

Prediction of Meteorological Droughts in Kuhrang Using the Hybrid Model of Wavelet and Artificial Neural Network

M. Bahrami Samani¹, R. Mirabbasi Najafabadi^{2*}, A. R. Ghasemi Dastgerdi³ and S. Abdollahi AsadAbadi⁴

1- MSc. Student of Water Resources Engineering, Shahrekord University, Shahrekord, Iran.

2*- Corresponding Author, Associate Professor, Department of Water Engineering, Shahrekord University Address: Water Eng. department, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran.(mirabbasi_r@yahoo.com).

3- Associate Professor, Department of Water Engineering, Shahrekord University Shahrekord, Iran.

4- PhD. of Water Resources Engineering, Department of Water Engineering, Shahid Chamran University od Ahvaz, Ahvaz, Iran.

ARTICLE INFO

Article history:

Received: 15 October 2019

Revised: 14 June 2020

Accepted: 20 June 2020

Keywords:

Meteorological Drought, WANN Model, ANN Model, SPI Index, RDI Index, Kuhrang

TO CITE THIS ARTICLE:

Bahrami Samani, M., Mirabbasi Najafabadi, R., Ghasemi Dastgerdi, A., Abdollahi AsadAbadi, S. (2021). 'Prediction of Meteorological Droughts in Kuhrang Using the Hybrid Model of Wavelet and Artificial Neural Network', *Irrigation Sciences and Engineering*, 44(3), pp. 61-74. doi: 10.22055/jise.2020.31370.1884.

Introduction

Meteorological drought is defined as a lack of rainfall over long periods, which reduces soil moisture and river flow. One of the critical drought assessment tools is drought indices (Tsakiris & Vangelis, 2005). So far, many drought indicators have been developed by researchers, for example, the RDI (Reconnaissance Drought Index) (Tsakiris & Vangelis, 2005). The difference between this index and other drought indices is that it is estimated based on two variables of precipitation and potential evapotranspiration. For this reason, it is more accurate than indices that are calculated only based on precipitation. So far, some studies have been used the RDI for drought assessment. Zarei et al. (2016) studied the spatial pattern of drought using the RDI index in southern Iran. The results showed that the area with dry conditions had an increasing trend. Asadi Zarch (2017) investigated the drought trend in Yazd province between 1966-2009 using the RDI index. The results showed that drought occurrence in Yazd increased during the studied period. Because, unlike other natural disasters, it is difficult to accurately determine the onset and the end of the drought period (Morieid et al., 2005). Accordingly, it is difficult to diagnose and evaluate the drought phenomenon. Therefore, monitoring and predicting drought is very important in water resources management. The use of wavelets is a new and very effective way of analyzing signals and time series. Application of Wavelet in Wavelet- Artificial Neural Network (WANN) models as a function for training has recently been used as an alternative for Artificial Neural Network (ANN) models. In recent years, the combination of wavelet theory and artificial neural networks has led to the development of wavelet neural networks (Thuillard, 2000). Zhang et al. (2017) applied the ARIMA, ANN, WANN, and Support Vector Regression (SVR) models to predict droughts in China's northern Haihe River basin using the SPI index. The results showed that the WANN model performed better than other considered models for predicting the SPI values at 6 and 12 months time scales. This study aimed to predict the meteorological droughts in the Kuhrang region using ANN and WANN models. To this end, the efficiency of ANN and WANN models in predicting precipitation and potential evapotranspiration will be evaluated. Then, the Resilience Drought Index (RDI) will be calculated based on the predicted values by ANN and WANN to describe and prediction of Kuhrang wetness conditions.

Material and Methods

Study Area

Kouhrang county is located in Chaharmahal va Bakhtiari province which its center is Chelgerd and having an area of over 3790.25 square kilometers. It is situated between $29^{\circ} 56' 49''$ and $37^{\circ} 26' 50''$ east longitude and $54^{\circ} 59' 31''$ and $49^{\circ} 05' 32''$ north latitude, at an altitude of 2365 meters above sea mean level. The average annual precipitation in Kouhrang station is 1308 mm.

Reconnaissance Drought Index (RDI)

This index was introduced in 2005 by Tsakiris and Vangelis. The RDI is obtained by fitting the log-normal distribution to the ratio of rainfall to potential evapotranspiration over the desired time interval. To calculate the RDI, the potential evapotranspiration value must first be calculated. One of the methods of estimating potential evapotranspiration is Hargreaves-Samani (1982). In this study, it was used to calculate the potential evapotranspiration at Kouhrang station.

Artificial Neural Network (ANN)

Artificial neural networks are flexible mathematical tools that can be used to model complex systems. The general capability of the ANN is to learn the nonlinear relationship among the data and determine the results for the other data (Nourani et al., 2009a,b). In this study, a three-layer MLP network was used to predict monthly precipitation and potential evapotranspiration data. Moreover, the activation functions of the middle layers and their outputs were considered as sigmoid and linear tangents, respectively. The purpose of this study is to predict monthly precipitation and potential evapotranspiration for the next one month using appropriate delays of both variables. In the next step, to determine the best input for the model, the best input pattern to the network was determined using the Auto Correlation Function and Partial Auto Correlation Function. Also, the trial and error method was used to select the superior input pattern. Next, monthly precipitation and potential evapotranspiration data from 1988 to the end of 2015 was used as the network training data. The data of 2016 have been used as network test data. In addition, the optimal number of neurons in the middle or hidden layer was determined by trial and error between one and ten neurons. Finally, after the calibration step, the results of the trained networks test were evaluated by R^2 and RMSE indices.

Wavelet- Artificial Neural Network (WANN) models

The WANNs are a hybrid of ANN and wavelet formed from an ANN model in which each of their input variables is decomposed by a discrete wavelet function into several subsets (Adamowski & Sun, 2010). In this study, Malat Algorithm or Multi-Resolution Analysis was used to implement the DWT method. In this method, the low and high frequencies of the signal are separated by the use of Low-Pass Filters and High Pass Filters, respectively, and the filtering process continues until the desired breakdown level is reached. In the phase of developing models for estimating the precipitation and potential evapotranspiration by ANN, WANN, it was assumed that precipitation and potential evapotranspiration in both models is a function of their previous observations at Kouhrang station and given the capabilities of the multilayer perceptron network in hydrological studies, three-layer perceptron network was used in this method.

Results and Discussion

Based on the results, although the ANN model has good performance in predicting potential evapotranspiration, it has not been successful in predicting precipitation. But the WANN model performed better than ANN in predicting the desired data in both the training and test phases. Therefore, in this study, the WANN model was used to predict monthly precipitation and potential evapotranspiration for 2016. Then the RDI values were calculated for predicted potential evapotranspiration and precipitation data. After predicting the monthly precipitation and potential evapotranspiration data using the WANN model in 2016, the RDI index was calculated and compared with the predicted data. Although it is difficult to predict rainfall data, the WANN model provides a relatively accurate precipitation prediction.

Conclusions

This study evaluated meteorological droughts of the Kuhrang station in Chaharmahal va Bakhtiari province using the RDI index. Then monthly precipitation and potential evapotranspiration data were predicted using ANN and WANN models for 2016. The results show that the WANN model predicts drought index changes more accurately than the ANN model. Finally, the RDI index was calculated using the data predicted in the WANN model. The results showed that the WANN model has acceptable accuracy in predicting monthly precipitation and potential evapotranspiration data. Therefore, this method can be used to predict drought for better management of water resources and make appropriate decisions for coping with drought conditions.

Acknowledgment

The authors thank the Vice Chancellor for Research and Technology of Shahrekord University for financial support (Grant No. 97GRN1M1692) of this study as well as the Islamic Republic of Iran Meteorological Organization and the Iran Water Resources Management Company for providing the required information.

