

EXTENDED ABSTRACT

Drought Simulation using Two CEEMD-GPR and GPR-GARCH Integrated Models (Case Study: Northwest of Iran)

K. Roushangar^{1*} and R.Ghasempour²

1*- Corresponding Author, Professor, Department of Civil Engineering, University of Tabriz, Iran. (kroshangar@yahoo.com).
2- PhD candidate, Department of Civil Engineering, University of Tabriz, Tabriz, Iran

ARTICLE INFO

Article history:

Received: 8 June 2019

Revised: 3 December 2019

Accepted: 9 December 2019

Keywords:

Drought, Empirical mode, GPR,
Nonlinear time series, Rainfall,
SPI.

TO CITE THIS ARTICLE:

Roushangar, K., Ghasempour, R. (2021). 'Drought Simulation using Two CEEMD-GPR and GPR-GARCH Integrated Models (Case Study: Northwest of Iran)', Irrigation Sciences and Engineering, 44(1), pp. 77-92. doi: 10.22055/jise.2019.29568.1846

Introduction

Drought is one of the most important natural disasters affecting agriculture section and water resources. Droughts often occur in arid and semi-arid regions. Therefore, drought forecasting is necessary and plays an important role in the planning and management of water resources. So far, numerous drought prediction methods have been proposed in the literature, including time series models, regression models, probabilistic models, machine learning models, physical models, and a host of hybrid models. Although all of these methods have shown promising results in terms of improving accuracy of drought forecasts, the impact of climate change on droughts has highlighted the need for more advanced methods for predicting this event. Engle (1982) proposed the ARCH model which can depict the variance of the time series and eliminate the heteroskedasticity caused by the constant time series variance. The GARCH model was further developed based on the ARCH model, the advantage of which is that it can use a simpler form to represent a high-order ARCH model. On the other hand, in recent years, the Meta model approaches have been applied in investigating the hydraulic and hydrologic complex phenomena. Hybrid models involving signal decomposition have also been found to be effective in improving prediction accuracy of time series prediction methods (Amirat et al., 2018). Complementary Ensemble Empirical Mode Decomposition analysis is one of the widely-used signal decomposition methods for hydrological time series prediction. Decomposition of time series reduces the difficulty of forecasting, thereby improving forecasting accuracy.

Due to the complexity of the drought phenomenon and the effect of various parameters on its prediction, in this study, the capability of GPR as a kernel-based approach and also integrated CEEMS-GPR and GPR-GARCH models were assessed for drought modeling based on six-month SPI index for the three cities of Tabriz, Urmia, and Ardabil in Iran during the period 1978-2017. In fact, this study attempts to create a novel method by combining the CEEMD and GARCH models with the GPR to enhance the estimation accuracy of the six- month SPI drought index.

Methodology

In this study, monthly rainfall data from the three stations namely Tabriz, Urmia, and Ardabil was used during the period 1978-2017. The time series of the drought SPI index was calculated in the period of 6 months. GPR models are based on the assumption that adjacent observations should convey information about each other. Gaussian processes are a way of specifying a prior directly over function space. This is a natural generalization of the Gaussian distribution, whose mean and covariance are a vector and matrix, respectively. The Gaussian distribution is over vectors, whereas the Gaussian process is over functions. Thus, due to prior knowledge about the data and functional dependencies, no validation process is required for generalization, and GP regression models are able to understand the predictive distribution corresponding to the test input (Ramussen & William, 2006). In most hydrological studies, the main attention is focused on the mean of the data. However, little attention has been paid to the variance changes over time. Regarding the progress of conducted studies on the field of risk and uncertainty in water resources engineering, it is essential to develop modeling techniques for considering the variance changes with respect to time. The GARCH is a non-linear time series model for modeling the variance changes over the time. In fact, GARCH is a generalized ARCH which was presented by Engle (1982). CEEMD was proposed to solve the mode mixing issue of empirical mode decomposition (EMD) which specifies the true IMF as the mean of an ensemble of trials (Wu & Huang, 2009). Each trial consists of the decomposition results of the signal plus a white noise of finite amplitude. EMD can be used to decompose any complex signal into finite intrinsic mode functions and a residue, resulting in subtasks with simpler frequency components and stronger correlations that are easier to analyze and forecast. Another important feature of empirical mode decomposition is that it can be used for noise reduction of noisy time series, which can be effective in improving the accuracy of model predictions.

