

**EXTENDED ABSTRACT**

**Evaluating the Performance of Time-Series, Neural Network and Neuro-Fuzzy Models in Prediction of Meteorological Drought (Case study: Semnan Synoptic Station)**

M. Sadeghian<sup>1</sup>, H. Karami<sup>2</sup> and S. F. Mousavi<sup>3\*</sup>

1- MSc., Faculty of Civil Engineering, Semnan University, Semnan, Iran.

2- Assistant Professor, Faculty of Civil Engineering, Semnan University, Semnan, Iran.

3\*- Corresponding Author, Professor, Faculty of Civil Engineering, Semnan University, Semnan, Iran ([fmousavi@semnan.ac.ir](mailto:fmousavi@semnan.ac.ir)).

Received: 25 April 2016

Revised: 2 October 2017

Accepted: 9 October 2017

**Keywords:** Prediction of drought, Time-series model, Artificial neural network (ANN), Adaptive neuro-fuzzy inference system (ANFIS), Semnan city.

**DOI:** 10.22055/jise.2017.17729.1283.

**Introduction**

Drought phenomenon is one of the natural and creeping disasters, which occurs in almost every climate and its properties vary spatially. A considerable number of scientific research has been done on drought in Iran and throughout the world. These studies have examined various aspects of drought. Through such research and knowledge effective and efficient solutions could be found to deal with good management of drought. Since Iran is located in an arid region of the world, nowhere in the country is immune from this phenomenon. This research has attempted to present appropriate models to predict drought for the city of Semnan, Iran.

**Methodology**

We used time series, artificial neural networks (ANNs), and adaptive neuro-fuzzy inference system (ANFIS) to predict drought for the city of Semnan. To show drought quantitatively, the SPI index was chosen, which was published in 1993 by McKee et al. (1993). For these modeling processes, meteorological parameters of average monthly rainfall (P), average monthly temperature (T), average monthly minimum temperature (Tmin), average monthly maximum temperature (Tmax), average monthly relative humidity (RH), average monthly minimum relative humidity (RHmin), average monthly maximum relative humidity (RHmax) and SPI drought index were used during the 1966-2013 period. The antecedent values of these parameters were also taken for modeling and were considered output in time t+1 for intelligent models of SPI. Prediction of drought was conducted in a six-month time scale. About 80% of the data was used in the training phase and 20% in the test phase. After reviewing past published research, modeling of time series by seasonal ARIMA model was performed. This model is an important practice and valid to simulate and predict climatic parameters. Another method is artificial neural network, which is one of the most dynamic fields of research in the contemporary era. In this study, two types of multilayer perceptron neural network (MLP) and radial basis function (RBF) neural network were applied. To perform modeling by ANFIS, Sugeno Fuzzy Systems and Gaussian and bell-shape membership functions were used, too. Besides, we considered subtractive clustering method for production rules and hybrid learning algorithm for training and educational courses (Epoch).

**Results and Discussion**

We reviewed all methods in modeling by different combinations of each input parameter. The results showed that the time series model had better performance with respect to other methods. ANFIS and ANN models ranked next. Finally, ARIMA(1,0,0)(1,0,1)<sub>6</sub> model was selected as the

best model and RMSE, MAE, R and Akaike criterion of 0.442, 0.341, 0.889 and -562.83, respectively, at training stage, and RMSE, MAE and R of 0.521, 0.385 and 0.846, respectively, at testing stage were obtained. Among the input parameters, the SPI drought index and its previous values had better performance.

By employing this model, the SPI values were predicted for the next 12 steps. Comparison of neural networks showed that feed-forward neural networks with back propagation algorithm (MLP) had more suitable performance than the radial basis function (RBF). MLP model with five parameters, SPI drought index of the present month and previous 4 time lags, 10 neurons in the hidden layer with sigmoid function had good performance in both training and testing phases. Also, as was expected from the reviewed research, adaptive neural fuzzy inference system (ANFIS) had more suitable performance with respect to neural network model. It was consistent with other research such as Bacanli et al. (2008), Komasi et al. (2012) and Shirmohammadi et al. (2013). Finally, modeling by ANFIS with five parameters, SPI drought index of this month and amounts of the previous 4 time lags and bell-shape membership functions were selected because they showed better performance in both training and testing compared to other models.

### Conclusion

Based on the results, SPI and its previous values had better performance and precipitation had weaker performance. Among all the models, the ARIMA(1,0,0)(1,0,1)<sub>6</sub> model was selected as the best model by fitting the SPI values with least RMSE (0.442 at training stage and 0.521 at test stage), and best R<sup>2</sup> at training stage (0.899) and at test stage (0.846). By using this model, the SPI values for the next 12 stages were predicted. The ANFIS model with RMSE=0.513, MAE=0.377 and correlation coefficient (R) of 0.861 at training stage and RMSE=0.518, MAE=0.41 and R=0.841 at test stage, ranked first and ANN model with RMSE=0.534, MAE=0.393 and R=0.85 at training stage and RMSE=0.532, MAE=0.402 and R=0.837 at test stage ranked next.

### Acknowledgement

The authors would like to thank Semnan University for supporting this research.

### References

- 1- Bacanli, U., Firat, M., and Dikbas, F., 2008. Adaptive neuro-fuzzy inference system (ANFIS) for drought forecasting. *Stochastic Environmental Research and Risk Assessment*, 23(8), pp. 1143-1154.
- 2- Komasi, M., Alami, M. T., and Nourani, V., 2012. Drought forecasting by SPI index and ANFIS model using fuzzy C-mean clustering. *Journal of Water and Wastewater*, 4, pp. 90-102. (In Persian).
- 3- McKee, T.B., Doesken, N.J., and Kleist, J., 1993. The relationship of drought frequency and duration to time scales. *8<sup>th</sup> Conference on Applied Climatology*, 17-22 Jan., Anaheim, California, pp. 379-384.
- 4- Shirmohammadi, B., Moradi, H.R., Moosavi, V., Taie Semiromi, M., and Zeinali, A., 2013. Forecasting of meteorological drought using wavelet-ANFIS hybrid model for different time steps (Case study: Southeastern part of east Azerbaijan province, Iran). *Journal of Natural Hazards*, 69, pp. 389-402.



© 2020 by the authors. Licensee SCU, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>).



## ارزیابی عملکرد مدل‌های سری زمانی، شبکه عصبی و سیستم استنتاج عصبی - فازی در پیش‌بینی خشکسالی هواشناسی (مطالعه موردی: ایستگاه سینوپتیک سمنان)

مریم صادقیان<sup>۱</sup>، حجت کرمی<sup>۲</sup> و سید فرهاد موسوی<sup>۳\*</sup>

۱- کارشناس ارشد، دانشکده مهندسی عمران، دانشگاه سمنان.

۲- استادیار، دانشکده مهندسی عمران، دانشگاه سمنان.

۳- نویسنده مسئول، استاد، دانشکده مهندسی عمران، دانشگاه سمنان fmousavi@semnan.ac.ir

پذیرش: ۱۳۹۶/۷/۱۷

بازنگری: ۱۳۹۶/۷/۱۰

دریافت: ۱۳۹۵/۲/۶

### چکیده

خشکسالی به‌عنوان یک بلای طبیعی نامحسوس تقریباً در تمامی اقلیم‌ها رخ می‌دهد و مشخصات آن از یک منطقه به منطقه دیگر متفاوت است. با توجه به نوسانات بیشتر در مقادیر بارندگی در بخش‌های جنوبی، شرقی و مرکزی ایران و در نتیجه آسیب‌پذیری بیشتر آن‌ها نسبت به پدیده خشکسالی، هدف اصلی این تحقیق یافتن مناسب‌ترین روش برای پیش‌بینی خشکسالی شهر سمنان می‌باشد. در پژوهش حاضر، با استفاده از روش‌های سری‌های زمانی، شبکه عصبی مصنوعی (ANN) و سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) سعی شده تا مدل‌های مناسب برای پیش‌بینی خشکسالی شهر سمنان ارائه گردد. در این مدل سازی‌ها از داده‌های میانگین ماهانه شامل بارندگی، دما، حداکثر و حداقل دما، رطوبت نسبی، حداکثر و حداقل رطوبت نسبی و شاخص خشکسالی SPI طی دوره آماری ۱۹۶۶ تا ۲۰۱۳ استفاده شده است. براساس نتایج، SPI و مقادیر پیشین آن نسبت به بارش عملکرد مناسب‌تری را داشت. با بررسی تمامی مدل‌ها، مدل  $(1,0,1)(1,0,1)$  با  $ARIMA(+,0,1)$  با برازش مناسب داده‌های SPI با کمترین مقدار جذر میانگین مربعات خطا (RMSE برابر  $0.442$  در مرحله آموزش و  $0.521$  در مرحله آزمون) و مناسب‌ترین ضریب همبستگی (R) برابر  $0.889$  در مرحله آموزش و  $0.846$  در مرحله آزمون) به‌عنوان مدل برتر انتخاب شد. با استفاده از این مدل، مقادیر SPI برای ۱۲ گام زمانی بعدی پیش‌بینی گردید. مدل ANFIS با مقادیر  $RMSE=0.513$ ،  $MAE=0.377$  و ضریب همبستگی (R) برابر  $0.861$  در مرحله آموزش و  $0.818$ ،  $RMSE=0.41$ ،  $MAE=0.41$  در مرحله آزمون و ANN با مقادیر  $RMSE=0.534$ ،  $MAE=0.393$  و  $R=0.85$  در مرحله آموزش و  $0.532$ ،  $MAE=0.402$ ،  $R=0.837$  در مرحله آزمون به‌ترتیب در رتبه‌های بعدی قرار گرفتند.

**کلید واژه‌ها:** پیش‌بینی خشکسالی، مدل سری زمانی، شبکه عصبی، سیستم‌های استنتاج عصبی - فازی تطبیقی.

کافی از این رخداد طبیعی، بتوان گام‌های مؤثر و کارآمدی در جهت مدیریت صحیح آن برداشت.

Mishra و Desai (2006) از مدل‌های آماری خطی (Seasonal Auto Regressive Integrated Moving Average / Auto Regressive Integrated Moving Average) و شبکه‌های عصبی مصنوعی (Artificial Neural Networks) و شبکه‌های (RMSNN/DMSNN) برای پیش‌بینی خشکسالی در حوضه رودخانه‌ی کانساباتی در غرب بنگال هند استفاده کردند (Mishra and Desai, 2006). آن‌ها برتری ANN نسبت به مدل‌های آماری را بیان نمودند. Eivazi et al. (2009) به پیش‌بینی خشکسالی در ایستگاه باران‌سنجی نوده با استفاده از آمار بارندگی و روش‌های سری زمانی (Time Series) (ARIMA/SARIMA) و شبکه عصبی (Radial Basis و Multi-Layer Perceptron)

### مقدمه

خشکسالی یکی از بلاهای طبیعی است که خسارات زیادی در زندگی انسان‌ها و اکوسیستم‌های طبیعی به‌وجود می‌آورد. به‌عنوان یک ناهنجاری اقلیمی، یکی از مخرب‌ترین پدیده‌های آب و هوایی محسوب می‌گردد و تقریباً در همه رژیم‌های اقلیمی نیز دیده می‌شود. بررسی پژوهش‌های علمی نشان‌دهنده تعدد تحقیقات انجام‌شده در زمینه خشکسالی در جهان و ایران می‌باشد. این تحقیقات جنبه‌های گوناگونی از خشکسالی را مورد بررسی قرار داده‌اند، زیرا وقوع خشکسالی در مناطق مختلف، متفاوت می‌باشد. در سال‌های اخیر نیز تحقیقات بسیاری در ارتباط با پیش‌بینی خشکسالی‌ها در ایران و سایر نقاط جهان صورت گرفته است، تا به واسطه این تحقیقات و در دست داشتن اطلاعات

موجک در ساخت مدل‌های ترکیبی Wavelet-ANN و Wavelet-ANFIS به ارزیابی این مدل‌ها در پیش‌بینی خشک‌سالی پرداختند. نتایج نشان داد که استفاده از تبدیل موجک در پردازش داده‌های ورودی عملکرد مدل‌ها را بهبود بخشیده و در نهایت مدل Wavelet-ANFIS بهترین عملکرد را نسبت به مدل‌های دیگر داشت.

