می‌کند اما مشکل برازش مدل را دارد.

از آنجا که استان اصفهان جزء مناطق خشک و نیمه‌بیابانی محسوب می‌گردد و از دیگر سو در سال‌های اخیر انواع خشکسالی‌های اقلیمی، هیدرولوژیک، کشاورزی


در پژوهش حاضر نیز مشخص شد که استفاده از مدل‌های FNN، MLP و ELM برای پیش‌بینی داده‌های بارش و وقوع خشکسالی مفید بوده است. همچنین نتایج نشان داده کاربرد شبکه‌های عصبی مصنوعی دارای قابلیت‌های خوبی در زمینه پیش‌بینی سری‌های زمانی بارش و خشکسالی برای ۵ سال آینده می‌باشند (۱، ۴، ۱۰، ۱۸، ۴۰، ۶۱). از مزایا و معایب شبکه‌های عصبی می‌توان به موارد زیر اشاره کرد:

مزایای اصلی استفاده از شبکه عصبی پیش‌خور عبارت‌اند از: حجم زیادی از مجموعه داده‌ها را می‌تواند مدیریت کند. این مدل توانایی تشخیص ضمنی روابط غیرخطی پیچیده را بین متغیرهای وابسته و مستقل را دارد و همچنین این مدل توانایی تشخیص تمام تعاملات ممکن بین متغیرهای پیش‌بینی را نیز دارد. معایب این مدل شامل: ماهیت «جعبه سیاه»، بار محاسباتی بیشتر و ماهیت تجربی توسعه مدل می‌باشد.

مزایای اصلی استفاده از مدل پرسپترون چندلایه عبارت‌اند از: قابل استفاده برای مدل‌های پیچیده غیرخطی،

در راستای انتخاب شاخص برتر برای پیش‌بینی خشکسالی در ایستگاه همدیدی اصفهان، قابلیت شاخص‌های درصد نرمال بارندگی^۱، بارش استاندارد شده^۲، معیار استاندارد^۳، Z چینی^۴ و Z چینی اصلاح شده^۵ براساس کمینه وقوع بارش در طی دوره آماری ۱۹۹۰-۲۰۲۰ در ده ایستگاه همدیدی استان اصفهان مورد بررسی قرار گرفت و شاخص معیار استاندارد به عنوان شاخص برتر انتخاب شد. نمودارهای ارزیابی وقوع خشکسالی ایستگاه اصفهان براساس شاخص خشکسالی ZSI در مقیاس‌های زمانی ۳، ۶، ۹، ۱۲، ۱۸، ۲۴ ماهه در شکل ۱۹ می‌باشد.

و اقتصادی- اجتماعی در منطقه ایجاد شه است؛ لذا پیش‌بینی وقوع خشکسالی و ارزیابی آن در این منطقه لازم و ضروری می‌باشد. در این پژوهش با بهره‌گیری از مدل شبکه عصبی پیش‌خور (FNNs) مقدار بارش برای دوره آماری پنج‌ساله ۲۰۲۱-۲۰۲۵ پیش‌بینی شد. استفاده از نرم‌افزار DIP و شاخص خشکسالی ZSI در مقیاس‌های زمانی مختلف (ماهانه، ۳ ماهه، ۶ ماهه، ۹ ماهه، ۱۲ ماهه، ۱۸ ماهه، ۲۴ ماهه و ۴۸ ماهه) شدت و مدت خشکسالی طی دوره ۲۰۲۱-۲۰۲۵ محاسبه شد (شکل ۱۹).



شکل ۱۹. نمودار پیش‌بینی وقوع خشکسالی با استفاده از شاخص ZSI در ایستگاه اصفهان در مقیاس‌های زمانی مختلف (الف): نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۳ ماهه، (ب). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۶ ماهه، (ج). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۹ ماهه، (د). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۱۲ ماهه، (ه). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۱۸ ماهه، (و). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۲۴ ماهه


⁵ MCZI: Modified Chinese Z - Index

¹ PNPI: Percent of Normal Precipitation Index

² SPI: Standardized Precipitation Index

³ ZSI: Z-Score Index

⁴ CZI: China Z- Index



ادامه شکل ۱۹. نمودار پیش‌بینی وقوع خشکسالی با استفاده از شاخص ZSI در ایستگاه اصفهان در مقیاس‌های زمانی مختلف (الف) نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۳ ماهه، (ب). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۶ ماهه، (ج). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۹ ماهه، (د). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۱۲ ماهه، (ه). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۱۸ ماهه، (و). نمودار پیش‌بینی وقوع خشکسالی در مقیاس زمانی ۲۴ ماهه