Results and Discussion

In order to evaluate and review the performance of the tested models and determine the accuracy of the selected models, four performance criteria named Correlation Coefficient (CC), Determination Coefficient (DC), Root Mean Square Errors (RSME), and Mean Absolute Percentage Error (MAPE) were used according to Table (1). The results indicated that the accuracy of both integrated CEEMD-GPR and GPR-GARCH models was higher than that of the GPR model. The use of these two methods decreased the error criteria as much as 25 to 40 %. It was observed that in predicting droughts, climatic elements including mean monthly temperature and relative humidity as well as SPI index related to the previous months were effective in the prediction of SPI index. During modeling by the GARCH method, the deterministic part of SPI time series was estimated using the GPR whereas the random part was determined via the GARCH model. From the results, it was observed that the SPI drought index can be simulated by considering the SPI_{t-1} as the only input variable using GPR-GARCH model.

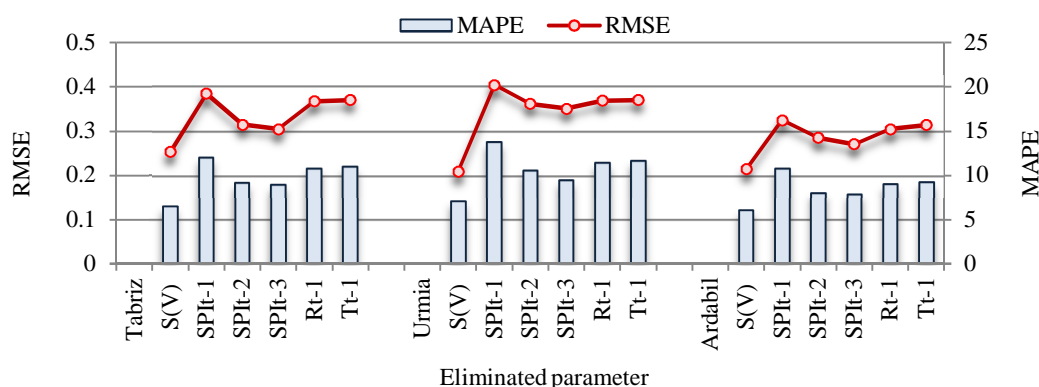
According to Fig. (1), sensitivity analysis was performed to determine the most significant parameters in modeling process. It was observed that SPI_{t-1} is the most effective parameter in modeling.

Conclusions

The comparison of the accuracies of the developed models revealed that both integrated CEEMD-GPR and GPR-GARCH models had higher performance compared with the single GPR model in predicting the six-month SPI index. The use of these two methods approximately decreased the error criteria between 25 to 40 %. Also, based on the sensitivity analysis, SPI_{t-1} was found to be the most effective parameter in the modeling process.

Table 1- Statistical parameters results for test series based on the integrated methods

Model	Performance criteria							
	CEEMD-GPR			MAPE	GPR-GARCH			
	R	DC	RMSE		R	DC	RMSE	MAPE
Tabriz								
S(I)	0.752	0.638	0.338	13.66	0.931	0.851	0.216	9.450
S(II)	0.804	0.793	0.305	12.52	0.841	0.801	0.270	10.31
S(III)	0.862	0.845	0.289	9.330	0.905	0.859	0.257	9.860
S(IV)	0.866	0.848	0.283	7.760	0.903	0.859	0.254	7.140
S(V)	0.871	0.852	0.282	7.130	0.908	0.861	0.251	6.980
Urmia								
S(I)	0.755	0.730	0.397	14.69	0.899	0.881	0.306	11.55
S(II)	0.816	0.887	0.356	13.28	0.872	0.811	0.325	12.21
S(III)	0.849	0.854	0.352	12.14	0.886	0.889	0.215	9.410
S(IV)	0.854	0.857	0.340	10.96	0.885	0.890	0.211	7.940
S(V)	0.858	0.861	0.334	10.29	0.889	0.891	0.209	7.050
Ardabil								
S(I)	0.733	0.626	0.346	12.93	0.899	0.864	0.221	8.620
S(II)	0.754	0.812	0.298	11.28	0.814	0.799	0.264	10.10
S(III)	0.793	0.842	0.288	9.340	0.899	0.878	0.218	7.039
S(IV)	0.797	0.843	0.284	7.790	0.888	0.879	0.214	6.140
S(V)	0.801	0.849	0.277	6.990	0.887	0.879	0.210	6.080

**Fig. 1- Relative significance of each of the input parameters of the best model****Acknowledgement**

The authors hereby thank the support of Tabriz university in conducting this research.