با توجه به قرار گرفتن ایران در کمربند خشک و نیمه‌خشک دنیا، هیچ منطقه‌ای در کشور از این پدیده در امان نیست و به نسبت موقعیت طبیعی خود اثر این پدیده مخرب را تجربه می‌کند. در این تحقیق، سعی بر آن است که با استفاده از اطلاعات موجود هواشناسی، سیستم‌های پیش‌بینی خشک‌سالی، مدل‌ها و الگوهای خطی و غیرخطی سری‌های زمانی، شبکه‌های عصبی مصنوعی و سیستم استنتاجی فازی-عصبی تطبیقی، مدل مناسبی برای پیش‌بینی خشک‌سالی هواشناسی در شهر سمنان ارائه گردد. در راستای این تحقیق و با توجه به بررسی‌های به‌عمل آمده در منابع موجود، این چنین استناد می‌شود که در این زمینه تحقیق به‌خصوصی که همه روش‌هایی که در ابتدا به آن‌ها اشاره گردید را در برگیرد، صورت نپذیرفته است.

## مواد و روش‌ها

### محدوده مورد مطالعه

شهر سمنان، مرکز استان سمنان و نیز مرکز شهرستان سمنان می‌باشد. این شهر در جنوب رشته‌کوه البرز و شمال دشت کویر قرار گرفته است و آب‌وهوای آن خشک و معتدل است.

پرداختند. نتایج بیانگر ارجحیت شبکه عصبی (MLP) می‌باشد. Bacanlı et al. (2008) از سیستم استنتاج فازی-عصبی تطبیقی (Adaptive Neuro-Fuzzy Inference System) به منظور پیش‌بینی خشک‌سالی در کشور ترکیه استفاده نمودند. نتایج نشان داد که ترکیب مقادیر پیشین بارندگی و شاخص SPI بایکدیگر، بهبود عملکرد مدل‌ها را به همراه دارد. مقایسه‌ها انجام گرفته با نتایج روش‌های شبکه‌های عصبی (Feed Forward Neural Networks) و رگرسیون خطی چندگانه (Multiple Linear Regression)، حاکی از ارجحیت مدل ANFIS نسبت به دو مدل دیگر بود. Aramesh و Negaresh (2011) پیش‌بینی خشک‌سالی شهر خاش را با استفاده از عناصر اقلیمی بارش، نم‌نسبی، دما و شاخص‌های اقلیمی مؤثر بر خشک‌سالی منطقه و مدل‌های شبکه عصبی و رگرسیونی برای سه دوره زمانی ماهانه، سه ماهه و یک‌ساله بررسی نمودند. از بین انبوه مدل‌ها، در مجموع، پیش‌بینی سه ماهه خشک‌سالی با مدل ANN (پس‌انتشار) بهترین عملکرد را دارا بود. همچنین، نتایج نشان داد که شاخص‌های اقلیمی در پیش‌بینی ماهانه خشک‌سالی تأثیری در بهبود عملکرد مدل‌ها ندارد. Komasi et al. (2012) در حوضه ليقوان‌چای با استفاده از آمار بارندگی ایستگاه ليقوان و ANN، مدل‌سازی ANFIS بدون خوشه‌بندی (C-mean) و ANFIS بر مبنای خوشه‌بندی خشک‌سالی را پیش‌بینی کردند. در نهایت، مدل ANFIS بر مبنای خوشه‌بندی به‌عنوان بهترین مدل معرفی شد. Shirmohammadi et al. (2013) با استفاده از آمار بارش ایستگاه عجب‌شیر و مدل‌های ANFIS، ANN و کاربرد تبدیل

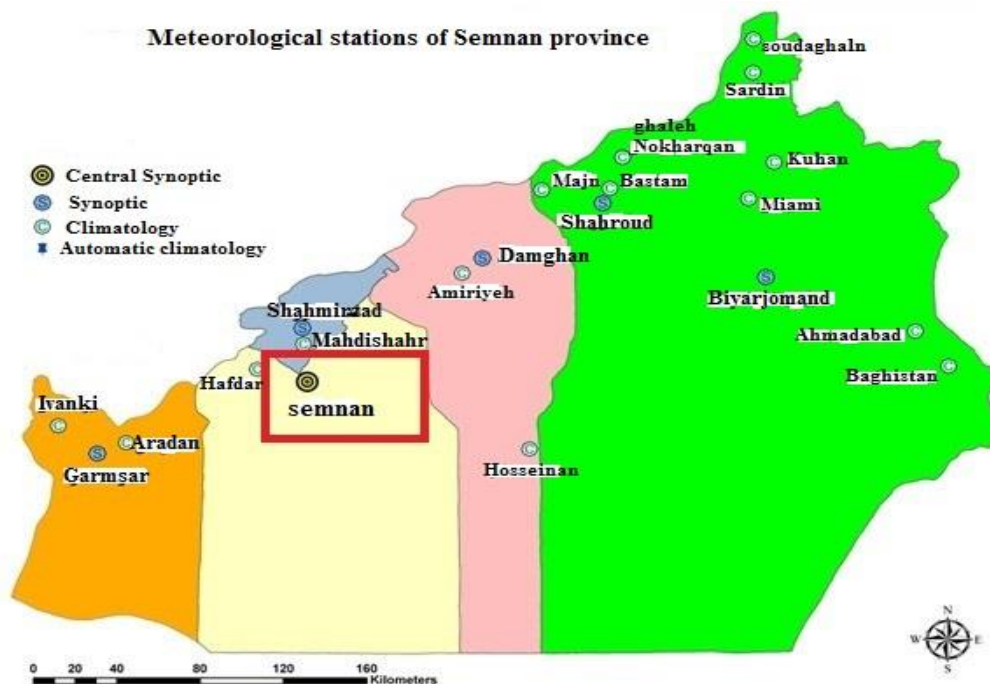


Fig. 1- Location of meteorological stations in Semnan province (Anonymous, 2014)

شکل ۱- موقعیت ایستگاه‌های هواشناسی استان سمنان (Anonymous, 2014)

داده‌ها و عدم وجود روند در آنها استفاده شده است (Mahdavi, 2006). براساس این آزمون‌ها صحت داده‌ها تأیید گردید. با توجه به این امر که اغلب بارش‌ها در شهر سمنان نیز همانند اکثر نقاط ایران در فصول سرد سال و اوایل بهار رخ می‌دهد که معمولاً یک دوره شش ماهه را در بر می‌گیرد، در این تحقیق نیز به بررسی خشک‌سالی در مقیاس زمانی شش ماهه پرداخته شده است.

### شاخص بارش استاندارد SPI

شاخص خشک‌سالی مد نظر، شاخص بارش استاندارد (SPI) در سال ۱۹۹۳ توسط McKee et al. (1993) ارائه شد. این شاخص براساس تفاوت بارش از میانگین برای یک مقیاس زمانی مشخص و سپس تقسیم آن بر انحراف معیار به دست می‌آید و تنها فاکتور مؤثر در محاسبه آن عنصر بارندگی می‌باشد. این شاخص را می‌توان در مقیاس‌های زمانی کوتاه‌مدت و بلندمدت محاسبه کرد. شاخص SPI از رابطه (۱) به دست می‌آید:

$$SPI = \frac{P_i - \bar{P}}{S} \quad (1)$$

که  $P_i$  مقدار بارش در دوره مورد نظر،  $\bar{P}$  میانگین درازمدت بارش برای دوره مورد نظر و  $S$  انحراف معیار مقدار بارش می‌باشند. مقادیر شاخص SPI که بدین گونه برای یک دوره زمانی مورد نظر به دست می‌آید، از توزیع نرمال با میانگین صفر و انحراف معیار یک تبعیت می‌کند. برای محاسبه این شاخص، ابتدا از توزیع گاما برای برازش داده‌های بلندمدت بارش استفاده می‌شود. سپس محاسبه و تعیین پارامترهای مربوط به SPI انجام می‌گیرد. محاسبه SPI شامل برازش تابع چگالی احتمال گاما بر توزیع فراوانی بارندگی می‌باشد. طبقه‌بندی ارزیابی شاخص SPI در جدول (۱) آورده شده است.

اقلیم غالب استان، به جز باریکه‌ای از مرز کوهستانی در شمال آن و در مجاورت استان‌های گلستان، مازنداران و تهران، خشک است. آب‌وهوای شهرستان سمنان در تابستان گرم و در زمستان نسبتاً سرد می‌باشد و بارندگی‌های این شهر معمولاً در فصول سرد سال صورت می‌گیرد (Anonymous, 2014).

در تحقیق حاضر، آمار و اطلاعات هواشناسی موجود در ایستگاه سینوپتیک شهرستان سمنان اخذ گردیده است. ایستگاه سینوپتیک شهرستان سمنان در سال ۱۳۴۴ (۱۹۶۵ میلادی) تأسیس شده است. این ایستگاه در عرض جغرافیایی ۳۵ درجه و ۳۵ دقیقه شمالی و طول جغرافیایی ۳۵ درجه و ۳۳ دقیقه شرقی قرار گرفته است. ارتفاع این ایستگاه از سطح دریا ۱۱۳۰/۸ متر است. موقعیت ایستگاه هواشناسی شهر سمنان در شکل ۱ نمایش داده شده است (Anonymous, 2014).