نتیجه‌گیری

شناخت ویژگی‌های خشکسالی لازمه مدیریت منابع آب است. واکاوی و پایش خشکسالی از نیازهای اساسی برنامه‌ریزی‌های مدیریتی کشاورزی و منابع آبی محسوب می‌شود. بدین منظور باید از شاخص‌های خشکسالی استفاده شود. شاخص معیار استاندارد (ZSI) یکی از شاخص‌های کاربردی و مهم در ارزیابی خشکسالی هواشناسی می‌باشد که با هدف اختصاص ارزش عددی به مهم‌ترین فاکتور اقلیمی، یعنی بارندگی مورد استفاده قرار می‌گیرد. از این شاخص به این دلیل که نواقص آماری را در بین سری داده‌ها قبول می‌کند و همچنین محاسبه ساده‌تری دارد (۱، ۳۶، ۴۴)، استفاده شد. پس از بررسی تمامی مدل‌ها در مدل‌سازی با متغیر ورودی داده‌های بارش، مدل برتر بر اساس کمترین مقادیر معیار ریشه میانگین مربعات خطا (RMSE)، میانگین مجذور خطای مطلق (MASE) و میانگین قدر مطلق خطاها (MAE) انتخاب شد، نتایج نشان داد مدل شبکه عصبی مصنوعی پیش‌خور (FNN) با مقادیر RMSE برابر ۰/۳۳، MASE برابر

خشکسالی شدید در مقیاس‌های زمانی ۳ ماهه و ۶ ماهه در سال‌های ۲۰۲۱ و ۲۰۲۳ و در مقیاس‌های زمانی ۹ ماهه و ۱۸ ماهه در سال ۲۰۲۴ در ایستگاه همدیدی اصفهان رخ داده است. همچنین خشکسالی متوسط در همه مقیاس‌های زمانی در سال ۲۰۲۴ و خشکسالی ضعیف در مقیاس‌های زمانی ۳ ماهه، ۶ ماهه و ۲۴ ماهه در سال‌های ۲۰۲۴ و ۲۰۲۵ در این ایستگاه اتفاق افتاده است. بیشترین شدت خشکسالی مربوط به مقیاس‌های زمانی کوتاه‌مدت می‌باشد و بیشترین تداوم خشکسالی مربوط به مقیاس‌های زمانی بلندمدت ۱۸ ماهه و ۲۴ ماهه بوده که به مدت ۲ سال (۲۰۲۳ تا ۲۰۲۵) دربر می‌گیرد. در مجموع نتایج نشان داد استفاده از مدل شبکه عصبی پیش‌خور در زمینه پیش‌بینی خشکسالی مؤثر بوده و پیش‌بینی شدت و مدت خشکسالی در مقیاس‌های زمانی مختلف به‌طور مؤثر وضعیت خشکسالی را به‌وضوح آشکار می‌کنند تا ابزار مفیدی برای جلوگیری از این پدیده خطرناک و مدیریت منابع آبی باشد.

با ضریب اطمینان قابل قبول در ۵ سال آینده بوده که این امر تأکید بر این موضوع دارد که استفاده از مدل شبکه عصبی پیش‌خور و محاسبه شاخص ZSI همه مقیاس‌های زمانی می‌تواند در زمینه پیش‌بینی خشکسالی مؤثر باشد. این امر موجب می‌شود که خشکسالی در همه مقیاس‌های زمانی را با وضوح بالاتری آشکار شود،

در پژوهش حاضر با پیش‌بینی خشکسالی در ایستگاه اصفهان در همه مقیاس‌های زمانی وضعیت خشکسالی شدید در سال‌های ۲۰۲۱، ۲۰۲۳ و ۲۰۲۴ به دلیل کاهش بارندگی به وضوح مشخص شد. وجود خشکسالی از یک‌سو و افزایش تقاضای آب به واسطه افزایش فن‌آوری و جمعیت در آینده از طرف دیگر ضروری می‌باشد این بحران کم‌آبی و خشکسالی در ایستگاه اصفهان به‌طور جدی مورد توجه قرار گرفته و تدابیر اساسی‌تری در جهت کاهش اثرات خشکسالی در سال‌های آتی به عمل آورد.