References

- 1- Adamowski, J. and Sun, K., 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390, pp.85-91.
- 2- AsadiZarch, M.A., 2017. Analyzing climate change effects on drought occurrence in Yazd province, Iran. *Scientific Association of Desert Management and Control*, 9, pp.74-90. (In Persian).
- 3- Hargreaves, G.H. and Samani, Z.A., 1982. Estimating potential evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 108, pp.223-230.
- 4- Moried, S., Moghaddasi, M., Paemozd, S.H. and Ghaemi, H., 2005. Designing drought monitoring system of Tehran province. *Applied Research Report Ministry of Energy*, 253P.
- 5- Nourani, V., Komasi, M. and Mano, A., 2009a. A multivariate ANN-Wavelet approach for Rainfall-Runoff Modeling. *Water Resources Management*, 23, pp.2877-2894.
- 6- Nourani, V., Alami, M.T. and Aminfar, M.H., 2009b. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Journal of Engineering Application of Artificial Intelligence*, 22, pp.466-472. (In Persian).
- 7- Thuillard, M., 2000. A review of wavelet networks, wavelet, fuzzy wavelet and their application. ESIT 2000 Aachen. Germany.
- 8- Tsakiris, G. and Vangelis, H., 2005. Establishing a drought index incorporating evapotranspiration. *European Water*, 10, pp.3-11.
- 9- Zarei, A.R., Moghimi, M.M. and Mahmoudi, M.R., 2016. Analysis of changes in spatial pattern of drought using RDI index in south of Iran. *Water Resour Manage*, 11, pp.3723-3743. (In Persian).
- 10- Zhang, Y., Li, W., Chen, Q., Pu, X. and Xiang, L., 2017. Multi-models for SPI drought forecasting in the north of Haihe River Basin, China. *Stoch Environ Res Risk Assess*, 31, pp.2471-2481.





کاربرد مدل تلفیقی تبدیل موجک و شبکه عصبی مصنوعی در پایش خشک‌سالی هواشناسی (مطالعه موردی: حوضه آبریز کوهرنگ)

مرضیه بهرامی سامانی^۱، رسول میرعباسی نجف آبادی^۲، احمدرضا قاسمی دستگردی^۳ و سجاد عبداللهی اسدآبادی^۴

۱- دانش آموخته کارشناسی ارشد مهندسی منابع آب، دانشگاه شهرکرد.

۲- نویسنده مسئول، دانشیار گروه مهندسی آب، دانشگاه شهرکرد. mirabbasi_r@yahoo.com

۳- دانشیار گروه مهندسی آب، دانشگاه شهرکرد.

۴- دکترای مهندسی منابع آب، دانشگاه شهید چمران اهواز.

پذیرش: ۱۳۹۹/۳/۳۱

بازنگری: ۱۳۹۹/۳/۲۵

دریافت: ۱۳۹۸/۷/۲۳

چکیده

خشک‌سالی یکی از بلاهای طبیعی است که سالانه خسارات فراوانی را برای جوامع مختلف به دنبال دارد. ارزیابی و پیش‌بینی خشک‌سالی‌ها می‌تواند اطلاعات با ارزشی جهت تدوین برنامه‌های مقابله با خشک‌سالی و کاهش خسارات مربوط به آن در اختیار مدیران و برنامه‌ریزان منابع آب بگذارد. در تحقیق حاضر، خشک‌سالی‌های هواشناسی ایستگاه کوهرنگ در استان چهارمحال و بختیاری با استفاده از شاخص خشک‌سالی احيایی (RDI) در دوره آماری ۲۰۱۶-۱۹۸۷ مورد بررسی و تحلیل قرار گرفت. سپس با استفاده از مدل شبکه عصبی مصنوعی (ANN) و مدل تلفیقی موجک با شبکه عصبی مصنوعی (WANN) داده‌های ماهانه بارش و تبخیر تعرق پتانسیل برای سال ۲۰۱۶ پیش‌بینی شد. نتایج نشان داد که هرچند مدل ANN در پیش‌بینی داده‌های تبخیر تعرق پتانسیل از دقت قابل قبولی برخوردار بود، اما دقت آن در پیش‌بینی داده‌های بارش مناسب نبوده است. در حالی که مدل WANN از دقت خوبی در پیش‌بینی داده‌های بارش ماهانه و تبخیر تعرق پتانسیل برخوردار بود، به طوری که میزان R^2 مرحله تست، در پیش‌بینی داده‌های ماهانه بارش معادل ۰/۶۹ و برای داده‌های ماهانه تبخیر تعرق پتانسیل معادل ۰/۹۹ بود که نتایج مطلوب‌تری نسبت به مدل شبکه عصبی داشت (میزان R^2 مدل شبکه عصبی مصنوعی برای بارش ۰/۵۲ بود). بنابراین، از مدل WANN برای پیش‌بینی داده‌های بارش و تبخیر تعرق پتانسیل استفاده شد. در مرحله بعد با استفاده از داده‌های پیش‌بینی شده، مقادیر شاخص RDI محاسبه و با مقادیر متناظر این شاخص که با داده‌های مشاهداتی محاسبه شده بودند، مقایسه گردید. نتایج نشان داد که مدل WANN عملکرد خوبی در پیش‌بینی خشک‌سالی کوهرنگ داشته است.

کلیدواژه‌ها: خشک‌سالی، تبخیر تعرق، بارش، مدل WANN، مدل ANN، شاخص RDI.

مقدمه

مهم و متداول برای ارزیابی خشک‌سالی‌ها، شاخص‌های خشک‌سالی هستند. اطلاعات به‌دست آمده از شاخص‌ها می‌تواند برای برنامه‌ریزان، طراحان و مدیران منابع آب مفید باشد (Tsakiris and Vangelis, 2005). تاکنون شاخص‌های خشک‌سالی بسیاری توسط محققان توسعه داده شده‌اند که از آن جمله می‌توان به شاخص خشک‌سالی پالمر یا PDSI (Palmer Drought Severity Index) (Palmer, 1965)، شاخص بارش استاندارد شده یا SPI (Standardized Precipitation Index) (Mckee et al, 1993) یا زیرزمینی یا GRI (Groundwater Resource Index) (Mendicino et al, 2008) و شاخص خشک‌سالی احيایی یا RDI (Reconnaissance Drought Index) (Tsakiris and Vangelis, 2005) اشاره نمود. یکی از شاخص‌هایی که در

خشک‌سالی عبارت است از کمبود بارش در دوره‌های بلندمدت زمانی، به نحوی که باعث کمبود رطوبت خاک و به دنبال آن کاهش آب‌های جاری شود و بدین طریق منجر به اثرات نامطلوب بر فعالیت‌های بشر گردد. از دیدگاه اقلیم‌شناختی، خشک‌سالی زمانی رخ می‌دهد که بارش دریافتی در یک محل و در یک دوره زمانی معین، کمتر از میانگین بلندمدت بارش آن محل باشد. در ایران بعد از خشک‌سالی‌های سال‌های پایانی دهه ۷۰ هجری شمسی، بررسی وضعیت خشک‌سالی و شناسایی خصوصیات آن بیش از پیش مورد توجه قرار گرفت. تعیین ویژگی‌های خشک‌سالی یا ترسالی در یک منطقه، یکی از نیازهای اساسی برنامه‌ریزی‌های محیطی و اقتصادی، به‌ویژه برنامه‌ریزی برای مدیریت منابع آب می‌باشد (Raziei et al., 2007). یکی از ابزارهای