پارامترهای مورد استفاده در این تحقیق شامل دو بخش می‌باشند. بخش اول، آمار و اطلاعات هواشناسی و دیگری شاخص خشک‌سالی بارش استاندارد (Standardized Precipitation Index) که پس از بررسی چندین شاخص خشک‌سالی به عنوان شاخص برتر در تعیین درجه خشکی انتخاب شده است. این متغیرها شامل میانگین بارندگی ماهانه (P)، میانگین دمای ماهانه (T)، میانگین حداقل دمای ماهانه (T<sub>min</sub>)، میانگین حداکثر دمای ماهانه (T<sub>max</sub>)، میانگین رطوبت نسبی ماهانه (RH)، میانگین حداقل رطوبت نسبی ماهانه (RH<sub>min</sub>)، میانگین حداکثر رطوبت نسبی ماهانه (RH<sub>max</sub>) در زمان حال و تا سه تأخیر زمانی پیشین و شاخص خشک‌سالی SPI در زمان حال و تا چهار تأخیر زمانی پیشین می‌باشند. هر کدام از این متغیرها دوره‌ی آماری ۴۷ ساله (۲۰۱۳-۱۹۶۶) را تشکیل می‌دهند. جهت بررسی صحت و سقم داده‌های مورد استفاده، از آزمون ناپارامتریک اسپیرمن (Spearman) برای تعیین استقلال و روند داده‌ها و همچنین آزمون دنباله‌ها (Runs test) برای بررسی تصادفی و همگن بودن

جدول ۱- تقسیم‌بندی ارزیابی شاخص بارش استاندارد (Mishra and Desai, 2006)  
Table 1- Classification of Standardized Precipitation Index evaluation  
(Mishra and Desai, 2006)

| Drought situation   | Index SPI    |
|---------------------|--------------|
| Very severe drought | >-2          |
| Severe drought      | -1.99 - -1.5 |
| Middle drought      | 1.49 - -1-   |
| Weak drought        | 0.99 - 0 -   |
| normal              | .            |
| Weak Wet            | 0 -0.99      |
| Middle Wet          | 1 - 1.49     |
| Severe Wet          | 1.5 - 1.99   |
| Very severe Wet     | <2           |

### مدل سازی SPI

به منظور پیش‌بینی شاخص خشک سالی هواشناسی، اقدام به مدل‌سازی (الگوسازی) آن با سه روش سری زمانی، ANN و ANFIS گردید. در ذیل به توضیح هر یک از روش‌ها پرداخته می‌شود.

### مدل سری زمانی

مهم‌ترین هدف از تحلیل سری زمانی، پیش‌بینی مقادیر آینده آن است. معمولاً برای تحلیل یک سری زمانی، تغییراتی که نتیجه چهار مؤلفه روند، تغییرات فصلی، دوره‌ای و نامنظم (تصادفی) می‌باشد، در نظر گرفته می‌شوند. مراحل ساخت مدل‌های سری زمانی شامل آماده‌سازی داده‌ها، شناسایی مدل، برازش مدل و تشخیص اعتبار مدل می‌باشند (Karamooz and Araghinezhad, 2010). مراحل فوق با استفاده از دو نرم‌افزار EViews7 و Minitab16 انجام شده است. برای بررسی ایستایی سری زمانی مد نظر از نرم‌افزار EViews استفاده شده است. پس از تأیید ایستایی سری، با توجه به این امر که سری‌های زمانی بر مبنای پیروی داده‌ها از توزیع احتمالاتی نرمال بنا نهاده شده‌اند، از نمودار احتمال برای آزمون نرمال بودن توزیع داده‌ها استفاده شد. برای آماده‌سازی داده‌ها سری زمانی در نرم‌افزار Minitab رسم شده و مؤلفه‌های روند، دوره‌ای، تناوبی و تصادفی در سری بررسی گردید. سپس، فرم اولیه مدل تعیین می‌گردد. طی بررسی تحقیقات گذشته، محققین به منظور تحلیل تغییرات پارامترهای اقلیمی تلاش نموده‌اند تا این پارامترها را ابتدا مدل‌سازی و سپس پیش‌بینی کنند. بر این اساس مدل‌سازی در خانواده‌ی آرما، آریمای فصلی از شیوه‌های مهم و معتبر در مدل‌سازی و پیش‌بینی پارامترهای اقلیمی می‌باشند (Box et al., 2002).

فرم کلی مدل‌های ARIMA که قابلیت مدل‌سازی برخی از سری‌های زمانی ناپایستا را با تفاضلی کردن سری مورد نظر دارند به صورت رابطه (۲) می‌باشند (Karamooz and Araghinezhad, 2010 و Box et al., 2002):

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

که در آن  $Z_t$  یک فرایند گسسته تصادفی محض و  $X_t$  یک فرایند خودهمبسته مرتبه  $P$  می‌باشند و چندجمله‌ای‌های مرتبه  $p$  و  $q$  به صورت زیر است:

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (3)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (4)$$

در روابط فوق،  $p$  درجه اتورگرسیون،  $d$  درجه تفاضل‌گیری،  $q$  درجه میانگین متحرک،  $\varphi_1, \dots, \varphi_p$  ضرایب خودهمبسته از درجه  $p$ ،  $\theta_1, \dots, \theta_q$  ضرایب میانگین متحرک از درجه  $q$  و متغیر  $B$  عملگر پس‌رو می‌باشد.

در صورت وجود اثر فصلی، مدل‌های فصلی SARIMA گروه دیگری از مدل‌های احتمالاتی هستند که در سری‌های زمانی مورد استفاده قرار می‌گیرند. در این مدل‌ها که به صورت مدل‌های  $\varphi(B)\nabla_s^D \nabla^d X_t = \theta(B)Z_t$  (ARIMA(p,d,q)(P,D,Q)) معرفی می‌شوند، برای بررسی فرایندهای ناپایستا، امکان تفاضلی کردن فصلی ایجاد می‌کنند. این مدل‌ها از رابطه (۵) پیروی می‌کنند (Box et al., 2002 و Shumway and Stoffer, 2006):

$$\Phi_p(B^s)\varphi_p(B)\nabla_s^D \nabla^d X_t = \Theta_q(B^s)\theta_q(B)Z_t \quad (5)$$

در این رابطه،  $p$  درجه اتورگرسیون غیرفصلی،  $d$  درجه تفاضل‌گیری،  $q$  درجه میانگین متحرک غیرفصلی و  $P$  درجه اتورگرسیون فصلی،  $D$  درجه تفاضل‌گیری فصلی،  $Q$  درجه میانگین متحرک فصلی،  $\Phi$  پارامتر اتورگرسیون فصلی از مرتبه  $p$ ،  $\Theta$  پارامتر میانگین متحرک فصلی از مرتبه  $q$  و  $s$  طول دوره فصلی می‌باشند. همچنین، در معادله فوق، چندجمله‌ای‌های مرتبه  $P$  و  $Q$  به صورت زیر است:

$$\Phi(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps} \quad (6)$$

$$\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_q B^{qs} \quad (7)$$

برای بررسی توانایی و کیفیت مدل آزمون‌های استقلال زمانی، نرمال بودن باقی‌مانده‌ها و ایستایی بودن پارامترهای برآورد شده روی فرضیه‌های مدل، مقایسه نمودار همبستگی نگار مدل با همبستگی نگار سری مشاهداتی و از معیار اطلاعات آکاییک (AIC) به منظور آزمون استفاده شده است (Karamooz and Araghinezhad, 2010).

### مدل ANN

در این تحقیق، از دو نوع شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی تابع پایه شعاعی (RBF) استفاده شده است.

شبکه‌های MLP دارای سه لایه به نام‌های لایه ورودی، لایه یا لایه‌های میانی (پنهان) و لایه خروجی می‌باشند که تعداد لایه‌های پنهان محدودیتی ندارد. در این روش، مجموع ورودی‌های وزن‌دار شده (ورودی خالص) از طریق یک تابع محرک به مقدار خروجی تبدیل می‌شوند. در لایه خروجی می‌توان از یک تابع خطی (Pureline) استفاده نمود. اما کاربرد این تابع در لایه پنهان پیشنهاد نمی‌شود. به این دلیل که کارایی شبکه کاهش یافته و قادر به حل مسائل غیرخطی نخواهد بود. از آنجا که اکثر مسائل در دنیای واقعی غیرخطی می‌باشند، لازم است در لایه‌های پنهان از توابع غیرخطی استفاده گردد. توابع سیگموئیدی (LogSig) و تانژانت هیپربولیک (TanSig) از رایج‌ترین توابع محرک غیرخطی به شمار می‌روند (Kamruzzaman et al., 2006). در این تحقیق در مدل‌های ساخته شده کارایی هر دو تابع مزبور در لایه

**مدل ANFIS**

اولین بار جانگ در سال ۱۹۹۳ توانست از قدرت زبانی سیستم‌های فازی و آموزش شبکه‌های عصبی استفاده نماید و ANFIS را ارائه نماید (Jang, 1993). ANFIS یک شبکه پیش‌خور چندلایه می‌باشد. که از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور ترسیم یک فضای ورودی به یک فضای خروجی استفاده می‌کند. اگر یک سیستم استنتاجی با دو ورودی  $x$  و  $y$  و یک خروجی  $z$  در نظر گرفته شود. برای یک مدل فازی تاکاگی-سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر-آن‌گاه فازی به صورت روابط زیر بیان نمود (Jang, 1993):

- اگر  $x$  برابر  $A_1$  و  $y$  برابر  $B_1$  باشد آن‌گاه:

$$z_1 = p_1 A_1 + q_1 B_1 + r_1 \quad (9)$$

- اگر  $x$  برابر  $A_2$  و  $y$  برابر  $B_2$  باشد آن‌گاه:

$$z_2 = p_2 A_2 + q_2 B_2 + r_2 \quad (10)$$

که در این قوانین،  $p_i, q_i, r_i$  برای  $i=1,2,\dots$  پارامترهای خطی در بخش تالی مدل فازی تاکاگی-سوگنو درجه اول هستند. ساختار ANFIS شامل پنج لایه می‌شود که در شکل (۲) نشان داده شده است (Dibike et al., 1999).

برای انجام مدل‌سازی‌ها با استفاده از سیستم‌های استنتاج عصبی-فازی تطبیقی از جعبه‌ابزار ANFIS در نرم‌افزار MATLAB استفاده شده است. در این روش نیز همانند روش شبکه عصبی، ابتدا داده‌ها با رابطه ۸ نرمال‌سازی شده و سپس به‌عنوان پارامترهای ورودی و خروجی در مدل‌ها استفاده گردیدند. در این پژوهش، جهت مدل‌سازی از سیستم فازی سوگنو و توابع عضویت (Membership Functions) ناقوسی و گوسی استفاده شده است.

پنهان بررسی گردیده است. در روش‌های یادگیری شبکه‌های چندلایه پیش‌خور بر پایه الگوریتم یادگیری پس‌انتشار خطا (BP) سه تابع یادگیری وجود دارند. تابع مارکوارت-لونبرگ نسبت به سایر توابع سریع‌تر بوده و جزو تکنیک‌های استاندارد بهینه‌سازی عددی محسوب می‌گردد (Negareh and Aramesh, 2011). مدل‌سازی‌ها با استفاده از جعبه‌ابزار نرم‌افزار MATLAB R2013a انجام گردید. برای متغیرهای ورودی با ترکیب‌های مختلف متغیرهای ذکر شده، تعداد بسیار زیادی مدل ساخته شد. در همه ترکیب‌ها، هر دو تابع لگاریتم سیگموئید و تانژانت هیپربولیک با تعداد نرون‌های متفاوت در لایه پنهان از ۲ تا ۳۰ نرون استفاده شد.