شایان ذکر است نتایج حاصل از پژوهش حاضر، حاکی از انعطاف‌پذیری زیاد مدل‌های هوش مصنوعی در شرایط فقر داده‌ها می‌باشد که همین عامل موجب شده تا مدل‌های هوش مصنوعی به‌عنوان ابزاری قدرتمند در شبیه‌سازی و پیش‌بینی‌ها شناخته شوند. همچنین با توجه به نتایج قابل قبول این پژوهش، توصیه می‌شود تصمیم‌گیران امر برای اقدام‌های مدیریت ریسک در منطقه و جلوگیری از وقوع بحران‌های جدی از نتایج این تحقیق بهره گرفته و استفاده نمایند. افزون بر این، لازم به‌ذکر است که عوامل هواشناسی از جمله بارش، دمای بیشینه، رطوبت و سرعت باد به ترتیب از مؤثرترین عوامل در افزایش دقت پیش‌بینی‌ها می‌باشند. لذا پیشنهاد می‌گردد برای افزایش دقت و کارایی هر چه بیشتر مدل‌های هوش مصنوعی از عوامل پیش‌گفت به‌طور هم‌زمان در محاسبات مورد استفاده قرار گیرد تا بستر و نتایج دقیق‌تری در پیش‌بینی و ارزیابی عوامل اقلیمی و هواشناسی به‌ویژه خشکسالی ایجاد شود.

MAE برابر ۰/۲۲ و به‌عنوان بهترین مدل در جایگاه اول و مدل پرسپترون چندلایه (MLP) با مقادیر RMSE برابر ۴/۳۳، MASE برابر ۰/۲۸ و MAE برابر ۲/۹۳ در جایگاه دوم، مدل ماشین‌های یادگیری افراطی (ELM) با مقادیر RMSE برابر ۸/۸۰، MASE برابر ۰/۸۳ و MAE برابر ۱۲/۴۴ در جایگاه سوم و مدل سری زمانی SARIMA با مقادیر RMSE برابر ۱۲/۷۴، MASE برابر ۰/۸۸ و MAE برابر ۹/۳۱ در جایگاه چهارم قرار گرفت.

مدل شبکه عصبی مصنوعی پیش‌خور قادر به پیش‌بینی بارش و خشکسالی در بیشترین حجم، با کمترین هزینه و در کوتاه‌ترین زمان ممکن می‌باشد، لذا اگر این پیش‌بینی داده‌ها به‌صورت دستی صورت می‌گرفت نیازمند اندازه‌گیری‌های فراوان با کارهای آزمایشگاهی پرهزینه و زمان‌بر بود. همچنین دقت و انعطاف‌پذیری بالای مدل شبکه عصبی مصنوعی پیش‌خور باعث ایجاد برتری محسوسی نسبت به سایر مدل‌های شبکه عصبی در این مطالعه شده است (۷).

نتایج ارزیابی پیش‌بینی شدت خشکسالی در ۵ سال آینده نشان داد که خشکسالی شدید در مقیاس‌های زمانی ۳ ماهه و ۶ ماهه در سال‌های ۲۰۲۱ و ۲۰۲۳ و در مقیاس‌های زمانی ۹ ماهه و ۱۸ ماهه در سال ۲۰۲۴، خشکسالی متوسط در همه مقیاس‌های زمانی در سال ۲۰۲۴ و خشکسالی ضعیف در مقیاس‌های زمانی ۳ ماهه، ۶ ماهه و ۲۴ ماهه در سال‌های ۲۰۲۴ و ۲۰۲۵ اتفاق افتاده است. در مجموع نتایج نشان داد که پیش‌بینی بارش و خشکسالی با توجه به ماهیت متغیر آن به‌خصوص برای مدتی قابل توجه قبل از وقوع در منطقه خشک و نیمه‌بیابانی اصفهان کاری بسیار دشوار بوده و اغلب روش‌های موجود قادر به پیش‌بینی با این دقت قابل قبول نیستند. اما در پژوهش حاضر مشخص شد مدل شبکه عصبی پیش‌خور قادر به انجام پیش‌بینی وقوع بارندگی به مقدار مشخص و

References

- Adnan, S., Ullah, K., Li, S., Gao, S., Hayat Khan, A., & Mahmood, R. (2017). Comparison of Various Drought Indices to Monitor Drought Status in Pakistan, *Climate Dynamics*, 51(5/6), 1885-1899.
- Afkhami, H., Dastorani, M. T., Malekinejad, H., & Mobin, M. H. (2010). Effects of Climatic Factors on Accuracy of ANN-Based Drought Prediction in Yazd Area. *Agriculture and Natural Resources*, 14(51), 157-169. (in Farsi)