سیگنال نالیستا عملکرد مناسبی ندارد. درحالیکه تبدیل موجک سیگنال‌های نالیستا را نیز به خوبی آنالیز می‌کند (Sifuzzaman et al., 2009). استفاده از موجک (Wavelet) به‌عنوان روشی نوین و بسیار موثر در زمینه تحلیل سیگنال‌ها و سری‌های زمانی است. کاربرد موجک در شبکه عصبی- موجکی به‌عنوان تابع آموزش، اخیراً به‌عنوان یک روش جایگزین در شبکه‌های عصبی به‌کار برده شده است. در سال‌های اخیر، ترکیب تئوری موجکی و شبکه‌های عصبی مصنوعی منجر به گسترش شبکه‌های عصبی- موجکی شده است (Thuillard, 2000). در ادامه به برخی از پژوهش‌هایی که تاکنون در این مورد صورت گرفته، اشاره شده است: Djerbouai و Souag-Gamane (2016) برای پیش‌بینی خشک‌سالی در حوضه آبریز (Algerois) در شمال الجزایر از مدل ANN، مدل WANN و مدل‌های تصادفی استفاده کردند. نتایج حاصل از این مطالعه نشان داد که مدل WANN برای پیش‌بینی همه سری‌های زمانی SPI در مقیاس‌های ۱ تا ۶ ماهه، بهترین عملکرد را داشت. Zhang et al. (2017) در تحقیقی، برای پیش‌بینی خشک‌سالی‌های به‌دست‌آمده با استفاده از شاخص SPI، در شمال حوضه رودخانه‌های هه (Haihe) در چین، از مدل‌های ANN، ARIMA، WANN و مدل رگرسیون بردار پشتیبان (SVR) استفاده کردند. نتایج نشان داد که مدل WANN عملکرد بهتری در پیش‌بینی مقادیر شاخص SPI در مقیاس‌های ۶ و ۱۲ ماهه داشته است. Hassanzadeh et al. (2013) برای پیش‌بینی خشک‌سالی‌های آینده، از تلفیق الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی در تحلیل شاخص بارش استاندارد- شده استفاده کردند و نشان دادند که به‌کارگیری روش تلفیقی مذکور در مقایسه با تلفیق الگوریتم ژنتیک و شبکه عصبی، نتایج مطلوبی ارائه می‌دهد.

Anshuka et al. (2019) در حوضه مورد مطالعه خود با استفاده از شاخص SPI به پیش‌بینی خشک‌سالی از طریق مدل‌های آماری پرداختند و بدین منظور از مدل‌های ANN و WANN نیز بهره جستند. نتایج نشان داد WANN با داشتن همبستگی بالاتر و میزان خطای کمتر نسبت به ANN، عملکرد بهتری در پیش‌بینی خشک‌سالی داشته است. هدف از مطالعه حاضر، پیش‌بینی خشک‌سالی‌های هواشناسی کوه‌رنگ با استفاده از مدل ANN و WANN می‌باشد. بدین منظور کارایی مدل‌های فوق در پیش‌بینی بارش و تبخیر-تعرق پتانسیل مورد ارزیابی قرار گرفته و براساس مقادیر پیش‌بینی‌شده، شاخص خشک‌سالی احیایی (RDI) برای توصیف شرایط رطوبتی کوه‌رنگ محاسبه گردید.

مواد و روش‌ها

منطقه مورد مطالعه

شهرستان کوه‌رنگ یکی از شهرستان‌های مهم استان چهارمحال و بختیاری می‌باشد که مرکز آن چلگرد است. به علت

سال‌های اخیر مورد توجه محققان قرار گرفته، شاخص خشک‌سالی احیایی (RDI) می‌باشد. تفاوت این شاخص با سایر شاخص‌ها در این است که این شاخص، خشک‌سالی را بر اساس دو متغیر بارندگی (P) و تبخیر-تعرق پتانسیل (ETP) تخمین می‌زند. به همین دلیل توصیف دقیق‌تری از شرایط رطوبتی نسبت به شاخص‌هایی که فقط براساس بارش محاسبه می‌شوند، ارائه می‌کند. تاکنون مطالعات زیادی در زمینه استفاده از شاخص RDI در ارزیابی خشک‌سالی انجام گرفته که به برخی از آن‌ها اشاره می‌شود: Tigkas et al. (2016) نسخه‌ای اصلاح‌شده از شاخص RDI به نام RDIE ارائه دادند که در آن به جای پارامتر بارش، بارش موثر جایگزین گردیده است. نتایج نشان داد که با اصلاح شاخص، مقدار آبی که توسط سیستم‌های کشاورزی مورد بهره‌برداری قرار می‌گیرد، افزایش یافته و بهبود عملکرد این شاخص را برای تجزیه و تحلیل خشک‌سالی کشاورزی به دنبال خواهد داشت. Zarei et al. (2016) تغییرات الگوی مکانی خشک‌سالی را با استفاده از شاخص RDI در جنوب ایران مورد بررسی قرار دادند. نتایج نشان داد که وسعت مناطقی که شرایط خشک دارند، دارای روند رو به افزایش هستند.

AsadiZarch (2017) روند وقوع خشک‌سالی در استان یزد را در بین سال‌های ۲۰۰۹-۱۹۶۶ مورد بررسی قرار داد و خشک‌سالی را با استفاده از شاخص RDI در مقیاس زمانی ۳، ۶، ۹، ۱۲، ۱۸ و ۲۴ ماهه محاسبه نمود. نتایج نشان داد که وقوع خشک‌سالی در یزد در دوره آماری مورد نظر روندی افزایش داشته که ناشی از روند کاهش بارش و افزایش تبخیر-تعرق پتانسیل بوده است. برآورد اثرات و خسارات خشک‌سالی تا حد زیادی دشوار است. زیرا برخلاف سایر پدیده‌های مخاطره‌آمیز، تعیین دقیق زمان شروع و پایان خشک‌سالی مشکل است. بنابراین، اغلب خشک‌سالی را پدیده‌ای خزنده توصیف می‌کنند (Morie et al., 2005). بر این اساس، به دلیل ماهیت خشک‌سالی و بطئی بودن شروع و خاتمه آن، تشخیص و ارزیابی آن مشکل می‌باشد. پیش‌بینی خشک‌سالی در سیستم‌های منابع آب نقش مهمی در کاهش خسارات خشک‌سالی ایفا می‌نماید. به‌طور سنتی در چندین دهه اخیر برای پیش‌بینی خشک‌سالی از برازش و مدل‌های ریاضی به‌طور گسترده استفاده شده است. این مدل‌ها، سری‌های زمانی را به‌صورت مانا در نظر گرفته و فرایندها را به‌صورت خطی مدل‌سازی می‌کنند. بیشتر سیگنال‌های هیدرولوژیکی مخصوصاً فصلی و ماهانه و روزانه دارای مشخصات نالیستا، پرش، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آن‌ها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به نظر می‌رسد. در حالت کلی برای تشخیص اطلاعاتی که در سیگنال نهفته می‌باشد، باید از تبدیل‌کننده‌های ریاضی از قبیل سری فوریه استفاده نمود (Polikar, 1996). تبدیل موجکی تابعی است که نسخه بهبودیافته تبدیل فوریه (Fourier Transform) را تداعی می‌نماید. تبدیل فوریه در آنالیز

پتانسیل در ایستگاه کوهرنگ استفاده شد. مراحل محاسبه شاخص خشک‌سالی احيایی (RDI) به شرح زیر می‌باشد:

۱- محاسبه ETP با روش Hargreaves و Samani (1982) با رابطه زیر:

$$ETP = 0.0023 \times Ra \times (T_{\text{mean}} + 17.8) \times (T_{\text{max}} - T_{\text{min}})^{0.5} \quad (1)$$

که در آن، T_{max} و T_{min} و T_{mean} به ترتیب دمای حداکثر، حداقل و متوسط روزانه برحسب $^{\circ}\text{C}$ هستند و Ra حداکثر ممکن تابش خورشید به سطح زمین است که برحسب mm day^{-1} می‌باشند. Ghamarnia et al. (2012) نشان دادند برای مناطقی که به اندازه کافی بزرگ هستند و با استفاده از داده‌های مطمئن و تعداد کافی ایستگاه‌ها ضریب اولیه 0.023 استفاده شده در معادله هارگریوز-سامانی (Hargreaves-Samani) نیازی به تعدیل نداشته و می‌تواند با اطمینان بالا به کار برده شود.

۲- محاسبه مقادیر اولیه آماره a_0 برای بازه زمانی مورد نظر در سال‌های مختلف با استفاده از مقادیر نسبت بارش به تبخیرتقرق پتانسیل با رابطه زیر:

$$a_0^{(i)} = \frac{\sum_{j=1}^{12} P_{ij}}{\sum_{j=1}^{12} PET_{ij}} \quad (2)$$

که در آن، P بارش ماهانه بر حسب mm و ETP تبخیرتقرق پتانسیل در i امین ماه از سال i ام، برحسب mm می‌باشد. همچنین مقدار i از 1 تا N (تعداد سال‌های مورد بررسی) تغییر خواهد کرد.