References

- 1- Engle, R.F., 1982. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflations. *Econometrica*, 50, pp. 987-1007.
- 2- Amirat, Y., Benbouzidb, M., Wang, T., Bacha, K. and Feld, G., 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133, pp.202–209.
- 3- Rasmussen, C.E. and Williams, C.K.I., 2006. Gaussian Processes for Machine Learning. *The MIT Press, Cambridge, MA*.
- 4- Wu, Z. and Huang, N.E., 2004. A study of the characteristics of white noise using the empirical mode decomposition method. *Proc RS Lond 460A*, pp.1597–1611.



شبیه‌سازی خشک‌سالی با استفاده از دو مدل تلفیقی CEEMD-GPR و GPR-GARCH (مطالعه موردی: شمال غرب ایران)

کیومرث روشنگر^{1*} و رقیه قاسم‌پور²

^{1*} - نویسنده مسئول، استاد گروه آب، دانشکده عمران، دانشگاه تبریز، kroshangar@yahoo.com

² - دانشجوی دکتری مهندسی و مدیریت منابع آب، دانشکده عمران، دانشگاه تبریز.

پذیرش: 1398/9/18

بازنگری: 1398/9/12

دریافت: 1398/3/18

چکیده

خشک‌سالی یکی از مهم‌ترین حوادث طبیعی تأثیرگذار بر بخش کشاورزی و منابع آب می‌باشد. پیش‌بینی آن نقش مهمی در برنامه‌ریزی و مدیریت منابع آب دارد. در تحقیق حاضر، با استفاده از داده‌های سه ایستگاه سینوپتیک ارومیه، تبریز و اردبیل واقع در شمال غرب کشور طی دوره زمانی (1978-2017) به پیش‌بینی خشک‌سالی پرداخته شده است. برای این منظور، ابتدا شاخص بارندگی استاندارد (SPI) در مقیاس زمانی شش ماهه محاسبه گردید. سپس با استفاده از روش‌های تلفیقی CEEMD-GPR و GPR-GARCH، خشک‌سالی سه ایستگاه مزبور پیش‌بینی شد. برای بررسی کارایی روش‌های تلفیقی، مدل‌های متفاوتی با در نظر گرفتن شاخص SPI دوره‌های قبل و عناصر اقلیمی به عنوان پارامترهای ورودی تعریف شد و نرخ تأثیر هر یک از این پارامترها مورد بررسی قرار گرفت. با توجه به نتایج محاسبه شاخص خشک‌سالی SPI مشخص شد که سطوح مختلف خشک‌سالی طی سال‌های 1983-1985، 1988-1991، 1995-2001، 2005-2010، 2011-2013 و 2017 در طول دوره آماری در سه منطقه رخ داده است. نتایج حاصل از تحلیل مدل‌های تعریف شده براساس شاخص SPI دوره‌های قبل و عناصر اقلیمی، دقت بالایی روش‌های تلفیقی به کاررفته در تحقیق حاضر را در تخمین شاخص خشک‌سالی به خوبی نشان داد. به طوری که در تمامی ایستگاه‌ها، درصد خطا با استفاده از روش‌های تلفیقی CEEMD-GPR و GPR-GARCH نسبت به روش GPR تقریباً به میزان 25 تا 40 درصد کاهش یافت. ملاحظه گردید که در پیش‌بینی خشک‌سالی، عناصر اقلیمی شامل میانگین دما و رطوبت نسبی ماهانه و همچنین شاخص SPI مربوط به ماه‌های گذشته تأثیرگذار می‌باشند. نتایج تحلیل حساسیت نشان داد که SPI_{t-1} تأثیرگذارترین پارامتر در مدل‌سازی است.

کلید واژه‌ها: بارش، خشک‌سالی، سری‌زمانی غیرخطی، مد تجزیه، SPI، GPR.