شبکه‌های تابع پایه شعاعی (RBF) از نوع شبکه‌های رو به جلو همراه با یک لایه میانی هستند. در این شبکه‌ها، معمولاً تابع محرک در لایه میانی، تابع گوسی (Gaussian) و در لایه خروجی تابع خطی می‌باشد (Dibike et al., 1999). تعداد زیادی مدل با شبکه RBF برای ترکیب‌های مختلفی از متغیرها، به‌عنوان ورودی و ثابت-های گسترش (Spread constants) متفاوت ساخته شدند. سپس با استفاده از مدل‌سازی بهترین مدل RBF با کمترین میزان خطا به-دست می‌آید. به‌منظور آماده‌سازی داده‌ها برای جلوگیری از عدم دقت و کاهش سرعت شبکه مدل‌سازی، داده‌ها با استفاده از رابطه (۸) نرمال‌سازی شده است (Aghajani, 2014):

$$x_n = 0.05 + 0.95 \left( \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \quad (8)$$

که در آن  $x$  معرف داده‌های مشاهداتی،  $x_{\max}$  و  $x_{\min}$  به‌ترتیب حداقل و حداکثر داده‌ها و  $x_n$  نیز داده نرمال شده می‌باشد. چون برای ورودی‌های نزدیک به صفر و یا یک، تغییرات وزن نرون‌ها حداقل خواهد بود و عناصر پردازش‌گر کند عمل می‌کنند، بدین منظور، داده‌ها طبق فرمول بین ۰/۰۵ و ۰/۹۵ قرار داده می‌شوند.

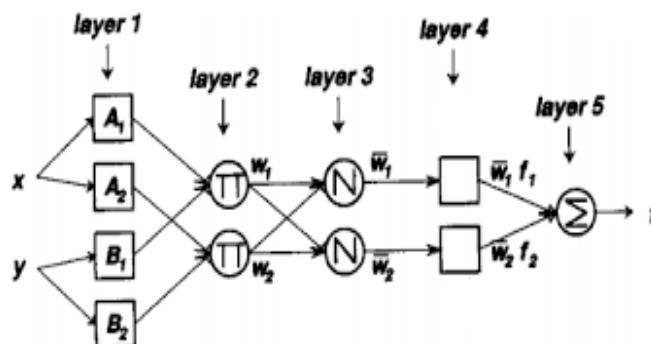


Fig. 2- An example of ANFIS structure (Jang, 1993)  
شکل ۲- نمونه‌ای از ساختار ANFIS (Jang, 1993)

در روابط فوق،  $x_i^o$  مقادیر مشاهداتی،  $x_i^p$  مقادیر پیش‌بینی شده،  $\bar{x}_i^o$  میانگین مقادیر مشاهداتی و  $\bar{x}_i^p$  میانگین مقادیر پیش‌بینی شده می‌باشند. هرچه مقادیر RMSE و MAE به صفر نزدیک‌تر باشد نشان‌دهنده عملکرد بهتر مدل است. مقادیر ضریب همبستگی بین ۱- و ۱ متغیر است.

**نتایج و بحث**

**الف- مدل‌سازی سری زمانی**

مدل‌سازی شاخص خشک‌سالی استاندارد بارش شش‌ماهه ( $SPI_6$ ) با مدل  $ARIMA(p,d,q)(P,D,Q)$  صورت گرفت. پس از تأیید ایستایی، پیروی سری زمانی از توزیع نرمال مورد بررسی گرفت. با توجه به شکل (۳) و مقدار  $P\text{-value}=0.080$  که بزرگ‌تر از  $0.05$  می‌باشد، سری از توزیع نرمال پیروی می‌کند. پس از رسم سری مورد نظر که در شکل (۴) آورده شده است، وجود مؤلفه روند در سری بررسی گردید که در شکل (۵) نشان داده شده است. معادله رگرسیون روند خطی سری مد نظر  $SPI_6=0.00183t-0.342$  و  $P\text{-value}$  مربوط به ضریب رگرسیون خطی  $0.194$  می‌باشد و نشان می‌دهد که شیب این خط رگرسیونی در سطح  $5\%$  معنی‌دار نمی‌باشد. برای تعیین بهترین مدل، پارامترهای  $p, q, P$  و  $Q$  از مرتبه صفر تا  $5$  و به علت ایستایی سری پارامتر  $d$  از مرتبه صفر در نظر گرفته شدند. پارامتر  $D$  نیز یک مرتبه تفاضلی گردید که با توجه به نمودارهای خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) مدل و مقایسه آن با نمودارهای ACF و PACF سری زمانی مشاهده‌ای و خروج مقادیر از محدوده اطمینان در نمودارهای مدل، از آن صرف‌نظر شد. همچنین، جهت ارزیابی مدل‌های اولیه نیز از نمودارهای ACF و مقایسه ACF با نمودار ACF سری زمانی مشاهده‌ای استفاده شده است. با توجه به حجم زیاد مدل‌ها، نتایج ارزیابی و مقادیر خطای برخی از مدل‌های برتر در جدول (۲) آورده شده است.

روش تولید قوانین کلاسترینگ کاهشی، الگوریتم آموزشی Hybrid برای آموزش؛ و تعداد دوره‌های آموزش (Epoch) برابر  $200$  عدد در نظر گرفته شد.

**روش اعتبار سنجی**

در مدل‌سازی دو روش ANN و ANFIS، شامل پارامترهای ورودی هواشناسی، شاخص خشک‌سالی  $SPI(t)$  و مقادیر پیشین آن‌ها در مقیاس زمانی شش‌ماهه (میانگین متحرک شش‌ماهه) به کار رفته است. خروجی مدل‌های مزبور نیز شامل شاخص خشک‌سالی  $SPI$  با گام زمانی بعدی  $SPI(t+1)$  می‌باشد. در مدل‌سازی سری زمانی شاخص خشک‌سالی  $SPI$  در مقیاس زمانی شش‌ماهه تشکیل شد. مقدار  $0.80$  داده‌ها ( $463$  عدد) در مرحله آموزش و  $0.20$  آن‌ها ( $108$  عدد) در مرحله آزمون استفاده گردیدند. در تمامی مدل‌سازی‌ها، جهت ارزیابی و تحلیل نتایج، از ملاک‌های جذر میانگین مربعات خطاها (RMSE)، میانگین مطلق خطاها (MAE) و ضریب همبستگی (R) (به ترتیب روابط ۱۱، ۱۲ و ۱۳) استفاده گردید (McKee et al., و Dibike et al., 1999):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^o - x_i^p)^2} \tag{11}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i^o - x_i^p| \tag{12}$$

$$R = \frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2 \sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \tag{13}$$

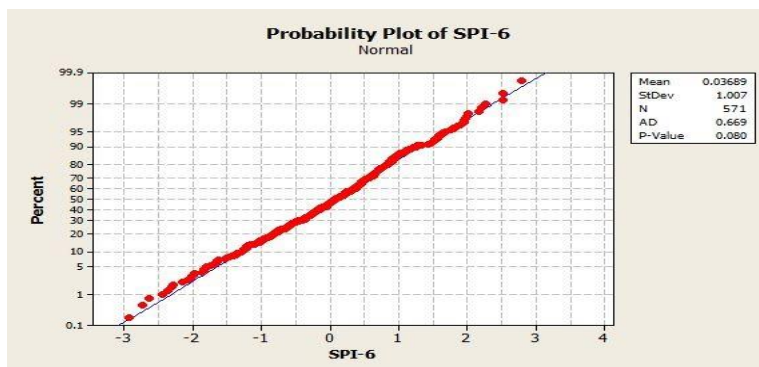


Fig. 3- Probability diagram of the normal distribution of the 6SPI time series

شکل ۳- نمودار احتمالاتی توزیع نرمال سری زمانی  $SPI_6$



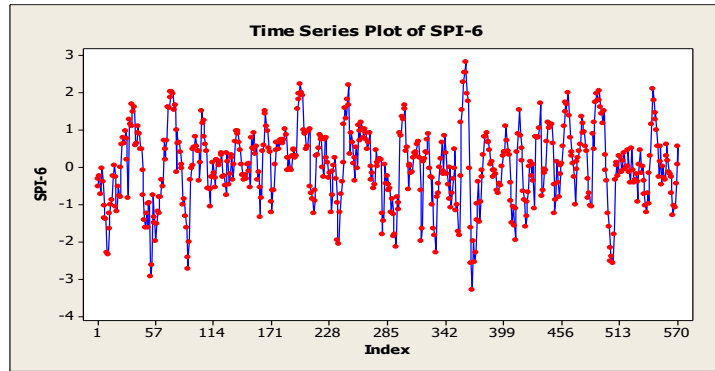


Fig. 4- Time series diagram of drought index SPI<sub>6</sub>  
 شکل ۴- نمودار سری زمانی شاخص خشک سالی SPI<sub>6</sub>

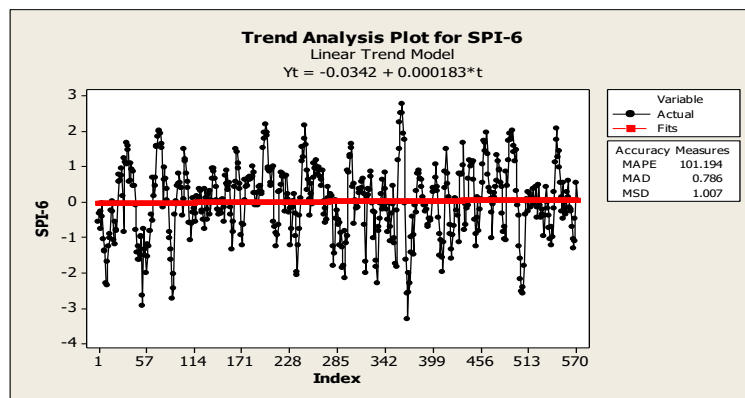


Fig. 5- Time series trend of drought index SPI<sub>6</sub>  
 شکل ۵- روند سری زمانی شاخص خشک سالی SPI<sub>6</sub>

جدول ۲- ارزیابی نتایج پیش بینی خشک سالی با مدل سری زمانی SARIMA

Table 2- Evaluation the results of the annual dry forecast with the SARIMA time series model

|   | Residual variance | Train        |              |              | AIC            | Test         |              |              |
|---|-------------------|--------------|--------------|--------------|----------------|--------------|--------------|--------------|
|   |                   | RMSE         | MAE          | R            |                | RMSE         | MAE          | R            |
| ARIMA (1,0,0)(1,0,0) <sub>6</sub>       | 0.304             | 0.442        | 0.341        | 0.889        | -547.56        | 0.551        | 0.396        | 0.839        |
| ARIMA (1,0,0)(1,1,0) <sub>6</sub>       | 0.557             | 0.659        | 0.35         | 0.761        | -266.49        | 0.746        | 0.566        | 0.715        |
| <b>ARIMA (1,0,0)(1,0,1)<sub>6</sub></b> | <b>0.292</b>      | <b>0.442</b> | <b>0.341</b> | <b>0.889</b> | <b>-562.83</b> | <b>0.521</b> | <b>0.385</b> | <b>0.846</b> |
| ARIMA (1,0,0)(1,0,2) <sub>6</sub>       | 0.293             | 0.442        | 0.341        | 0.889        | -560.89        | 0.541        | 0.714        | 0.845        |
| ARIMA (1,0,2)(1,0,1) <sub>6</sub>       | 0.291             | 0.441        | 0.339        | 0.889        | -561.15        | 0.539        | 0.384        | 0.846        |
| ARIMA (2,0,0)(1,0,1) <sub>6</sub>       | 0.292             | 0.441        | 0.338        | 0.889        | -562.13        | 0.54         | 0.385        | 0.846        |
| ARIMA (2,0,0)(1,0,2) <sub>6</sub>       | 0.292             | 0.441        | 0.338        | 0.889        | -560.14        | 0.54         | 0.385        | 0.846        |
| ARIMA (2,0,0)(2,0,2) <sub>6</sub>       | 0.292             | 0.43         | 0.325        | 0.895        | -558.71        | 0.54         | 0.386        | 0.846        |
| ARIMA (2,0,3)(1,0,3) <sub>6</sub>       | 0.289             | 0.411        | 0.314        | 0.904        | -560.4         | 0.538        | 0.385        | 0.847        |
| ARIMA (3,0,0)(1,0,1) <sub>6</sub>       | 0.291             | 0.44         | 0.337        | 0.89         | -561.22        | 0.539        | 0.384        | 0.847        |
| ARIMA (4,0,0)(1,0,1) <sub>6</sub>       | 0.291             | 0.431        | 0.332        | 0.894        | -559.21        | 0.54         | 0.384        | 0.846        |

همچنین، P-value آماره آزمون Ljung-Box نیز در تأخیرهای مختلف، که بزرگتر از سطح معنی‌داری ۵٪ می‌باشد، فرض صفر که فرض استقلال باقی‌مانده‌ها است را تأیید می‌کند (جدول ۴). مدل برتر  $ARIMA(1,0,0)(1,0,1)$  به صورت رابطه ۱۴ بیان می‌گردد.

$$(1 - 0.1707B^6)(1 - 0.5887B)X_t = 0.00166(1 - 0.5581B^6) \quad (14)$$

در شکل (۸) نمودار مقادیر مشاهداتی شاخص خشک‌سالی  $SPI(t)$  و مقادیر پیش‌بینی شده با استفاده از مدل مذکور آورده شده است.