وجود منابع آبی بسیار زیاد و یخچال‌های طبیعی، این شهر را می‌توان به‌عنوان یکی از پرآب‌ترین شهرهای ایران به حساب آورد. شهرستان کوهرنگ با مساحت 3790.25 کیلومتر مربع در موقعیت $29^{\circ} 56' 49''$ تا $37^{\circ} 26' 50''$ طول شرقی و $54' 59'' 31$ درجه تا $49^{\circ} 05' 33''$ عرض شمالی از نصف‌النهار گرینویچ در ارتفاع 2365 متری از سطح آزاد دریا قرار گرفته و میانگین بارش سالیانه در آن معادل 1308 میلی‌متر می‌باشد. این شهرستان از شمال به شهرستان شهرکرد و استان اصفهان و از جنوب به استان خوزستان، از شرق به شهرستان فارس و از شمال غرب به استان لرستان محدود شده است (شکل ۱).

شاخص خشک‌سالی احيایی (RDI)

این شاخص توسط Vangelis و Tsakiris (2005) ارائه شد. شاخص RDI از برازش توزیع لوگ‌نرمال بر نسبت بارندگی به تبخیرتقرق پتانسیل در بازه زمانی موردنظر به دست می‌آید. برای محاسبه شاخص RDI ابتدا باید مقدار تبخیرتقرق پتانسیل محاسبه گردد. برای تخمین تبخیرتقرق پتانسیل تاکنون روابط متعددی توسط محققان پیشنهاد شده که می‌توان به روش‌های پنمن مانیتث (FAO Penman-Monteith)، هارگریوز-سامانی (Hargreaves-Samani)، و تورنت وایت (Thornthwaite) (FAO-56) اشاره نمود. Zarei et al. (2013) در پژوهشی اثر چند مدل تابش خورشیدی را در برآورد تبخیرتقرق مرجع چمن در دشت شهرکرد مورد بررسی قرار دادند و در نهایت روش هارگریوز-سامانی را برای محاسبه تبخیرتقرق پتانسیل در دشت شهرکرد پیشنهاد دادند. لذا در این پژوهش نیز از روش Hargreaves و Samani (1982) برای محاسبه تبخیرتقرق

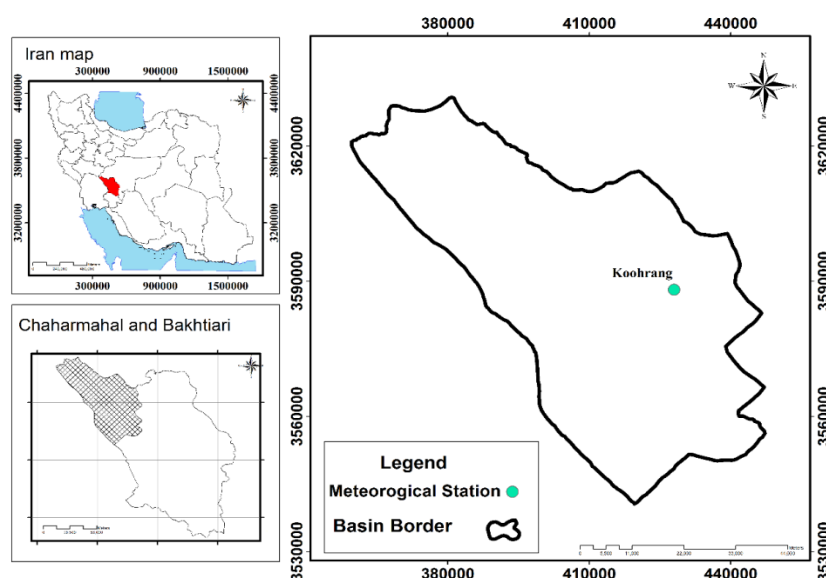


Fig. 1- Koohrang cities location in Chaharmahal and Bakhtiari province.

شکل ۱- موقعیت شهرستان کوهرنگ در استان چهارمحال و بختیاری.

اساس بسیاری از واحدهای پردازش به نام نرون یا گره انجام می‌شود. با استفاده از یک استدلال ریاضیاتی می‌توان اثبات نمود که از بین شبکه‌های عصبی مصنوعی پرسپترون چندلایه (MLP, multilayer perceptron) شبکه‌های MLP سه لایه، برای تخمین هر تابع پیچیده غیرخطی مناسب هستند (Mason et al., 1996). در تحقیق حاضر، برای پیش‌بینی داده‌های ماهانه بارندگی و تبخیرتغرق پتانسیل، از یک شبکه MLP سه لایه که توابع محرک لایه‌های میانی و خروجی آن به ترتیب تانژانت سیگموئید و خطی در نظر گرفته شده، استفاده گردید. لازم به توضیح است در مطالعه حاضر، هدف پیش‌بینی افق یک ماهه دو متغیر مذکور با بهره‌گیری از تاخیرهای مناسب هر یک از این متغیرها می‌باشد. در گام بعدی برای تعیین بهترین ورودی به مدل، بهترین الگوی ورودی به شبکه از طریق استفاده از توابع خودهمبستگی (Auto Correlation Function) و خودهمبستگی جزئی (Partial Auto Correlation Function) مشخص شد و از روش آزمون و خطا، برای انتخاب الگوی ورودی برتر استفاده شد. هم‌چنین برای نرمال‌سازی داده‌ها از رابطه زیر در محیط نرم افزار متلب استفاده گردید:

$$Y = \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) \times (Y_{\max} - Y_{\min}) + Y_{\min} \quad (5)$$

که در آن، Y داده‌های نرمال شده، X داده‌های خام اولیه، X_{\max} و X_{\min} به ترتیب مقدار حداقل و حداکثر داده‌های اولیه و Y_{\max} و Y_{\min} به ترتیب حد پایینی و حد بالایی دامنه تغییرات داده‌های تبدیل شده می‌باشند. در مرحله بعد داده‌های ماهانه بارندگی و تبخیرتغرق از سال ۱۹۸۸ تا آخر سال ۲۰۱۵ به‌عنوان داده‌های آموزش شبکه و از سال ۲۰۱۶ به‌عنوان داده‌های آزمون شبکه مورد استفاده قرار گرفتند. هم‌چنین تعداد بهینه نرون لایه میانی یا پنهان از طریق سعی و خطا بین یک تا ده نرون انجام گردید. نهایتاً پس از مرحله واسنجی، نتایج حاصل از تست شبکه‌های آموزش‌دیده به‌وسیله شاخص‌های آماری R^2 و RMSE مورد ارزیابی قرار گرفت.

۳- محاسبه RDI نرمال شده (RDI_n) با رابطه زیر:

$$RDI_n^{(i)} = \frac{a_0^{(i)}}{\bar{a}_0} - 1 \quad (3)$$

که در آن، \bar{a}_0 میانگین حسابی اعداد a_0 در هر سال است.

۴- محاسبه RDI استاندارد شده (RDI_{st}) با فرض این که مقادیر a_0 از توزیع لوگ نرمال پیروی می‌کنند از رابطه زیر:

$$RDS_{st}^{(i)} = \frac{y^{(i)} - \bar{y}}{\sigma_y} \quad (4)$$

که در آن، y_1 برابر است $\ln(a_0^{(i)})$ و \bar{y} و σ_y به ترتیب انحراف معیار و میانگین حسابی $y^{(i)}$ می‌باشند. این شاخص می‌تواند با در نظر گرفتن مقیاس‌های مختلف زمانی و به‌صورت سالانه وضعیت خشک‌سالی را پایش نماید. پس از تعیین مقادیر RDI در مقیاس-های زمانی مختلف در هر یک از ماه‌ها و ایستگاه‌ها، مقادیر کمی شاخص توسط طبقه‌بندی ارائه شده در جدول (۱) توصیف می‌گردد. این طبقه‌بندی جهت تعیین شدت‌های خشک‌سالی براساس شاخص SPI ارائه شده است (Mckee et al., 1993).