مقدمه

خشک‌سالی به‌طورکلی به معنای کم شدن میزان بارش یک دوره نسبت به میانگین بارش درازمدت است. لذا، شناخت هرچه بیشتر این پدیده، راه را برای برنامه‌ریزی و مدیریت هرچه بهتر این رخداد هموارتر نموده و ابزار قوی‌تری را برای مدیریت بهتر ریسک در دست مسوولین ذی‌ربط قرار می‌دهد. وقوع خشک‌سالی در ایران به دلیل کم بودن میزان نزولات جوی و به‌طورکلی خشک بودن اقلیم منطقه، کشور را از لحاظ تأمین آب با بحران روبه‌رو کرده است. McKee et al. (1993) تعریف تازه‌ای از خشک‌سالی تحت عنوان نمایه بارش استاندارد شده یا SPI (Standard Precipitation Index) ارائه نمودند. Shokrikochak و Behnia (2013) از سری‌های زمانی حاصل از شاخص بارش استاندارد شده (SPI) و زنجیره مارکوف، پایش، پیش‌بینی و گسترش خشک‌سالی در سطح استان خوزستان را بررسی کردند. Saada و Abu-Romman (2017)

از مدل‌های خطی مانند CARMA برای پیش‌بینی شاخص خشک‌سالی SPI 12 ماهه استفاده کردند و بیان نمودند که روش به کاررفته از کارایی مناسبی برخوردار است. Nosrati et al. (2009) شاخص روزانه خشک‌سالی موثر را در اقلیم‌های مختلف کشور محاسبه و ارتباط آن را با منابع آب قابل دسترس تأیید کردند. Morid et al. (2006) با مقایسه هفت شاخص خشک‌سالی بارش در استان تهران نشان دادند که شاخص‌های خشک‌سالی موثر و بارش استاندارد شده می‌توانند آغاز خشک‌سالی را به خوبی نشان دهند. Morid et al. (2008) از دو شاخص خشک‌سالی SPI و EDI به عنوان متغیرهای پیش‌بینی شونده استفاده کردند و ترکیبات مختلفی از متغیرهای بارندگی، شاخص‌های بزرگ مقیاس اقلیمی Southern Oscillation، North Atlantic Oscillation (NAO) و Index (SOI) و همچنین مقادیر قبلی خود شاخص‌های خشک‌سالی را به عنوان ورودی‌های مدل شبکه عصبی مصنوعی مد نظر قرار دادند. در تمام مقیاس‌های زمانی، بهترین مدل‌ها آن‌هایی

از طرفی امروزه محققین، با پیشرفت روش‌های هوشمند، در جستجوی راه‌هایی برای پیش‌بینی پارامترهای مهم هواشناسی و هیدرولوژی هستند. در دهه‌های اخیر روش‌های نرم برای شبیه‌سازی رفتار سیستم‌ها در مهندسی آب مورد استفاده قرار گرفته‌اند. این روش‌ها اکثراً الهام‌گرفته از پدیده‌های موجود در طبیعت هستند و به‌عنوان ابزاری توانمند در حل مسائل پیچیده به‌شمار می‌آیند (Govindaraju, 2000). به‌عنوان نمونه Siviapragasam و Liang (2001) از مدل ماشین بردار پشتیبان برای پیش‌بینی بارش - روان‌آب حوضه Tryggevaelde واقع در کشور هلند استفاده کردند. Younesi et al. (2018) به پیش‌بینی خشک‌سالی با استفاده از مدل تلفیقی شبکه عصبی مصنوعی موجک پرداختند. Zhu et al. (2018) از مدل رگرسیون فرایند گاوسی برای پیش‌بینی دبی رودخانه استفاده کردند. Rezazadeh و Sattari (2016) با استفاده از مدل رگرسیون فرایند گاوسی به تخمین عمق آب‌شستگی پایه پل در سازه‌های آبی پرداختند. Samuelsson et al. (2017) از این روش برای بررسی فرایندهای تصفیه فاضلاب استفاده کردند.