با در نظر گرفتن آماره‌های به کار رفته جهت ارزیابی این مدل‌ها و همچنین با توجه به مقایسه نمودارهای ACF و PACF مدل با نمودارهای ACF و PACF سری مشاهده‌ای (این نمودارها در شکل ۶ و ۷ آورده شده است)، مدل  $ARIMA(1,0,0)(1,0,1)$  به عنوان مدل برتر انتخاب گردید. در مرحله آموزش این مدل، واریانس باقی‌مانده‌ها برابر  $0.292$  و  $0.442$ ،  $MAE=0.341$ ، ضریب همبستگی برابر  $0.889$  و معیار آکاییک (AIC) برابر  $562/83$  می‌باشد. هم‌چنین، در مرحله اعتبار سنجی، مقدار  $MAE=0.385$ ،  $RMSE=0.521$  و ضریب همبستگی برابر  $0.846$  است. ضرایب مدل برتر و همچنین مقدار P آماره خطای استاندارد هر ضریب (t) نشان داد که تمامی ضرایب در سطح ۵٪ معنی‌دار می‌باشند و مقادیر آنها در جدول (۳) آورده شده است.

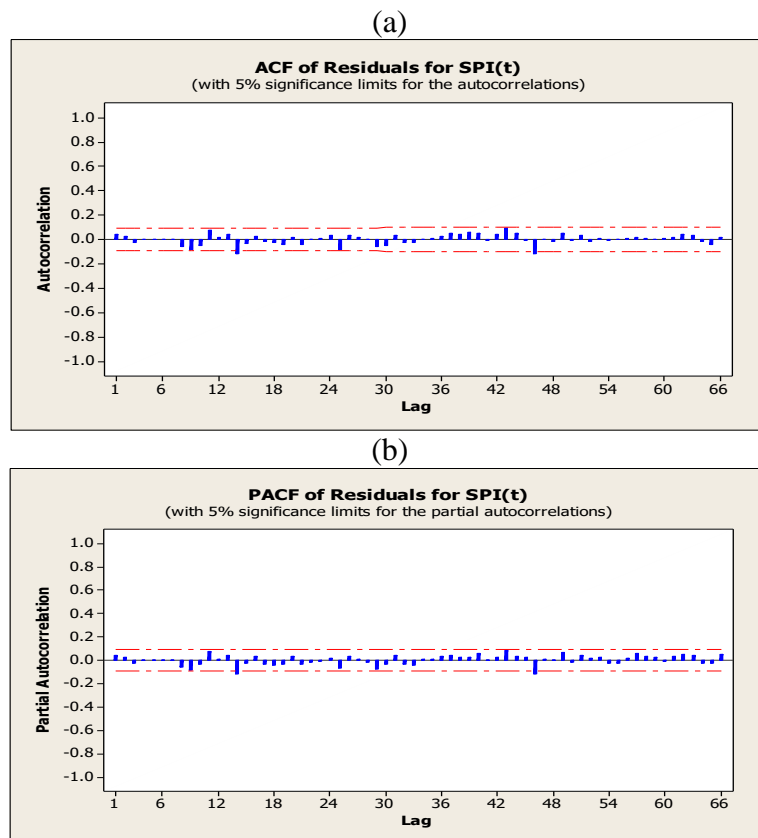


Fig. 6- (a) Chart of Autocorrelation. (b) Chart partial autocorrelation of the better model

شکل 6- (a): نمودار خودهمبستگی، (b): نمودار خودهمبستگی جزئی مدل برتر

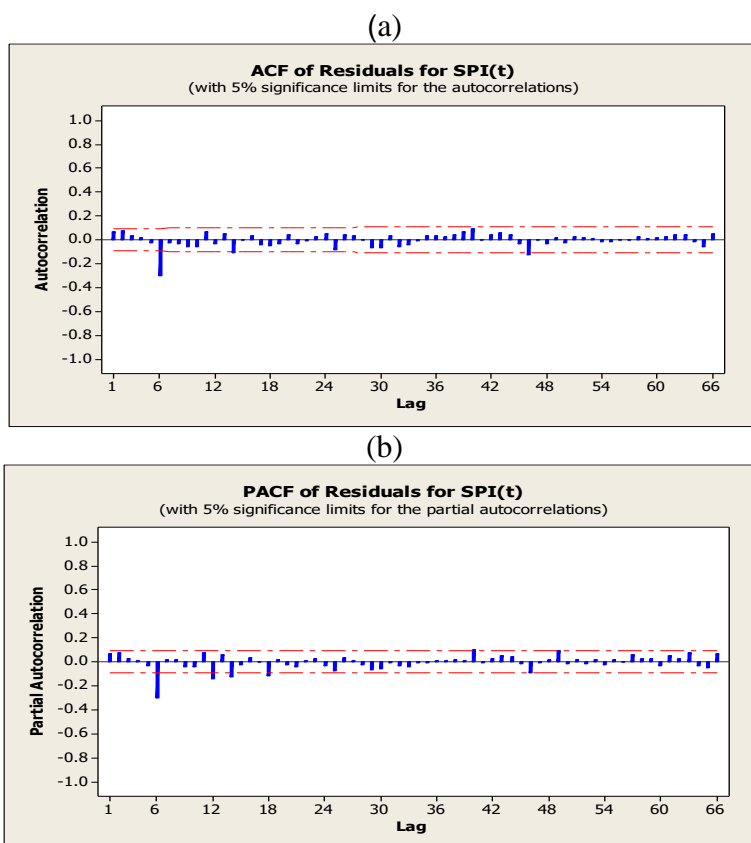


Fig. 7- (a) Chart of Autocorrelation (b) Chart of partial autocorrelation observed series.  
شکل ۷- (a): نمودار خودهمبستگی (b): نمودار خودهمبستگی جزئی سری مشاهده‌ای

جدول ۳- مقادیر ضرایب و خطای استاندارد آن

Table 3- Coefficients and standard errors

| Type     | degree | Coefficient | P-values |
|----------|--------|-------------|----------|
| AR       | 1      | 0.5887      | 0        |
| SAR      | 1      | 0.1707      | 0.004    |
| SMA      | 1      | 0.5581      | 0        |
| constant | -      | 0.00166     | 0.002    |

جدول ۴- مقادیر P آماره آزمون Ljung-Box تا ۴۸ تأخیر

Table 4- P values of Ljung-Box test statistics up to 48 delays

| Ljung-Box Test |       |       |       |       |
|----------------|-------|-------|-------|-------|
| Delay          | 12    | 24    | 36    | 48    |
| P-value        | 0.244 | 0.367 | 0.558 | 0.277 |

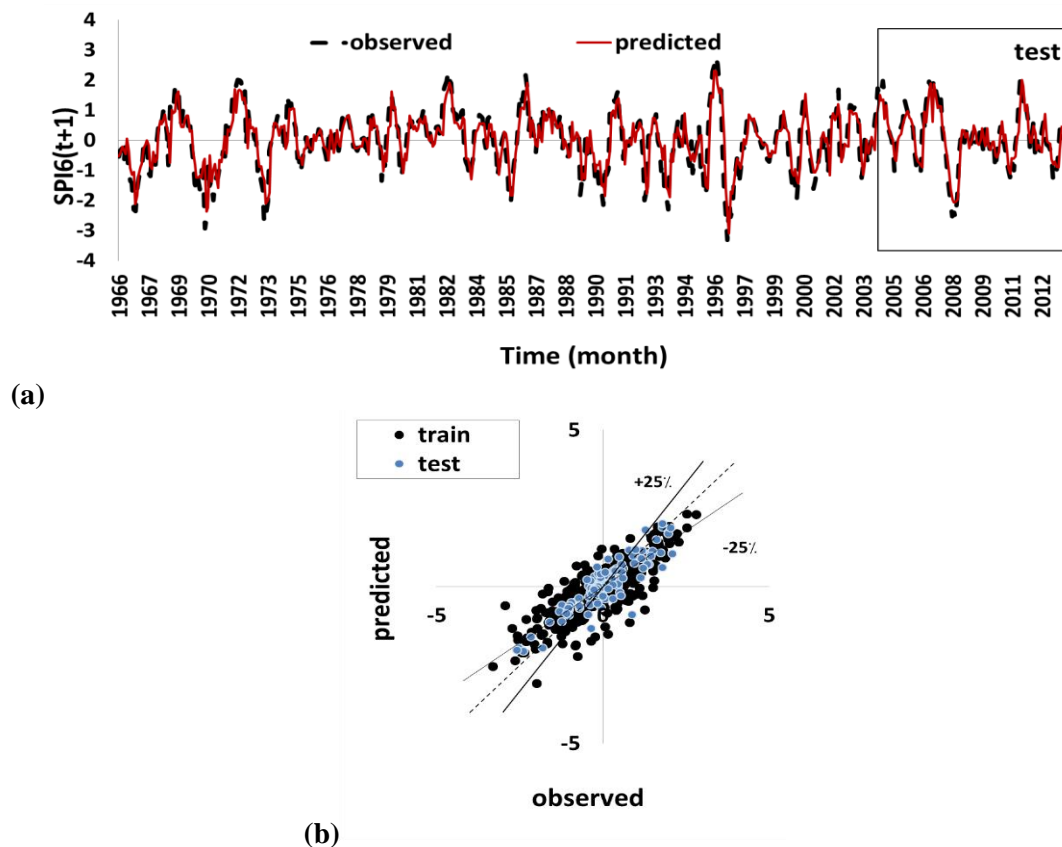


Fig. 8- (a) and (b) Comparison of observed and predicted values (SP) of SPI with model  $ARIMA(1,0,0)(1,0,1)_6$

شکل ۸- (a) و (b): نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده  $SPI(t)$  با مدل  $ARIMA(1,0,0)(1,0,1)_6$

در مدل‌سازی شبکه عصبی RBF تعداد بسیار زیادی مدل با ترکیب‌های مختلف متغیرهای ورودی ساخته شد. با توجه به حجم بالای مدل‌ها برای هر ترکیب ورودی فقط بخشی از نتایج حاصل از مدل با ثابت گسترش بهینه، کمترین خطا و بیشترین همبستگی مقادیر مشاهداتی و پیش‌بینی‌شده در جدول (۶) آورده شده است. پس از ارزیابی نتایج، مشخص گردید که این نوع شبکه عصبی، عملکرد ضعیف‌تری را نسبت به شبکه عصبی MLP از خود نشان داد. از بین این مدل‌ها، مدل RBF با هشت متغیر ورودی  $SPI(t)$ ،  $RH_{min}(t)$ ،  $RH_{min}(t-1)$ ،  $SPI(t-1)$ ،  $SPI(t-2)$ ،  $SPI(t-3)$ ،  $RH_{min}(t-2)$  و  $RH_{min}(t-3)$  با ثابت گسترش ۱۵۰ که عملکرد مناسب در هر دو مرحله آموزش و آزمون را نشان داد، به عنوان مدل برتر انتخاب گردید. در مرحله آموزش مقادیر  $RMSE=0/54$ ،  $MAE=0/399$  و ضریب همبستگی برابر  $0/844$  و در مرحله آزمون  $RMSE=0/55$ ،  $MAE=0/434$  و ضریب همبستگی برابر  $0/834$  می‌باشد. در شکل (۱۰)، نمودار مقادیر مشاهداتی شاخص خشک-سالی  $SPI(t+1)$  و مقادیر پیش‌بینی‌شده با استفاده از مدل مذکور آورده شده است.