در این پژوهش، برای ارزیابی خشک‌سالی‌های هواشناسی در منطقه کوه‌رنگ، مقدار شاخص RDI در مقیاس‌های زمانی یک، سه، شش و ۱۲ ماهه محاسبه گردید. بعد از پیش‌بینی داده‌های ماهانه بارندگی و تبخیرتغرق پتانسیل (ETP) در منطقه مورد نظر، این شاخص با داده‌های پیش‌بینی شده نیز محاسبه و ارزیابی گردید.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی مدلهای ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به‌کار برده شوند. هم‌چنین این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاهت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند. توانایی کلی شبکه عصبی مصنوعی، یادگیری ارتباط غیرخطی بین داده‌ها و تعیین نتایج برای داده‌های دیگر است (Nourani et al., 2009a,b). پردازش در این شبکه‌ها بر-

جدول ۱- طبقه‌بندی شاخص RDI و تعریف کلاس‌های متناظر با آن

Table 1- Drought classification according to RDI values

RDI range	Drought Classes
2 or more	Extremely wet
1.5 to 1.99	Very wet
1 to 1.49	Moderately wet
0.99 to -0.99	Normal
-1 to -1.49	Moderately dry
-1.5 to -1.99	Severely dry
-2 and less	Extremely dry

پرسپترون چندلایه در مطالعات هیدرولوژیکی، در این روش از شبکه پرسپترون سه لایه استفاده گردید. سپس سطح تجزیه مناسب از رابطه زیر محاسبه شد:

$$L = \text{INT}[\log(N)] \quad (7)$$

در رابطه فوق، L تعداد سطح تجزیه، N طول سری داده‌های اولیه و INT عملگر صحیح (Integer Operator) می‌باشد (Wang and Ding, 2003). مشابه با مدل ANN عمل نرمال‌سازی داده‌ها از رابطه (7) صورت گرفت و تعیین بازه زمانی داده‌های ماهانه بارندگی و تبخیرتغرق پتانسیل به‌عنوان داده‌های آموزش و آزمون و همچنین تعداد بهینه نرون لایه میانی نیز مشابه با مدل ANN انجام شد. نهایتاً در مرحله آخر آزمون شبکه‌های آموزش دیده به‌وسیله شاخص‌های آماری ضریب تعیین (R^2) و ریشه میانگین مربعات خطا (RMSE) مورد ارزیابی قرار گرفت. در این پژوهش برای پیش‌بینی خشک‌سالی با استفاده از مدل‌های ANN و WANN، تابع خودهمبستگی جزئی (شکل ۳) و خودهمبستگی (شکل ۴) برای داده‌های ماهانه بارندگی و تبخیر-تغرق پتانسیل رسم شد. خطوط خط چین قرمز موجود در شکل‌ها، باند اطمینان ۹۵ درصد را نشان می‌دهند. طبق این نمودارها، مشاهده شد که تقریباً بعد از ۱۲ ماه، این داده‌ها در باند اطمینان قرار می‌گیرند و خطوط باند را قطع نمی‌کنند. بنابراین همبستگی معنی‌دار نیست. به‌همین دلیل داده‌های ماهانه بارندگی و تبخیر-تغرق پتانسیل، بعد از ۱۲ ماه تاخیر، به عنوان ورودی به مدل معرفی شدند. ساختار مدل‌های ریاضیاتی مورد استفاده به‌منظور تخمین متغیرهای بارش و تبخیرتغرق ماهانه به ترتیب در روابط (۸) و (۹) آرایه شده است.

$$\text{Model (1): } P_t = f(P_{t-1}, P_{t-2}, P_{t-3}, P_{t-4}, P_{t-5}, P_{t-6}, P_{t-7}, P_{t-8}, P_{t-9}, P_{t-10}, P_{t-11}, P_{t-12}) \quad (8)$$

$$\text{Model (1): } ETP_t = f(ETP_{t-1}, ETP_{t-2}, ETP_{t-3}, ETP_{t-4}, ETP_{t-5}, ETP_{t-6}, ETP_{t-7}, ETP_{t-8}, ETP_{t-9}, ETP_{t-10}, ETP_{t-11}, ETP_{t-12}) \quad (9)$$

که در آن، پارامترهای ETP و P به‌ترتیب داده‌های ماهانه تبخیرتغرق پتانسیل و بارش هستند. نمایه‌های t ، $t-1$ ، $t-2$ ، $t-3$ ، ... و $t-12$ به‌ترتیب ماه جاری، یک ماه تاخیر، دو ماه تاخیر، سه ماه تاخیر، ... و دوازده ماه تاخیر را نشان می‌دهند.

مدل‌های تلفیقی موجک و شبکه عصبی مصنوعی


مدل‌های تلفیقی موجک و شبکه عصبی مصنوعی، مدل‌های ANN ای هستند که هر کدام از متغیرهای ورودی آن‌ها به‌وسیله تابع موجک گسسته به چند زیرسری تجزیه شده است (Adamowski and Sun, 2010). تحقیقات اخیر در زمینه هیدرولوژی و منابع آب نشان داده است که در تجزیه سری زمانی هیدرولوژیکی، استفاده از موجک دابچیز مرتبه چهار یا $Db4$ ، به‌عنوان موجک مادر، نتایج رضایت بخشی حاصل می‌کند (Nourani et al., 2009a,b).

در روش تبدیل موجک گسسته (DWT, Discrete Wavelet Transform) در مقایسه با تبدیل موجک پیوسته (CWT, Continuous wavelet transform) در اجرا ساده‌تر و محاسبات آن در زمان کوتاه‌تری انجام می‌گیرد. در روش DWT معمولاً مقادیر پارامترهای مقیاس و انتقال به صورت توان‌های از عدد دو می‌باشند. در اصطلاح به آن‌ها پارامترهای انتقال و اتساع دوتایی (Dyadic) گفته می‌شود. شکل گسسته تابع موجک به صورت زیر تعریف می‌شود:

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{|S_0^j|}} \Psi\left(\frac{t - k\tau_0 S_0^j}{S_0^j}\right) \quad (6)$$

که در آن، k و z اعدادی صحیح، $S_0 > 1$ گام ثابت اتساع و τ_0 گام ثابت انتقال زمان می‌باشد (Cannas et al, 2006). الگوریتم‌های مالات (Algorithm Mallat) و تروس (Trous Algorithm) از جمله الگوریتم‌های استفاده‌شده به‌منظور اجرای روش DWT می‌باشند (Mallat, 1989). در این پژوهش، از الگوریتم مالات یا آنالیز چندتفکیکی (Multi Resolution Analysis) برای اجرای روش DWT استفاده شد. در این روش فرکانس‌های پایین و بالای سیگنال به‌ترتیب با استفاده از فیلترهای کوتاه‌گذر (Low-Pass Filters) و بلندگذر (High Pass Filters) تفکیک می‌شوند. به محتوای فرکانس‌های پایین و بالای سیگنال به‌ترتیب تقریب (Approximation) و جزئیات (Details) گفته می‌شود. فرایند فیلتر کردن تا رسیدن به سطح تجزیه مطلوب ادامه می‌یابد (شکل ۲). با اعمال DWT واریانس سری‌های زمانی اولیه به زیرسری‌های تقریب و جزئیات منتقل شده و هیچ‌گونه اطلاعاتی از سری زمانی اولیه از بین نخواهد رفت (Labat et al, 2005). به‌طوری‌که با استفاده از تبدیل معکوس موجک گسسته (Inverse Discrete Wavelet Transform) می‌توان با دقت بالایی سری زمانی اولیه را بازسازی نمود (Daubechies, 1992).