بررسی منابع صورت گرفته، نشان از کاربرد روش هوشمند شبکه عصبی مصنوعی در پیش‌بینی سری‌های زمانی است. این در حالی است که مطالعات چندانی در زمینه کاربرد روش‌های مبتنی بر کرنل مانند رگرسیون فرایند گاوسی در تخمین شاخص‌های خشک‌سالی انجام نشده است. از طرفی، در سال‌های اخیر استفاده از روش‌های تجزیه سیگنال به‌عنوان روشی نوین و مؤثر در زمینه تحلیل سیگنال‌ها و سری‌زمانی مورد توجه قرار گرفته است (Agarwal et al. 2016). در این روش سیگنال اصلی به چندین زیرسری تجزیه شده و داده‌های حاصل از تجزیه با معادله‌های مناسب برازش می‌یابد و مدل به‌دست‌آمده برای پیش‌بینی استفاده می‌شود. از جمله این روش‌ها روش جدید تجزیه مد تجربی یکپارچه کامل است.

بدین ترتیب، با توجه به پیچیده بودن پدیده خشک‌سالی و تأثیر پارامترهای مختلف در پیش‌بینی آن و با توجه به این نکته که داده‌های هیدرولوژی به‌صورت ترکیبی از بخش قطعی و تصادفی می‌باشند و داده‌های تولیدی مدل‌های هوشمند به‌صورت قطعی است، بهره‌گیری از روش‌های جدید و کاربردی تعیین ویژگی‌های خشک‌سالی که بتوانند قطعیت مدل را افزایش دهند ضروری به نظر می‌رسد. لذا، هدف از این تحقیق بررسی کارایی روش‌های تلفیقی CEEMD-GPR و GPR-GARCH به‌عنوان روش‌های جدید برای بهبود دقت پیش‌بینی شاخص خشک‌سالی SPI است که می‌تواند در برنامه‌ریزی و مدیریت بهینه منابع آبی مورد استفاده قرار گیرد. با استفاده از روش تلفیقی GPR-GARCH بخش قطعی مدل توسط GPR تعیین شده و بخش تصادفی مدل توسط GARCH به‌دست می‌آید. با تلفیق نتایج این دو روش قطعیت مدل افزایش یافته و پیش‌بینی دقیق‌تر خواهد بود. هم‌چنین با استفاده از روش تجزیه سیگنال CEEMD حجم محدودی از نویز سفید وارد

بودند که شامل مقادیر شاخص خشک‌سالی ماه متناظر و سال گذشته بودند. آن‌ها هم‌چنین دریافتند که SOI و NAO تأثیر چندانی بر بهبود قابلیت پیش‌بینی مدل در منطقه مورد مطالعه ندارند. Modarres et al. (2016) به بررسی تغییرات شدت سیلاب و خشک‌سالی ایران در سال‌های 1950 تا 2010 در برخی از ایستگاه‌ها پرداختند. آزمون Mann-Kendall برای بررسی روند تغییرات شدت سیل و خشک‌سالی مورد استفاده قرار گرفت. برای بررسی اثر همبستگی نیز آزمون PWT استفاده شد. نتایج بیانگر وجود هر دو روند افزایشی و کاهش‌ی در شدت خشک‌سالی و میزان سیلاب در مناطق مختلف آب و هوایی ایران بود. Ouarda و Modarres (2014) به توسعه روش تک متغیره و چند متغیره مدل Generalized Autoregressive Conditional Heteroscedasticity (GARCH) به منظور ارزیابی کوواریانس بین خشک‌سالی و دو شاخص گردش جوی (SOD) و (NAO) در طول سال‌های 1954-2000 پرداختند. نتایج نشان داد که کوواریانس شرطی به‌دست‌آمده بین شاخص‌های خشک‌سالی و جوی ضعیف و منفی است. هم‌چنین مشاهده شد که کوواریانس بین شاخص‌های خشک‌سالی و جوی به‌طور عمده به تغییرات کوتاه‌مدت شاخص‌های جوی بستگی دارد تا تغییرات طولانی‌مدت. باوجود این که مدل‌های هیدرولوژی مختلفی برای پیش‌بینی خشک‌سالی پیشنهاد شده است، اما با توجه به ماهیت غیرخطی و ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ‌یک از مدل‌های آماری و مفهومی پیشنهاد شده به‌منظور الگوسازی دقیق خشک‌سالی نتوانسته‌اند به‌عنوان یک مدل برتر و توانا شناخته شوند و عدم قطعیت در پیش‌بینی‌ها از اعتبار برآوردها از طریق مدل‌های مختلف می‌کاهد. بیش‌تر مدل‌های سری‌زمانی رایج در هیدرولوژی و منابع آب را مدل‌های خطی سری‌های زمانی تشکیل داده‌اند. مدل‌های غیرخطی خانواده ARCH (Autoregressive Conditional Heteroscedasticity) بیش‌تر در علوم مرتبط با آمار، اقتصاد و ریاضیات مورد بحث قرار گرفته و توسعه یافته‌اند ولی در منابع آب کم‌تر مورد استفاده قرار گرفته‌اند. مدل با خصوصیت اتورگرسیو با واریانس شرطی به مدلی گفته می‌شود که فرض بر این دارد که واریانس خطاها، تابع اندازه خطاها در دوره‌های زمانی قبل است. معمولاً واریانس مرتبط با مربع خطاها و مرتبط با خطاها در زمان قبلی است. چنین مدلی معمولاً ARCH نامیده می‌شود. Wang et al. (2005) از ترکیب مدل ARMA و مدل GARCH برای برازش واریانس و میانگین روزانه جریان رودخانه زرد در چین استفاده کردند. Laux et al. (2011) با استفاده از مدل غیرخطی سری زمانی ARMA-GARCH با ارزیابی بر روی داده‌های ایستگاه‌های منتخب در منطقه آلپ آلمان، شبیه‌سازی بارش باران تصادفی را انجام دادند. Modarres و Ouarda (2013) به بررسی رابطه بارش - روان‌آب با استفاده از مدل غیرخطی GARCH پرداختند.