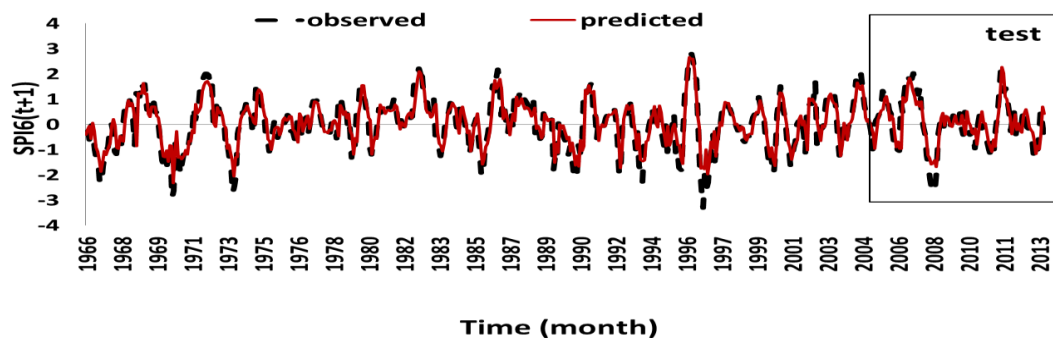
#### ب- مدل‌سازی ANNs

در مدل‌سازی با استفاده از شبکه عصبی MLP تعداد بسیار زیادی مدل با ترکیب‌های مختلف متغیرهای ورودی ساخته شد که با توجه به حجم بالای آن‌ها فقط بخشی از نتایج در جدول (۵) آورده شده است. این نتایج نشان می‌دهد که شاخص خشک‌سالی  $SPI$  عملکرد بهتری را در مدل‌سازی نسبت به سایر متغیرها دارا بوده و متغیر میانگین بارش با بیشترین میزان خطا، عملکرد ضعیفی را از خود نشان داده است. در نهایت، با توجه به سایر آماره‌ها جهت ارزیابی مدل‌ها، مدل MLP با پنج متغیر ورودی شاخص خشک‌سالی  $SPI$  در ماه جاری و مقادیر پیشین آن تا چهار تأخیر زمانی با تابع محرک لگاریتم سیگموئید و ۱۰ نرون در لایه پنهان، عملکرد مناسبی در هر دو مرحله آموزش و آزمون را نشان داد. در مرحله آموزش مقادیر  $RMSE=0/534$ ،  $MAE=0/393$  و ضریب همبستگی برابر  $0/85$  و در مرحله آزمون  $RMSE=0/532$ ،  $MAE=0/402$  و ضریب همبستگی برابر  $0/837$  می‌باشد. در شکل (۹)، نمودار مقادیر مشاهداتی شاخص خشک‌سالی  $SPI(t+1)$  و مقادیر پیش‌بینی‌شده با استفاده از مدل مذکور آورده شده است.

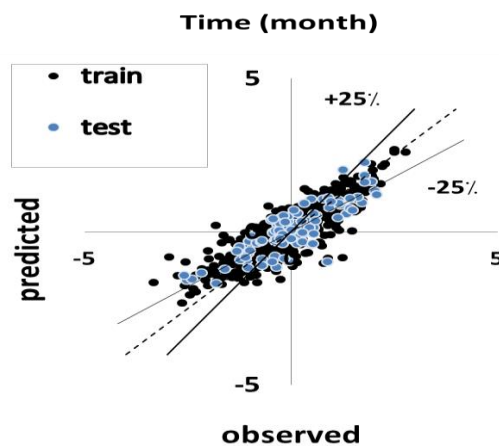
جدول ۵- ارزیابی نتایج پیش‌بینی خشک‌سالی با FFBP

Table 5- Evaluation of the results of annual dry forecasting with FFBP

|                 |               |                |           | Train        |              |             | Test         |              |              |
|-----------------|---------------|----------------|-----------|--------------|--------------|-------------|--------------|--------------|--------------|
|                 |               |                |           | RMSE         | MAE          | Corr.       | RMSE         | MAE          | Corr.        |
|                 | Tansig        | Purelin        | 13        | 0.535        | 0.406        | 0.848       | 0.53         | 0.421        | 0.833        |
|                 | <b>logsig</b> | <b>Purelin</b> | <b>10</b> | <b>0.534</b> | <b>0.393</b> | <b>0.85</b> | <b>0.532</b> | <b>0.402</b> | <b>0.837</b> |
|                 | Tansig        | Purelin        | 2         | 0.782        | 0.611        | 0.632       | 1.072        | 0.805        | 0.304        |
|                 | logsig        | Purelin        | 2         | 0.777        | 0.605        | 0.637       | 1.056        | 0.837        | 0.136        |
|                 | Tansig        | Purelin        | 10        | 0.953        | 0.757        | 0.337       | 0.95         | 0.725        | 0.257        |
|                 | logsig        | Purelin        | 21        | 0.954        | 0.759        | 0.326       | 0.934        | 0.715        | 0.259        |
|                 | Tansig        | Purelin        | 6         | 0.97         | 0.754        | 0.277       | 0.944        | 0.716        | 0.235        |
|                 | logsig        | Purelin        | 8         | 0.953        | 0.748        | 0.33        | 0.925        | 0.723        | 0.378        |
| SPI(t,t-1,t-2), | Tansig        | Purelin        | 5         | 0.567        | 0.427        | 0.827       | 0.541        | 0.43         | 0.827        |
| T(t,t-1,t-2)    | logsig        | Purelin        | 9         | 0.571        | 0.426        | 0.83        | 0.532        | 0.427        | 0.836        |
|                 | Tansig        | Purelin        | 15        | 0.559        | 0.421        | 0.833       | 0.55         | 0.436        | 0.829        |
|                 | logsig        | Purelin        | 14        | 0.559        | 0.415        | 0.832       | 0.558        | 0.455        | 0.814        |



(a)



(b)

Fig 9- (a) and (b) Comparison chart of observed and predicted values of SPI(t+1) with MLP model with five inputs and the logarithmic function of sigmoid and 10 neurons in the hidden layer

شکل ۹- (a) و (b): نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI(t+1) با مدل MLP با پنج ورودی و تابع لگاریتم سیگموئید و ۱۰ نرون در لایه پنهان

جدول ۶- ارزیابی نتایج پیش‌بینی خشک‌سالی با شبکه عصبی تابع شعاعی

Table 6- Evaluation of the results of drought prediction with neural network of radial function

|   |     |     | Train |       |       | Test  |       |       |
|---|-----|-----|-------|-------|-------|-------|-------|-------|
|   |     |     | RMS E | MAE   | Corr. | RMS E | MAE   | Corr. |
| SPI(t,t-1,t-2,t-3,t-4)  | RBF | 80  | 0.552 | 0.411 | 0.837 | 0.477 | 0.383 | 0.866 |
| P(t,t-1)  | RBF | 10  | 0.767 | 0.596 | 0.649 | 1.065 | 0.846 | 0.178 |
| T <sub>max</sub> (t,t-1,t-2,t-3)  | RBF | 100 | 0.972 | 0.764 | 0.267 | 0.95  | 0.709 | 0.138 |
| RH(t,t-1,t-2,t-3)   | RBF | 70  | 0.927 | 0.735 | 0.394 | 0.978 | 0.786 | 0.139 |
| SPI(t,t-1,t-2,t-3),<br>RH <sub>min</sub> (t,t-1,t-2,t-3)<br>SPI(t,t-1), P(t,t-1),<br>T <sub>max</sub> (t-1) |     |     |       |       |       |       |       |       |

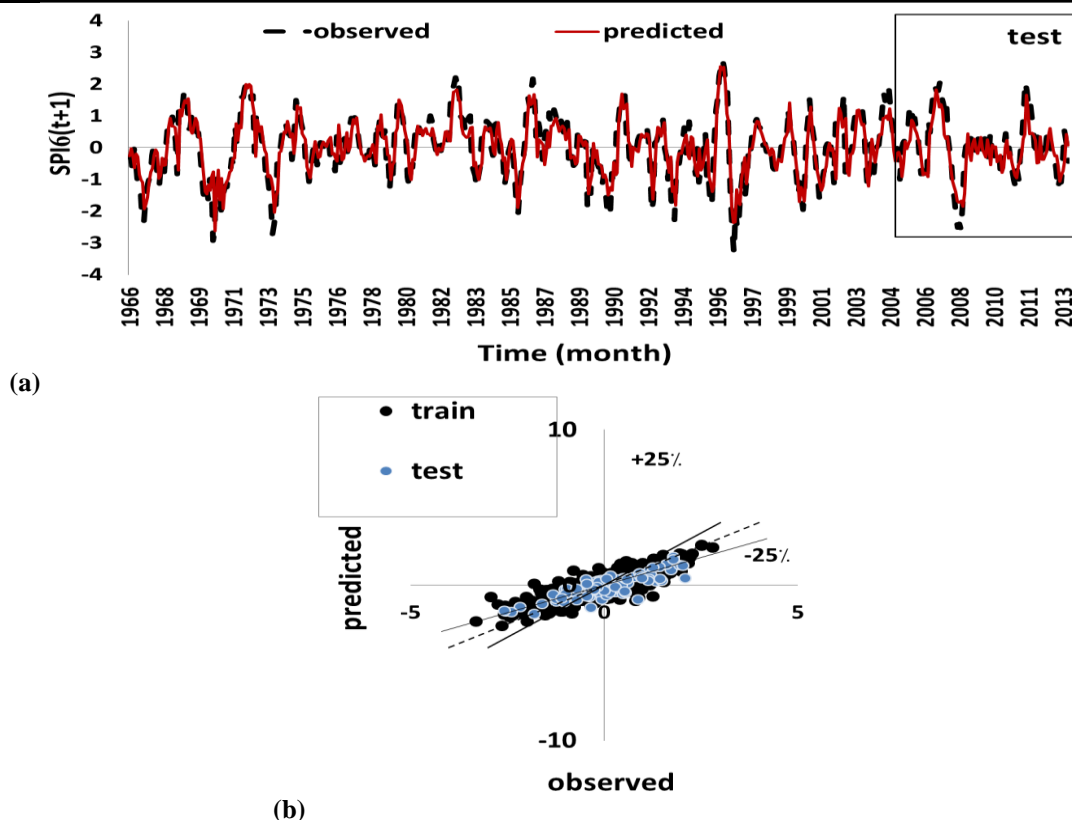


Fig 10- (a) and (b) Comparison chart of observed and predicted values SPI(t+1) with RBF model with eight inputs and Spread constants 150