3. Alizadeh, S., & Toosi, A. (2008). Development of a Model for Monitoring and Forecasting Drought (Case Study: Khorasan Razavi Province). *Water and Soil*, 22(1), 223-235. (in Farsi)
4. Alsumaiei, A. A., & Alrashidi, M. S. (2020). Hydrometeorological Drought Forecasting in Hyper-Arid Climates Using Nonlinearautoregressive Neural Networks. *Water*, 12(9), 2611.
5. Arjmandi Harat, Z., & Asadi Zarch, M. A. (2021). Performance Analysis of NAR Model for Short and Long-Term Drought Forecasting in Arid Regions, *Desert Management*, 9(2), 103-120. (in Farsi)
6. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial Neural Networks in Hydrology. I: Preliminary Concepts, *Hydrologic Engineering*, 5(2), 124-137.
7. Biranvand, S., & Sahraeian, K. (2018). *Types of Neural Networks and Their Applications*, 3rd International Conference on Management and Humanities Research in Iran, Non-Governmental Organizations and Centers, Modbar Management Research Institute, 3, University of Tehran. (in Farsi)
8. Boustani, A., Ulke A., (2020). Investigation of Meteorological Drought Indices for Environmental Assessment of Yesilirmak Region, *Environmental Treatment Techniques*, 8(1), 374-381.
9. Box, G., Jenkins, G. M., & Reinsel, G. C. (1994). *Time Series Analysis, Forecasting and Control (3rd edn)*. Prentice-Hall. Englewood Cliffs. NJ.
10. Byzedi, M., Siosemardeh, M., & Asragah, A. (2017). Prediction and Analysis of Meteorological Drought Based on Time Series (Case Study: Salmas Watershed). *Environmental and Water Engineering*, 2(4), 346-359. (in Farsi)
11. Deo, R. C., & Sahin, M. (2016). An Extreme Learning Machine Model for The Simulation of Monthly Mean Streamflow Water Level in Eastern Queensland, *Environmental Monitoring and Assessment*, 188(2).
12. Deo, R. C., & Sahin, M. (2015). Application of The Extreme Learning Machine Algorithm for the Prediction of Monthly Effective Drought Index in Eastern Australia, *Atmospheric Research*, 153, 512-525.
13. Eivazi, M., Mosaedi, A., & Dehghani, A. A. (2009). Comparison of Different Approaches for Predicting SPI. *Water and Soil Conservation*, 16(2), 145-167. (in Farsi)
14. Fallah Ghalhari, GH., Bayatani, A. F., & Fahiminezhad, E. (2015). Comparing the Forecasting Accuracy of the Box-Jenkins Models in Modeling Seasonal Precipitation (Case Study: The South of Kerman Province, Iran). *Applied Environmental and Biological Sciences*, 5(12) 64-78.
15. Farajzadeh. M. (2013). *Climatic Hazards in Iran*. Tehran, SAMT Press. (in Farsi)
16. Faris, H., Hassonah, M. A., Al-Zoubi, A. M., & Mirjalili, S. (2018). A Multi-Verse Optimizer Approach for Feature Selection and Optimizing SVM Parameters Based on A Robust System Architecture, *Neural Computing and Applications*, 30(8), 2355-2369.
17. Flood, I., & Kartam, N. (1994). Neural Networks in Civil Engineering I: Principles and Understanding. *Computing in Civil Engineering*, 8(2), 131-148.
18. Fung, K. F., Huang, Y. F., Koo, C. H., & Soh, Y. W. (2020). Drought Forecasting: A Review of Modelling Approaches 2007-2017, *Water and Climate Change*, 11(3), 771-799.
19. Haltiner, G. J., & Williams, R. T. (1989). *Numerical Prediction and Dynamic Eteorology*, 2nd Eddition. New York, Wiley & Sons.