منطقه مورد مطالعه مطابق با شکل (1) شامل استان‌های آذربایجان غربی، شرقی و اردبیل است که با وسعتی معادل 100503 کیلومترمربع در شمال غرب ایران قرار گرفته‌اند. در این مطالعه از داده‌های بارندگی 40 ساله مشترک سه ایستگاه سینوپتیک ارومیه، تبریز و اردبیل برای پیش‌بینی خشک‌سالی استفاده شده است که مشخصات عمومی و پارامترهای آماری داده‌های ماهانه بارندگی ایستگاه‌های مذکور در جدول (1) نشان داده شده است. برای هر ایستگاه، داده‌های بارش ماهانه در طول سال‌های 1978 تا 2017 برای محاسبه شاخص SPI استفاده شد. داده‌های مربوط به سال‌های 1978 تا 2007 برای آموزش مدل‌ها و داده‌های مابین سال‌های 2008 تا 2017 برای آزمون مدل‌ها مورد استفاده قرار گرفت.

سیگنال اصلی شده و با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف خواهد شد. در این تحقیق از داده‌های سه ایستگاه سینوپتیک ارومیه، تبریز و اردبیل مربوط به دوره زمانی (2017-1978) استفاده شده و با استفاده از داده‌های مربوط به عناصر اقلیمی مانند میانگین دما و رطوبت نسبی ماهانه و شاخص SPI دوره‌های قبل دقت روش‌های تلفیقی و همچنین پارامترهای موثر در مدل‌سازی شاخص خشک‌سالی SPI بررسی شد.