شکل ۱۰- (a) و (b): نمودار مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده SPI(t+1) با مدل RBF با هشت ورودی و ثابت گسترش ۱۵۰

نهایت، با توجه به سایر آماره‌ها جهت ارزیابی مدل‌ها، مدل با پنج پارامتر ورودی شاخص خشک‌سالی SPI در ماه جاری و مقادیر پیشین آن تا چهار تأخیر زمانی با شش قانون و تابع عضویت ناقوسی با عملکرد مناسب در هر دو مرحله آموزش و آزمون و با مقادیر  $RMSE=0.513$ ،  $MAE=0.377$ ، و ضریب همبستگی برابر  $0.861$  در مرحله آموزش و  $RMSE=0.518$ ،  $MAE=0.41$  و ضریب همبستگی برابر  $0.841$  در مرحله آزمون، نسبت به سایر مدل‌ها به عنوان مدل برتر انتخاب گردید. در شکل (۱۱)، نمودار مقادیر مشاهده‌ای شاخص خشک‌سالی SPI(t+1) و مقادیر پیش‌بینی شده با استفاده از مدل‌های مذکور آورده شده است.

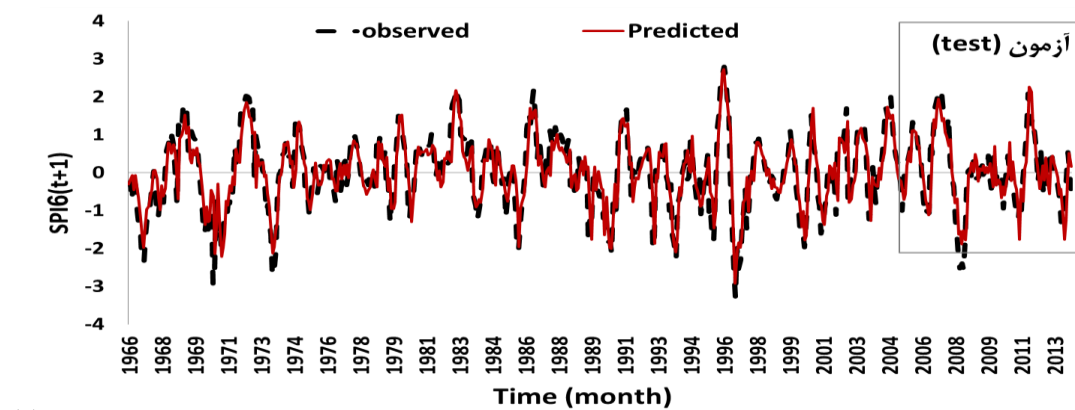
### ج- مدل‌سازی ANFIS

در مدل‌سازی با استفاده از سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS)، تعداد بسیار زیادی مدل با ترکیب‌های مختلف پارامترهای ورودی ساخته شد. با توجه به تعدد مدل‌ها به ازای هر ترکیب ورودی، صرفاً نتایج حاصل از مدل با تعداد قوانین بهینه، کمترین خطا و بیشترین همبستگی مقادیر مشاهده‌ای و پیش‌بینی شده در جدول (۷) آورده شده است. نتایج نشان می‌دهد که پارامتر شاخص خشک‌سالی SPI عملکرد بهتری را در مدل‌سازی نسبت به سایر پارامترها دارا بوده و میانگین بارش با بیشترین میزان خطا، عملکرد ضعیفی را از خود نشان داده است. در

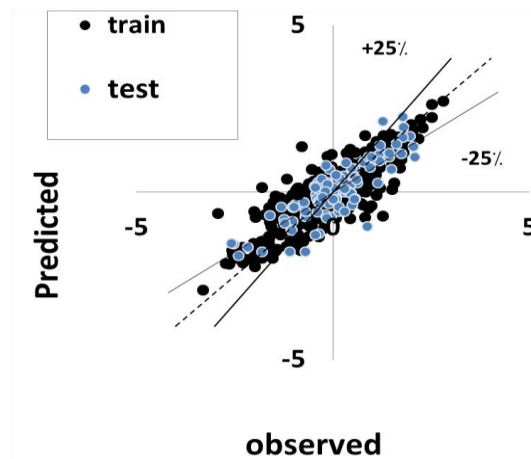
جدول ۷- ارزیابی نتایج پیش‌بینی خشک‌سالی با سیستم استنتاج عصبی- فازی تطبیقی

Table 7- Evaluation of the results predicted drought with Adaptive Neuro-Fuzzy Inference System

| Input variables                   | membership function | Output membership function | rules    | train        |              |              | test         |             |              |
|-----------------------------------|---------------------|----------------------------|----------|--------------|--------------|--------------|--------------|-------------|--------------|
|                                   |                     |                            |          | RMSE         | MAE          | Corr.        | RMSE         | MAE         | Corr.        |
|                                   | gaussmf             | Linear                     | 6        | 0.533        | 0.391        | 0.849        | 0.522        | 0.412       | 0.838        |
|                                   | <b>gbellmf</b>      | <b>Linear</b>              | <b>6</b> | <b>0.513</b> | <b>0.377</b> | <b>0.861</b> | <b>0.518</b> | <b>0.41</b> | <b>0.841</b> |
|                                   | gaussmf             | Linear                     | 2        | 0.769        | 0.597        | 0.647        | 1.082        | 0.863       | 0.155        |
|                                   | gbellmf             | Linear                     | 2        | 0.768        | 0.597        | 0.648        | 1.084        | 0.871       | 0.166        |
|                                   | gaussmf             | Linear                     | 6        | 0.924        | 0.742        | 0.4          | 0.918        | 0.707       | 0.325        |
|                                   | gbellmf             | Linear                     | 7        | 0.896        | 0.713        | 0.458        | 0.951        | 0.752       | 0.274        |
|                                   | gaussmf             | Linear                     | 7        | 0.908        | 0.703        | 0.436        | 0.912        | 0.708       | 0.429        |
|                                   | gbellmf             | Linear                     | 9        | 0.879        | 0.679        | 0.489        | 0.925        | 0.708       | 0.379        |
| SPI(t,t-1,t-2,t-3),               | gaussmf             | Linear                     | 4        | 0.52         | 0.389        | 0.856        | 0.511        | 0.418       | 0.85         |
| RH <sub>min</sub> (t,t-1,t-2,t-3) | gbellmf             | Linear                     | 4        | 0.51         | 0.381        | 0.863        | 0.513        | 0.415       | 0.846        |
|                                   | gaussmf             | Linear                     | 2        | 0.562        | 0.412        | 0.83         | 0.531        | 0.418       | 0.833        |
|                                   | gbellmf             | Linear                     | 2        | 0.561        | 0.412        | 0.831        | 0.537        | 0.423       | 0.829        |



(a)



(b)

Fig 11- (a) and (b) Comparison chart of observed and predicted values of SPI(t+1) with ANFIS model with five inputs and a function of bell membership and 6 rules

شکل ۱۱- (a) و (b): نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI(t+1) با مدل ANFIS با پنج ورودی و تابع عضویت ناقوسی و ۶ قانون

مدل‌های ANFIS، شبکه عصبی MLP و شبکه عصبی RBF با اختلاف اندک در مقادیر خطا در رتبه‌های بعدی قرار گرفتند. سپس با استفاده از مدل  $ARIMA(1,0,1)$  مقادیر شاخص خشک‌سالی  $SPI_6$  برای دوازده ماه آینده پیش‌بینی گردید. در شکل (۱۳) نمودار این مقادیر نشان داده شده است. مقادیر پیش‌بینی شده شاخص  $SPI_6$  با توجه به جدول (۸) حاکی از وقوع شرایط نرمال در ۱۲ ماه آینده می‌باشد.

پس از انتخاب مدل‌های برتر در پیش‌بینی خشک‌سالی در هر روش، جهت انتخاب بهترین روش، این مدل‌ها با هم مقایسه شدند. نتایج این مقایسه در شکل (۱۲) آورده شده است. با ارزیابی مقادیر خطای این مدل‌ها و با توجه به شکل (۱۲)، در مدل  $ARIMA(0,0,1)$  مقادیر پیش‌بینی شده انطباق بیشتری را با مقادیر مشاهده‌ای نسبت به مدل‌های برتر دو روش ANN و ANFIS از خود نشان داد و به عنوان مدل برتر انتخاب گردید و