در بخش روش توسعه مدل‌های تخمین بارش و تبخیرتغرق پتانسیل به‌وسیله مدل‌های ANN، WANN، میزان بارش و تبخیرتغرق پتانسیل در هر دو مدل تابعی از مشاهدات قبلی آن‌ها در ایستگاه کوه‌رنگ فرض شد و با توجه به قابلیت‌های شبکه



S : The original signal \downarrow_2 : Downsampling operator
 Lo-D : Low pass filter cAj : Approximation coefficients at jth level of decomposition
 Hi-D : High pass filter cDj : Details coefficients at jth level of decomposition

Fig. 2- Schematic image of multiple separation signal analysis.

شکل ۲- نمایش شماتیک آنالیز چند تفکیکی سیگنال.

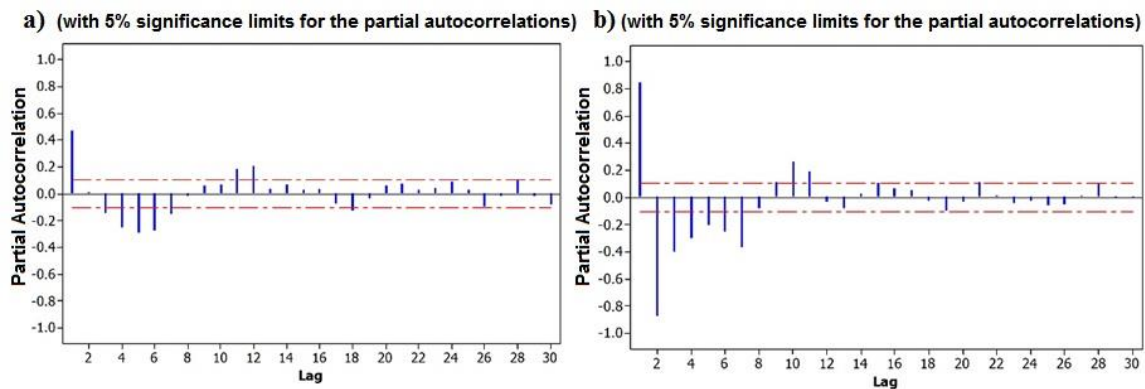


Fig. 3- Partial autocorrelation function for monthly (a) rainfall data, (b) ETP data in Koohrang station.

شکل ۳- تابع خودهمبستگی جزئی داده‌های ماهانه a-بارندگی، b-تبخیر تعرق پتانسیل در ایستگاه کوهرنگ.

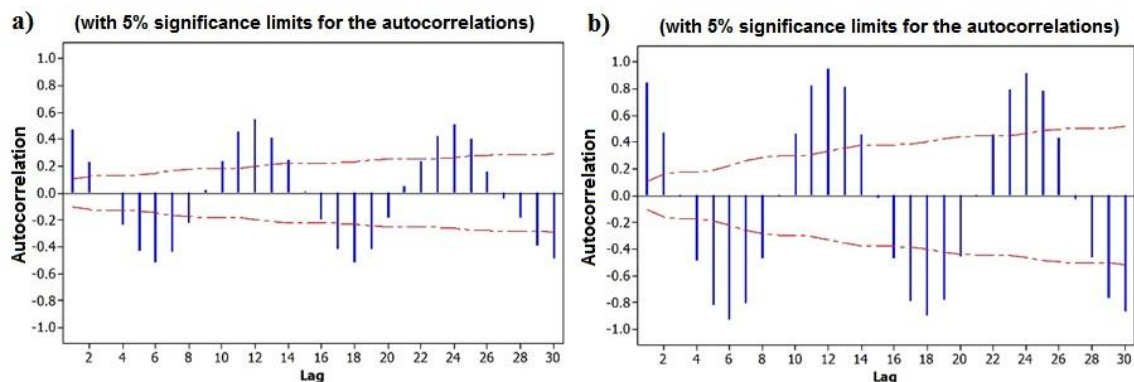


Fig. 4- Autocorrelation function for monthly (a) rainfall data, (b) ETP data in Koohrang station.

شکل ۴- تابع خودهمبستگی داده‌های ماهانه a-بارندگی، b-تبخیر تعرق پتانسیل در ایستگاه کوهرنگ.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (11)$$

که در آن، y_i مقدار مشاهداتی، \hat{y}_i مقدار تخمینی از مدل و N تعداد مشاهدات است. مقادیر کمتر شاخص RMSE نشان‌دهنده عملکرد بهتر مدل می‌باشد.

نتایج و بحث

در شکل (۵) نتایج مقادیر پیش‌بینی شده بارش و تبخیر تعرق پتانسیل توسط مدل‌های ANN و WANN در مرحله آزمون در برابر مقادیر مشاهداتی رسم شده است. همان‌گونه که در شکل (۵) مشاهده می‌شود، مدل ANN مقادیر بارش را کمتر از مقادیر واقعی پیش‌بینی کرده است که این ضعف در مقادیر حدی (بارش-های کم و زیاد) حادث می‌باشد. درحالی‌که عملکرد مدل WANN در پیش‌بینی بارش بهبود یافته است. نتایج عملکرد مدل‌های در مراحل آموزش و آزمون در جدول (۲) ارایه شده‌اند.

معیار کارایی مدل‌ها

بعد از کالیبراسیون مدل‌ها با استفاده از مجموعه داده‌های آموزش می‌توان کارایی آن‌ها را با معیارهای خطا ارزشیابی نمود. در این پژوهش از معیارهای مرسوم R^2 (coefficient of determination) و RMSE (Root Mean Square Error) استفاده شد. مقادیر بالاتر R^2 (حداکثر مقدار برابر با ۱ است)، نشان‌دهنده عملکرد بهتر مدل می‌باشد. ضریب R^2 به شرح زیر تعریف می‌شود:

$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (10)$$

که در آن، y_i مقدار مشاهداتی، \hat{y}_i مقدار تخمینی از مدل، N تعداد مشاهدات و \bar{y}_i مقدار میانگین مشاهدات می‌باشد. جذر میانگین مربعات خطا (RMSE)، واریانس خطاها را مستقل از اندازه نمونه ارزیابی می‌کند و به صورت زیر تعریف می‌شود:

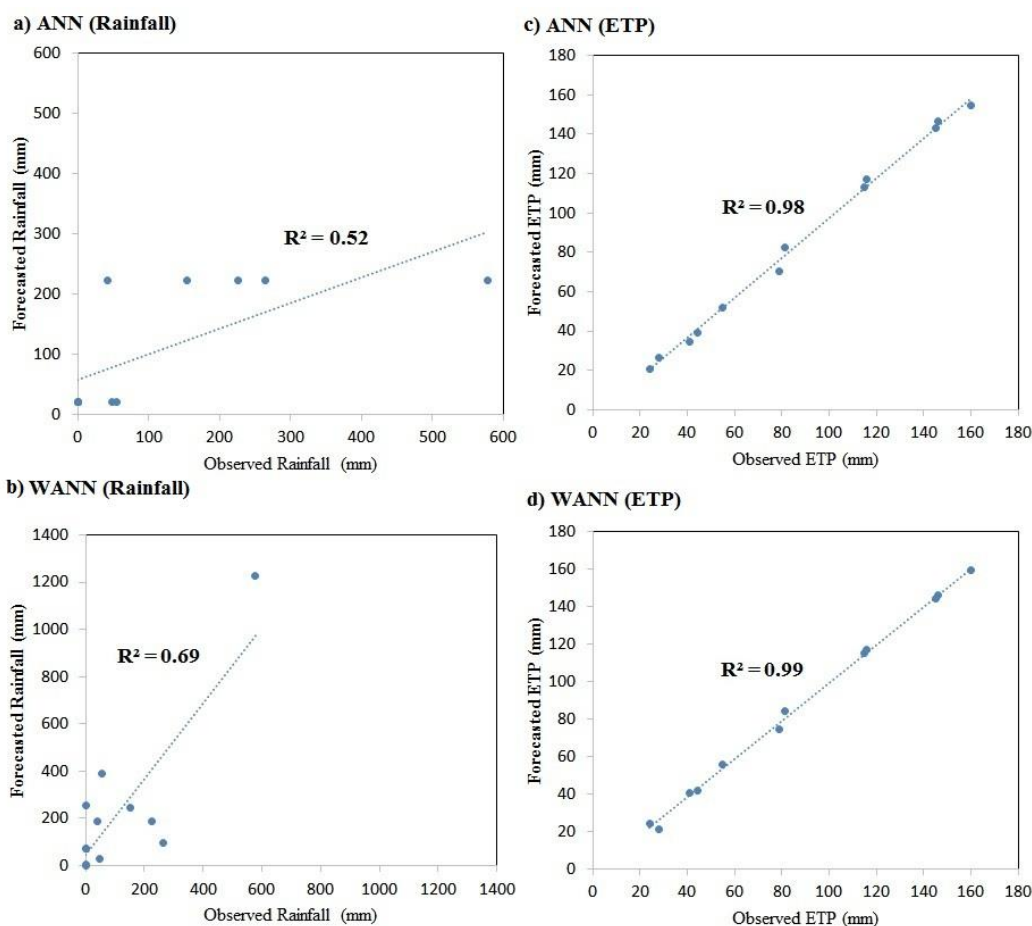


Fig. 5- The forecasted values of monthly rainfall by a) ANN and b) WANN model, and monthly ETP by c) ANN and d) WANN models versus observed values in the test phase

شکل ۵- مقادیر پیش‌بینی شده بارش ماهانه (a) توسط مدل‌های ANN و (b) WANN (ب و تبخیر تعرق پتانسیل ماهانه c) توسط مدل‌های ANN و (d) WANN در مرحله آزمون در برابر مقادیر مشاهداتی

جدول ۲- نتایج ارزیابی مدل های ANN و WANN برای پیش بینی داده های ماهانه بارش و تبخیر تعرق پتانسیل
Table 2- Results of ANN and WANNs models evaluation for predict monthly rainfall and ETP data

RMSE (mm)	R ²	appraisement	model
91.67	0.54	train	ANN
118.72	0.52	test	(Rain)
4.10	0.99	train	ANN
5.51	0.98	test	(ETP)
19.59	0.71	train	WANN
28.55	0.69	test	(Rain)
0.79	0.99	train	WANN
2.59	0.99	test	(ETP)

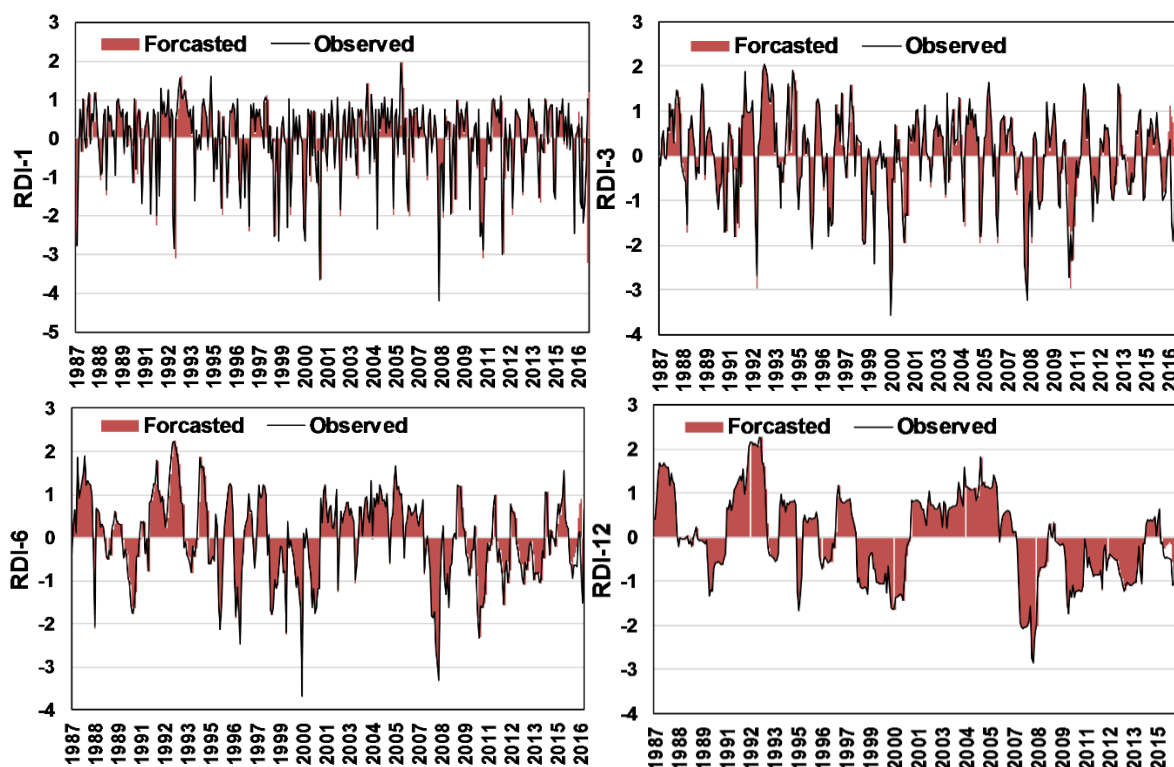


Fig. 6- RDI time series on a 1-month, 3-month, 6-month, and 12-month scale at Koohrang Station.

شکل ۶- سری زمانی شاخص RDI در مقیاس زمانی یک ماهه، سه ماهه، شش ماهه و ۱۲ ماهه در ایستگاه کوهرنگ

و قابل قبول تر است. بنابراین، واضح است که مدل WANN نسبت به ANN در پیش بینی داده های ماهانه بارش و تبخیر تعرق پتانسیل کارایی بیشتری دارد و از دقت بالاتری برخوردار است. از این رو، در این پژوهش برای پیش بینی داده های ماهانه بارش و تبخیر تعرق پتانسیل در سال ۲۰۱۶ از مدل WANN استفاده شد. سپس با استفاده از داده های بارش و تبخیر تعرق پتانسیل پیش بینی شده، مقادیر شاخص RDI محاسبه گردید.

شکل (۶) سری زمانی شاخص RDI در مقیاس های زمانی یک، سه، شش و ۱۲ ماهه را در ایستگاه کوهرنگ نمایش می دهند. بعد از پیش بینی داده های ماهانه بارش و تبخیر تعرق پتانسیل با استفاده از

بر اساس نتایج به دست آمده در جدول (۲) اگرچه مدل ANN در پیش بینی داده های تبخیر تعرق پتانسیل عملکرد مناسبی داشته است (مقدار خطای آن کم و میزان R² آن در مرحله آموزش و آزمون به یک نزدیک است)، اما در پیش بینی داده های بارش موفقیت چندانی نداشته و بیشترین مقدار RMSE معادل ۹۱/۶۷ میلی متر در مرحله آموزش و ۱۱۸/۷۲ میلی متر در مرحله آزمون را به همراه داشته است. اما مدل WANN در پیش بینی داده های مورد نظر هم در مرحله آموزش و هم در مرحله آزمون عملکرد بهتری داشته است. بیشترین مقدار R² نیز در این مدل و برای پیش بینی داده های تبخیر تعرق پتانسیل به دست آمده است. میزان خطای آن هم از مدل قبلی کمتر

شبکه عصبی مصنوعی به خاطر در اختیار داشتن کرنل غیرخطی توانایی مدل‌سازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی‌های نایستایی و غیرخطی بودن داده‌های بارش و تبخیرترعق پتانسیل، به منظور شبیه‌سازی دقیق از مدل WANN استفاده شد. زیرا شبکه عصبی مصنوعی به تنهایی قادر به غلبه بر نایستایی سیگنال نمی‌باشد. درحالی‌که تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پایین، ویژگی‌های چندمقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. در مرحله آخر با استفاده از داده‌های پیش‌بینی شده در مدل WANN شاخص RDI محاسبه شد. نتایج نشان داد که مدل WANN در پیش‌بینی داده‌های ماهانه بارش و تبخیرترعق پتانسیل از دقت قابل‌قبولی برخوردار می‌باشد. لذا از این روش می‌توان برای پیش‌بینی خشک-سالی جهت مدیریت بهتر منابع آب و اتخاذ تصمیمات مناسب برای مقابله با خشک‌سالی استفاده نمود.