مواد و روش‌ها

موقعیت منطقه مورد مطالعه و داده‌های استفاده‌شده

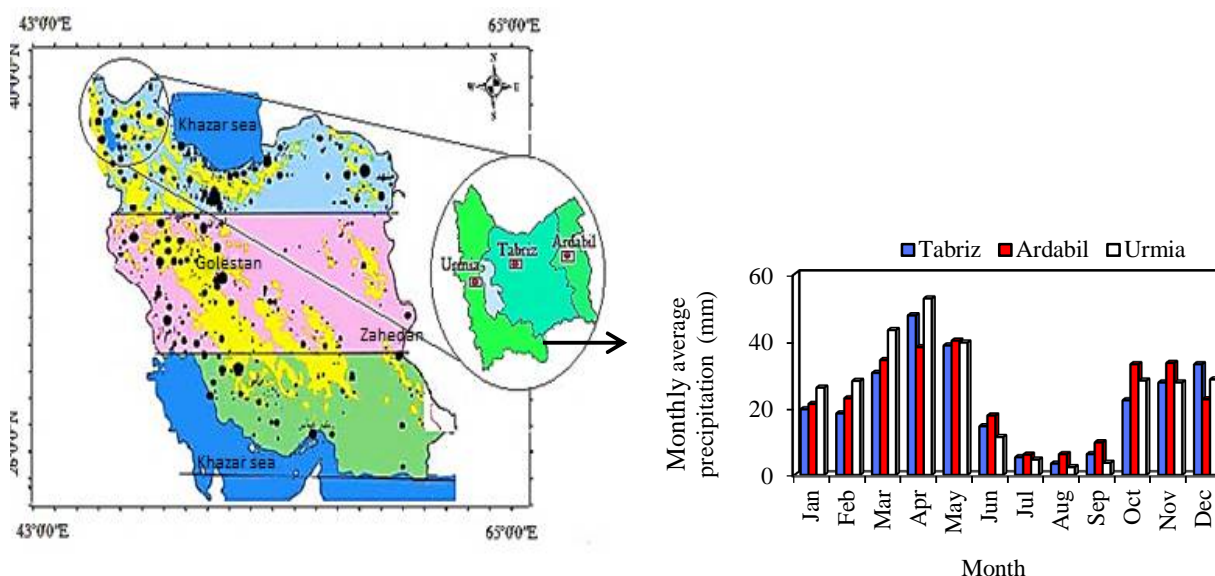


Fig. 1- Location of the study area and monthly average precipitation in selected stations for the period (1978-2017)

شکل 1- موقعیت منطقه مورد مطالعه و متوسط بارندگی ماهانه در ایستگاه‌های مورد نظر در بازه (1978-2017)

جدول 1- اطلاعات آماری سری زمانی بارندگی ماهانه ایستگاه‌ها (1978-2017)

Table 1- Statistical properties of the monthly rainfall time series of stations (1978-2017)

Descriptive statistics	Station		
	Tabriz	Ardabil	Urmia
Maximum (mm)	128.4	158.9	147.5
Minimum (mm)	0	0	0
Mean (mm)	21.404	23.819	25.916
Skewness	1.5075	1.880	1.545
Standard deviation (mm)	21.141	22.897	27.788
Coefficient of Variation	98.7%	96.1%	107.2%

شاخص استاندارد شده بارش (SPI)

روش SPI، توسط اقلیم‌شناسان برای انجام مطالعات بر روی خشک‌سالی‌ها استفاده می‌شود. تنها پارامتر مورد استفاده در محاسبه آن بارش بوده و از ویژگی‌های آن قابلیت تحلیل خشک‌سالی‌ها در هر مقیاس زمانی و مکانی است. در واقع، درک این نکته که بارندگی تأثیر متفاوتی بر منابع آب مانند آب زیرزمینی، ذخایر آب سطحی و برف دارد، منجر به این گشت که شاخص SPI تدوین و ارایه گردد. سیستم طبقه‌بندی SPI بیانگر شدت‌های متفاوتی از خشک‌سالی در یک منطقه بوده و براساس آن می‌توان آستانه خشک‌سالی را برای هر دوره زمانی تعیین کرد. این شاخص اساساً در مقیاس‌های کوتاه‌مدت یک و سه ماهه، میان‌مدت شش و نه ماهه و هم‌چنین در مقیاس‌های بلندمدت 12، 24 و 48 ماهه قابل محاسبه است و به‌منظور هشدار اولیه و پایش شدت خشک‌سالی اهمیت زیادی دارد. این مقیاس‌های زمانی متفاوت اثرات ویژه خشک‌سالی را بر روی قابلیت دسترسی به منابع آبی مختلف بیان می‌کنند. برای مثال شرایط رطوبتی خاک نسبت به ناهنجاری‌های کوتاه‌مدت بارندگی واکنش نشان می‌دهد، در صورتی که آب‌های سطحی و زیرزمینی تحت تأثیر ناهنجاری‌های درازمدت قرار دارند. در این تحقیق از SPI میان‌مدت شش ماهه استفاده شد تا نوسانات مربوط به جریان‌های سطحی و تراز مخزن نیز لحاظ گردد.