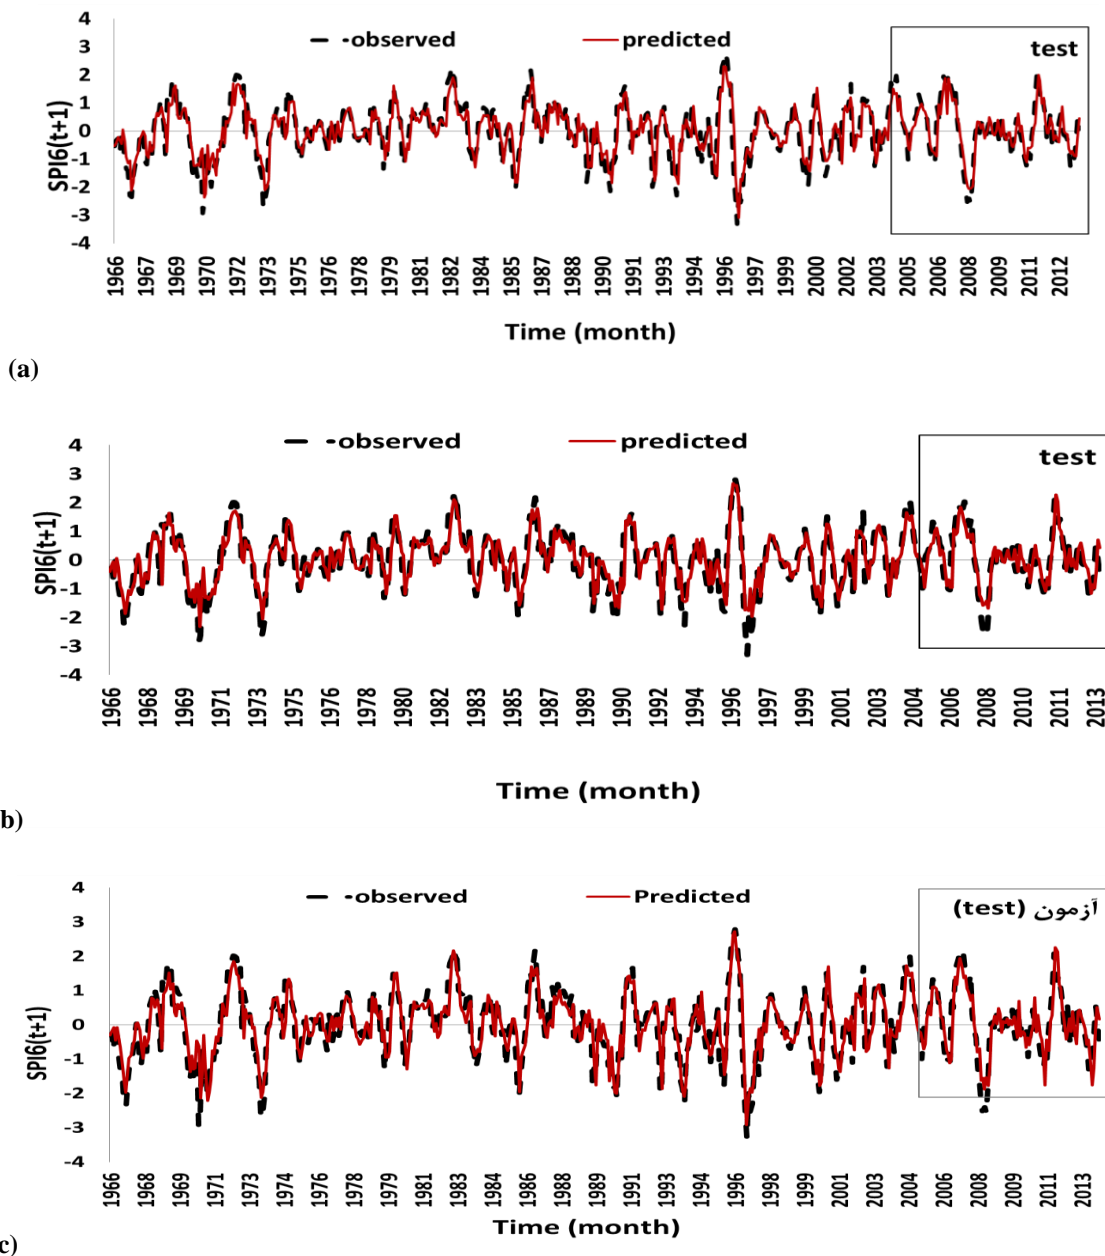


Fig 12- (a) The best model by method ARIMA. (b) The best model by method ANN. (c) The best model by method ANFIS.

Comparison chart of observed and predicted values of 6SPI index with top models of different methods

شکل ۱۲- (a): مدل برتر با روش ARIMA. (b): مدل برتر با روش ANN. (c): مدل برتر با روش ANFIS.

نمودار مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده شاخص  $SPI_6$  با مدل‌های برتر روش‌های مختلف



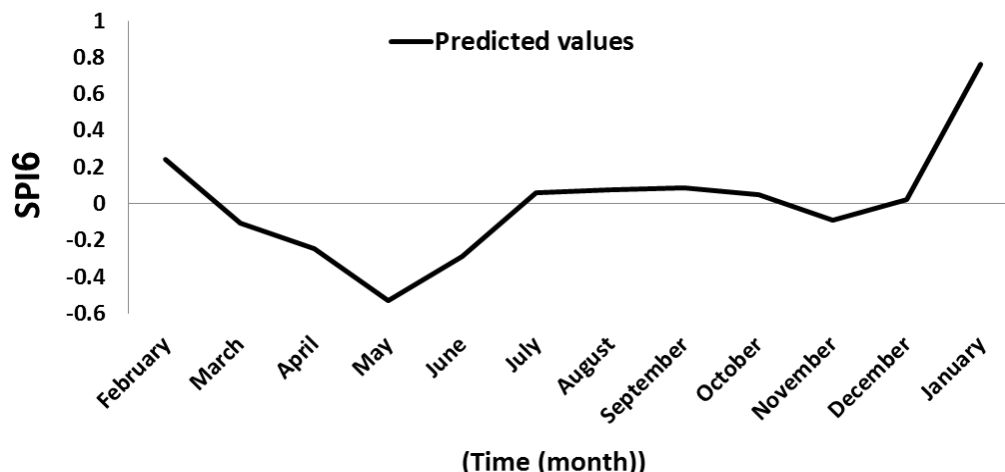


Fig 13- chart of the predicted values of the SPI<sub>6</sub> annual dry index for the next twelve months with the fit of mode ARIMA(1,0,0)(1,0,1)<sub>6</sub> 1 on the historical time series SPI<sub>6</sub>

شکل ۱۳- نمودار مقادیر پیش‌بینی شده شاخص خشک‌سالی SPI<sub>6</sub> برای دوازده ماه آینده با برازش مدل ARIMA(1,0,0)(1,0,1)<sub>6</sub> بر سری زمانی تاریخی SPI<sub>6</sub>

بررسی روش‌ها نشان داد، مدل‌های ساخته شده با شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا (MLP) از عملکرد مناسب‌تری نسبت به مدل‌های تابع شعاعی (RBF) برخوردار بودند که با نتایج حاصل از پژوهش Eivazi et al. (2009) و Negaresh و Aramesh (2011) همخوانی داشت (Eivazi et al., 2009). همچنین، همانطور که از Bacanlı et al. (2008) و Shirmohammadi et al. (2012) و Komasi et al. (2013) انتظار می‌رفت (Bacanli et al., 2008) و Shirmohammadi et al. (2012) سیستم‌های استنتاج فازی-عصبی تطبیقی (ANFIS) عملکرد مناسب‌تری را نسبت به شبکه‌های عصبی در مدل‌ها نشان دادند. در ترکیب‌های مختلف پارامترهای ورودی، تابع محرک لگاریتم سیگموئید عملکرد بهتری داشت. اما لزوماً تابع محرک برتر تشخیص داده نشد. در مدل‌های ANFIS نیز تابع عضویت گوسی در اکثر مدل‌ها عملکرد مناسبی را نشان داد. اما، لزوماً تابع محرک برتر تشخیص داده نشد.

### تقدیر و تشکر

بدین وسیله، نگارندگان، از دانشگاه سمنان به پاس فراهم آوردن امکان این تحقیق قدردانی می‌نمایند.

### نتیجه‌گیری

در پژوهش حاضر، جهت پیش‌بینی خشک‌سالی در شهر سمنان، با استفاده از اطلاعات و آمار ایستگاه هواشناسی سینوپتیک سمنان و روش‌های سری‌های زمانی، شبکه‌های عصبی مصنوعی (MLP) و RBF) و سیستم‌های استنتاج فازی-عصبی تطبیقی (ANFIS)، مدل‌های مناسب جهت پیش‌بینی خشک‌سالی شهرستان سمنان ارائه گردید. پس از بررسی تمامی روش‌ها در مدل‌سازی با تک‌تک متغیرهای ورودی و ترکیب‌های مختلف آن‌ها، نتایج نشان داد که در پیش‌بینی خشک‌سالی در مقیاس زمانی شش ماهه، مدل‌های سری زمانی عملکرد بهتری از دو روش دیگر را دارا بودند و مدل‌های ANFIS و شبکه عصبی در رتبه‌های بعدی قرار گرفتند. البته اختلاف در مقادیر خطای مدل‌سازی با این روش‌ها اندک بود و در نهایت مدل  $ARIMA(1,0,0)(1,0,1)_6$  به‌عنوان مدل برتر انتخاب گردید.

از بین متغیرهای ورودی شاخص خشک‌سالی SPI و مقادیر پیش‌بینی آن عملکرد بهتری را در بهبود مدل‌سازی‌ها دارا بودند و میانگین بارش ضعیف‌ترین عملکرد را نشان داد که این امر ممکن است به سبب وجود تغییرات مقادیر داده‌ها و تعدد مقدار کمینه (صفر) در آمار بارش باشد. در پژوهش صورت گرفته توسط Bacanlı et al. (2008) نیز استفاده از شاخص SPI در ترکیب با متغیرهای ورودی عملکرد مدل‌ها را بهبود بخشید (Bacanli et al., 2008). از بین متغیرهای هواشناسی، دما عملکرد مناسب‌تری را دارا بود.

### References

- 1- Aghajani, N., 2014. Torq River sediment prediction in Khorasan Razavi province using multiple and intelligent regression models. Thesis, *Semnan University of Semnan, Iran*. 140p. (In Persian).

- 2- Anonymous, 2014. Meteorological system of Semnan province, <http://www.semnanweather.ir/index.php>
- 3- Bacanlı, U., Firat, M., and Dikbas, F., 2008. Adaptive neuro-fuzzy inference system (ANFIS) for drought forecasting. *Stochastic Environmental Research and Risk Assessment*, 23(8), pp. 1143-1154.
- 4- Box, G.E.P., Jenkins, G.M., and Reinsel, G.C., 2002. *Time Series Analysis: Forecasting and Control*. Fourth Edition, John Wiley Publication, 734 p.
- 5- Dibike, Y.B., Solomatine, D., and Abbott, M.B., 1999. On the encapsulation of numerical-hydraulic models in artificial neural networks. *Journal of Hydraulic Research*, 37(2), pp. 147-161.
- 6- Eivazi, M., Mosaedi, A., and Dehghani, A.A., 2009. comparison of different approaches predicting SPI. *Journal of Water and Soil Conservation*, 16(2), pp. 145-167. (In Persian).
- 7- Jang, J.S.R., 1993. ANFIS: Adaptive-network based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), pp. 665-685.
- 8- Kamruzzaman, J., Begg, R., and Sarker, R., 2006. *Artificial Neural Networks in Finance and Manufacturing*. Idea Group Publishing, USA.
- 9- Karamooz, M., and Araghinezhad, SH., 2010. *Advanced Hydrology*. Second Edition, Amirkabir University of Technology Press, Tehran. (In Persian).
- 10- Komasi, M., Alami, M. T., and Nourani, V., 2012. Drought Forecasting by SPI Index and ANFIS Model Using Fuzzy C-mean Clustering. *Journal of Water and Wastewater*, 4, pp. 90-102. (In Persian).
- 11- Mahdavi, M., 2006. *Applied hydrology*. Sixth Edition, University of Tehran. (In Persian).
- 12- McKee, T.B., Doesken, N.J., and Kleist, J., 1993. The relation of drought frequency and duration to time scales. *8<sup>th</sup> Conference on Applied Climatology, 17-22 Jan., Anaheim, California*, pp. 379-384.
- 13- Mishra, A.K., and Desai V.R., 2006. Drought forecasting using feed-forward recursive neural networks. *Journal of Ecological Modelling*, 98, pp. 127-138.
- 14- Negaresh, H., and Aramesh, M., 2011. Drought forecast for Khash city using neural network model. *Journal of Arid Regions Geographic Studies*, 2(6), pp. 33-50. (In Persian).
- 15- Shirmohammadi, B., Moradi, H.R., Moosavi, V., Taie Semiromi, M., and Zeinali, A., 2013. Forecasting of meteorological drought using wavelet-ANFIS hybrid model for different time steps (Case study: Southeastern part of east Azerbaijan province, Iran). *Journal of Natural Hazards*, 69, pp. 389-402.
- 16- Shumway R.H., and Stoffer, D.S., 2006. *Time Series Analysis and its Applications: with R Examples*. Springer Texts in Statistics, 656 p.