تشکر و قدردانی

نویسندگان مقاله بدینوسیله از حمایت مالی معاونت پژوهش و فناوری دانشگاه شهرکرد (در قالب پژوهانه شماره 97GRN1M1692) از این مطالعه و همچنین سازمان هواشناسی ایران و شرکت مدیریت منابع آب ایران به خاطر در اختیار قرار دادن اطلاعات موردنیاز تشکر می‌نمایند.

مدل WANN در سال ۲۰۱۶، این شاخص با داده‌های پیش‌بینی شده نیز محاسبه گردید و با هم مقایسه شدند. با توجه به این که پیش‌بینی داده‌های بارش دشوار است، همان‌طور که در شکل مشاهده می‌شود در مدل WANN پیش‌بینی بارش تا حدود قابل‌قبولی با موفقیت روبه‌رو بوده است. در سری زمانی یک‌ماهه و سه‌ماهه داده‌های پیش‌بینی شده نسبت به داده‌های واقعی خشک‌سالی بیشتری نشان داده‌اند. در مقیاس زمانی شش و ۱۲ ماهه پیش‌بینی داده‌های مورد-نظر به واقعیت نزدیک‌تر بوده است.

نتیجه‌گیری

نتایج حاصل از بررسی‌های صورت گرفته در این پژوهش نشان می‌دهد که شبکه WANN نسبت به مدل ANN با دقت مناسب‌تری تغییرات شاخص خشک‌سالی را پیش‌بینی می‌کند. Cannas et al. (2006) نیز در تحقیقی برای تخمین جریان ماهانه رودخانه‌ای در ایتالیا، در یک دوره آماری ۶۹ ساله از مدل WANN استفاده کردند. نتایج نشان داد پیش‌پردازش‌های صورت-گرفته توسط روش‌های آنالیز موجک، خصوصاً در حالت گسسته تأثیر به‌سزایی در افزایش دقت مدل‌های ANN دارد که با نتایج تحقیق حاضر نیز مطابقت دارد. دقت بالاتر مدل WANN نه تنها به خاطر پیش‌پرداز و پارتیشن‌بندی موجک به زیر سیگنال‌های مختلف است، بلکه علت آن می‌تواند بخاطر توجه به تأثیر هر زیر سیگنال تجزیه‌ای به‌وسیله بزرگنمایی نسبی وزن آن زیر سیگنال باشد. با این که مدل

References

- Adamowski, J. and Sun, K., 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390, pp.85-91.
- Anshuka, A. Floris, F. and Rutger, W., 2019. Drought forecasting through statistical models using standardised precipitation index: a systematic review and meta-regression analysis. *Journal of the International Society for the Prevention and Mitigation of Natural Hazards*, 97, pp.955-977.
- AsadiZarch, M.A., 2017. Analyzing climate change effects on drought occurrence in Yazd province, Iran. *Scientific Association of Desert Management and Control*, 9, pp.74-90. (In Persian).
- Cannas, B., Fanni, A., See, L. and Sias, G., 2006. Data preprocessing for river flow forecasting using neural network, wavelet transforms and data partitioning. *Physics and Chemistry of the Earth*, 31(18), pp.1164-1171.
- Daubechies, I., 1992. Ten lectures on wavelets. In *CBMS-NSF Regional Conference Series in Applied Mathematics* 61. Philadelphia, PA. USA.
- Djerbouai, S. and Souag-Gamane, D., 2016. Drought forecasting using neural networks, Wavelet neural networks, and stochastic nodels. *Water Resources Management*, 30, pp.2445-2464.

- 6- Ghamarnia, H., Rezvani, V., Khodaei, E. and Mirzaei, H., 2012. Time and place calibration of the Hargreaves equation for estimating monthly reference evapotranspiration under different climatic conditions. *Journal of Agricultural Science*, 4(3), pp.111-122. (In Persian).
- 7- Hargreaves, G.H. and Samani, Z.A., 1982. Estimating potential evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 108, pp.223-230.
- 8- Hassanzadeh, Y., Abdi Kordani, A. and Fakheri Fard, A., 2013. Drought forecasting using genetic algorithm and conjoined model of neural network-wavelet. *Journal of Water and Wastewater*, 23, pp.48-59. (In Persian).
- 9- Labat, D., Ronchail, J. and Guyot, J.L., 2005. Recent advances in wavelet analyses: Part 2-Amazon, Parana, Orinoco and Congo discharges time scale variability. *Journal of Hydrology*, 314, pp.289-311.
- 10- Mallat, S.G., 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11, pp.674-693.
- 11- Mason, J.C., Price, R.K. and Tem, M.E., 1996. A neural network model of rainfall-runoff using radial basis functions. *Journal of Hydraulic Research*, 34, pp.537-548.
- 12- Mckee, T.B., Doesken, N.J. and Kleist, J., 1993. The relationship of drought frequency and duration on time scales. In *8th Conference on Applied Climatology*, Anaheim university, California.
- 13- Mendicino, G., Senatore, A. and Versace, P., 2008. A groundwater resource index (GRI) for drought monitoring and forecasting in a Mediterranean climate. *Journal of Hydrology*, 357, pp.282-302.
- 14- Moried, S., Moghaddasi, M., Paemozd, S.H. and Ghaemi, H., 2005. Designing drought monitoring system of Tehran province. *Applied Research Report Ministry of Energy*.
- 15- Nourani, V., Komasi, M. and Mano, A., 2009a. A multivariate ANN-Wavelet approach for rainfall-runoff modeling. *Water Resources Management*, 23, pp.2877-2894.
- 16- Nourani, V., Alami, M.T. and Aminfar, M.H., 2009b. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Journal of Engineering Application of Artificial Intelligence*, 22, pp.466-472. (In Persian).
- 17- Palmer, W.C., 1965. Meteorological drought. Research Paper No. 45. *US Department of Commerce Weather Bureau*. Washington DC.
- 18- Polikar, R., 1996. *Fundamental concept and an overview of the wavelet theory wavelet tutorial*. Rowan University. Glassboro.
- 20- Razinei, T., Daneshkar, A., Akhtari, R. and Saghafian, B., 2007. Investigation of meteorological droughts in the Sistan and Balouchestan province using the standardized precipitation index and Markov chain model. *Water Resources Research*, 3(1), pp.25-35. (In Persian).
- 21- Sifuzzaman, M., Islam, M.R. and Ali, M.Z., 2009. Application of wavelet transform and its advantages compared to fourier transform. *Journal of Physical Sciences*, 13, pp.121-134.
- 22- Thuillard, M., 2000. *A review of wavelet networks, wavelet, fuzzy wavelet and their application*. ESIT 2000 Aachen. Germany.
- 23- Tigkas, D., Vangelis, H. and Tsakiris, G., 2016. Introducing a modified reconnaissance drought index (RDIE) incorporating effective precipitation. *Procedia Engineering*, 162, pp.332-339.

-
- 24- Tsakiris, G. and Vangelis, H., 2005. Establishing a drought index incorporating evapotranspiration. *European Water*, 10, pp.3-11.
- 25- Wang, W. and Ding, J., 2003. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1, pp.67-71.
- 26- Zarei, A.R., Moghimi, M.M. and Mahmoudi, M.R., 2016. Analysis of changes in spatial pattern of drought using RDI index in south of Iran. *Water Resources Management*, 11, pp.3723-3743. (In Persian).
- 27- Zarei, M.A., Tabatabaei, S.H., Babazadeh, H. and Sedghi, H., 2013. Determining the best radiation model for Hargreaves-Samani equation in Shahrekord plain under Lysimeter condition. *Journal of Water Research*, 3(9), pp.47-56.
- 28- Zhang, Y., Li, W., Chen, Q., Pu, X. and Xiang, L., 2017. Multi-models for SPI drought forecasting in the north of Haihe River Basin, China. *Stochastic Environmental Research and Risk Assessment*, 31, pp.2471-2481.