20. Han, P., Wang, P. X., Zhang, S. Y., & Zhu, D. H. (2010). Drought Forecasting Based on the Remote Sensing Data Using ARIMA Models. *Mathematical and Computer Modelling*, 51, 1398-1403.
21. Hejazizadeh, Z., & Javizadeh, S. (2017). *Introduction to Drought and its Indicators*. Tehran, Samt Press. (in Farsi)
22. Hosseini-Moghari, S. M., & Araghinejad, Sh. (2016). Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e Kavous Station), *Water and Soil*, 30(1), 247-259. (in Farsi)
23. Huang, G., Huang, G. B., Song, S., & You, K. (2015). Trends in Extreme Learning Machines: A Review. *International Neural Network Society*, 61, 32-48.
24. Hyndman, R. J., & Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *Forecasting*, 22, 679-688.
25. Kardavani, P. (2001). *Drought and ways to deal with it in Iran*. Tehran, University of Tehran (In Farsi).
26. Kaur, A., & Sandeep, K. S. (2020). Deep Learning Based Drought Assessment and Prediction Framework, *Ecological Informatics*, 57(9).
27. Kaviani, M. R., & Alikhani, B. (2016). *Basics of meteorology*. Tehran, Samt Press. (in Farsi)
28. Khalili, K., Hesari, B. (2004). *Prediction of Drought Trend Using Time Series Statistical Models (Case Study of Urmia Synoptic Station)*. 1th Water Resources Management Conference, Tehran. (in Farsi)
29. Khorrami, M., A. Bozorgnia. 2007. *Analysis of Time Series with MINITAB Software 14*. Sokhan Gostar Publications, 336. (in Farsi)
30. Khosravi, I., Akhondzadeh, M., & Khoshgoftaar, M. (2015). Modeling and Predicting the Drought Indices Time Series Using Machine Learning Methods in Order to Managing Hazards (Case Study: Eastern District of Isfahan), *Environmental Management Hazards*, 2(1), 51-65. (in Farsi)
31. Kisi, O., Karahan, M., & Sen, Z. (2006). River Suspended Sediment Modeling Using Fuzzy Logic Approach. *Hydrological Processes*, 20(2), 4351-4362.
32. Malekian, A., Dehbozorgi, M., & Ehsani, A. H. (2015). Evaluation the Efficiency of Using Artificial Neural Networks in Predicting Meteorological Droughts in North-West of Iran. *Researches in Geographical Sciences*, 15(36), 139-156. (in Farsi)
33. Malekian, A., Dehbozorgi, M., Ehsani, A., & Keshtkar, A. (2014). Application of Artificial Neural Networks in Simulating and Forecasting of Meteorological Drought Decile Percentage Index (Case Study: Sistan & Balouchestan Province), *Range and Watershed Management*, 67(1), 127-139.
34. Masoumpour Samakosh, J., Jalilian, A., & Yari, E. (2016). The Analysis of Seasonal Precipitation Time Series in Iran. *Physical Geography Research*, 49(3), 457-475. (in Farsi)
35. Meteorological Organization of the Country. (2021). *Meteorological of Isfahan Province*, 26-149. (in Farsi)
36. Mirzaei, A. A., & Sabe, Gh. A. (2011). *Water Engineering Specialized Software*. Kian Academic Publication, Tehran, Iran. (in Farsi)
37. Mishra, A. K., & Desai, V. R. (2006). Drought Forecasting Using Feed-Forward Recursive Neural Network, *Ecological Modelling*, 198(1), 127-138.
38. Mishra, A. K., & Desai, V. R. (2005). Drought Forecasting Using Stochastic Models. *Stoch Environ Res Risk Assess*, 19(2), 326-339.

39. Moharrampour, M., Mehrabi, A., Hajikandi, H., Sohrabi, S., & Vakili, J. (2013). Comparison of Support Vector Machines (SVM) and Autoregressive Integrated Moving Average (ARIMA) in Daily Flow Forecasting. *River Engineering*, 1(1), 1–8.
40. Nazari Pouya, H., Khosroshahi, M. (2013). Determining the Most Appropriate Meteorological Drought Index for Evaluation of Drought in Hamedan Province, *Range and Desert Research*, 20(4), 625-633. (in Farsi)
41. Niromand, H., & Bozorgnia, S. A. (2002). *Introduction to Time Series Analysis (Edition 2)*. Translation. Ferdowsi University Press, Mashhad, Iran. (in Farsi)
42. Niromand, H., & Bozorgnia, S. A. (2011). *Time Series (Edition 5)*. Payam Noor University Press, Tehran. (in Farsi)
43. Nourani, V., Alami, M. T., & Aminfar, M. H. (2009). A Combined Neural-Wavelet Model for Prediction of Ligvanchai Watershed Precipitation. *Engineering Applications of Artificial Intelligence*, 22(2), 466–472.
44. Pahlavanravi, A., & Ghasemi, H. (2008). *Estimation of Wet and Drought Periods Using Z-Score Index in Zabol*, International Water Crisis Conference, Ministry of Science, Research and Technology, March 20-22, First Course, Zabol University.
45. Rahdan, H., Moradi, H. R., & Sharifi, K. M. (2015). *Comparison of the Efficiency of Some Meteorological Indicators to Determine the Drought in Isfahan*, 4th National Conference on Health, Environment and Sustainable Development, Islamic Azad University, Bandar Abbas Branch. (in Farsi)
46. Rostami, M., Pahlavanravi, A., & Moghaddamnia, A. (2016). Comparison of Artificial Neural Network Models and Adaptive Neuro-Fuzzy Inference System in Predicting the Drought Mond Basin of Fars Province. *Natural Environmental Hazards*, 4(6), 21-32. (in Farsi)
47. Rumelhart, D. E., & McClelland, J. L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, V. 1: Foundations. London, The MIT Press.
48. Saadati, S., Soltani, S., & eslamian, S. (2009). Statistical Analysis of Return Period of Drought Conditions in Isfahan Province Using the Standardized Precipitation Index, *Range and Watershed Management*, 62(2), 257-270. (in Farsi)
49. Sadeghian, M., Karami, H., & Mousavi, S. F. (2018). Selection of a Proper Model to Predict Monthly Drought in Semnan Using Weather Data and Linear and Nonlinear Models, *Water and Soil Science*, 21(4). (in Farsi)
50. Sánchez-Monedero, J., Salcedo-Sanz, S., Gutiérrez, P., Casanova-Mateo, C., & Hervás-Martínez, C. (2014). Simultaneous Modelling of Rainfall Occurrence and Amount Using a Hierarchical Nominal–Ordinal Support Vector Classifier, *Engineering Applications of Artificial Intelligence*, 34, 199–207.
51. Salas, J. D. (1980). *Applied Modeling of Hydrologic Time Series*: Water Resources Publication.
52. Shafiee, M., Champion, B., Ansari, H., & Sharifi, M. B. (2011). Stochastic Simulation of Drought Severity Based on Palmer Index, *Water and Irrigation Management*, 1(1), 1-13. (in Farsi)
53. Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., & Tyukov, A. P. (2013). A Survey of Forecast Error Measures. *World Applied Sciences*, 24, 171-176.

54. Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F. (2018). Application of Artificial Intelligence Models for The Prediction of Standardized Precipitation Evapotranspiration Index (SPEI) at Langat River Basin, Malaysia, *Computers and Electronics in Agriculture*, 144, 164–173.
55. Tarkhaneh. O., & Shen. H. (2019). Training of Feedforward Neural Networks for Data Classification Using Hybrid Particle Swarm Optimization, Mantegna Levy Flight and Neighborhood Search. *Helion*, 5, e01275.
56. Tokar, A. S., & Markus, M. (2000). Precipitation - Run off Modeling Using Artificial Neural Network and Conceptual Models. *Hydrologic Engineering*, 4(3), 156-161.
57. Torabipodeh, H., Dehghani, R., & Rostami, S. (2019). Estimation Drought in Lorestan Using Intelligent Networks. *Climate Research*, 1397(35), 41-52. (in Farsi)
58. Toufani, P., Mosaedi, A., & Fakhri Fard, A. (2010). Prediction of Precipitation Applying Wavelet Network Model (Case Study: Zarringol Station, Golestan Province, Iran). *Water and Soil (Agricultural Science and Technology)*, 5(25), 1217-1226. (in Farsi)
59. Vidyarthi, V. K., & Jain, A. (2020). Knowledge Extraction from Trained ANN Drought Classification Model. *Hydrology*, 585.
60. Wilhite, D. A., Rosenberg, N. J., & Glantz, M. H. (1986). Improving Federal Response to Drought, *Climate and Applied Meteorology*, 25, 332–342.
61. Yeh, H. F., & Hsu, H. L. (2019). Stochastic Model for Drought Forecasting in the Southern Taiwan Basin, *Water*, 11(10), 2041.
62. Younesi, M., Shahraki, N., Marofi, S., & Nozari, H. (2017). Drought Forecasting Using Artificial Wavelet Neural Network Integrated Model (WA-ANN) and Time Series Model (ARIMA), *Irrigation Sciences and Engineering*, 41(2), 167-181.