استفاده از این روش بر روی داده‌های بارندگی منجر به نمایش دقیق و مؤثر آن از طریق تابع ریاضی احتمال تجمعی می‌شود و به کمک آن می‌توان احتمال بارندگی را حول محور یک مقدار برآورد نمود (Hayes, 2007). به‌عبارت‌دیگر این شاخص امکان محاسبه مقادیر کمتر و بیشتر از حالت میانگین را به‌وجود می‌آورد و برای پایش خشک‌سالی‌ها (بارش کمتر از حالت نرمال) و ترسالی‌ها (بارش بیشتر از حال نرمال) به‌کار رفته و این امکان را به تحلیل‌گر می‌دهد که شدت، مدت، فراوانی و زمان شروع و خاتمه خشک‌سالی‌ها را شناسایی کند. از آن‌جا که این شاخص بدون‌بعد است از آن می‌توان برای مقایسه اطلاعات مناطق مختلف و هم‌چنین برای تهیه نقشه‌های پهنه‌بندی خشک‌سالی استفاده نمود. طبقه‌بندی شاخص SPI به‌صورت بی‌نهایت مرطوب ($SPI \geq 2$)، مرطوب شدید ($1.5 \leq SPI < 2$)، مرطوب متوسط ($1 \leq SPI < 1.5$)، نزدیک به نرمال ($-1 \leq SPI < 1$)، خشک‌سالی متوسط ($-1.5 \leq SPI < -1$)، خشک‌سالی شدید ($-2 < SPI < -1.5$) و خشک‌سالی بسیار شدید ($SPI \leq -2$) است.

رگرسیون فرایند گاوسی (Gaussian Process Regression)

فرایند گاوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد دلخواه محدودی از آن‌ها با توزیع‌های گاوسی ادغام شده‌اند. فرایند گاوسی به‌طور کامل توسط تابع میانگین $m(x)$ و تابع کوواریانس $k(x, x')$ آن تعیین می‌شود. این فرایند، تعمیمی طبیعی از توزیع

گاوسی است که میانگین و کوواریانس آن به ترتیب یک بردار و یک ماتریس است. مدل‌های رگرسیون فرایند گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره هم‌دیگر باشد. یکی از جذابیت‌های فرایند گاوسی تنوع بسیار توابع کوواریانس آن است که به ایجاد توابعی با درجات مختلف همواری یا انواع مختلف ساختارهای پیوستی منجر می‌شود و به محقق این امکان را می‌دهد که از میان آن‌ها گزینش مناسبی انجام دهد. این مدل‌ها می‌توانند توزیع‌هایی را بین توابعی با تعداد یک یا چندین متغیر ورودی مشخص کنند. هنگامی که چنین تابعی میانگین پاسخ را در یک مدل رگرسیونی با خطاهای گاوسی تعریف می‌کند، می‌توان از محاسبات ماتریس برای استنتاج بهره‌گیری کرد؛ این مسئله برای داده‌هایی با بیش از هزار نمونه امکان‌پذیر است. فرایندهای گاوسی در مدل‌سازی آماری بسیار پراهمیت‌اند، زیرا خصوصیات نرمالی دارند (Neal, 1997). می‌توان n مشاهده را همیشه در مجموعه داده دلخواه $Y = [y_1, y_2, \dots, y_n]$ به‌صورت یک نقطه تکی نمونه‌گیری شده از توزیع گاوسی چندمتغیری (n متغیری) تصور کرد. از این‌رو، مجموعه داده‌ها را می‌توان با یک فرایند گاوسی متناظر کرد. اغلب فرض می‌شود که میانگین فرایند گاوسی متناظر در هر جا صفر است. آن‌چه در چنین حالتی یک مشاهده را به مشاهده دیگر ارتباط می‌دهد تابع کوواریانس است. هر مشاهده y را می‌توان از طریق مدل نویزی گاوسی به یک تابع اصلی ارتباط داد:

$$y_i = f(x_i) + \varepsilon \quad (1)$$

که در آن $f(x)$ بیانگر تابع رگرسیون دلخواه و ε نیز مقدار نویز توزیع گاوسی با میانگین صفر و واریانس σ^2 می‌باشد، یعنی $\varepsilon \sim N(0, \sigma^2)$. رگرسیون در واقع جست‌وجو برای $f(x)$ است. چنین فرض می‌گردد که $f = [f(x_1), f(x_2), \dots, f(x_n)]^T$ رفتاری بر مبنای فرایند گاوسی داشته به‌نحوی که $p(f|X) = N(0, K)$ که در آن K ماتریس کوواریانس با درایه‌های $k_{i,j} = k(x_i, x_j)$ می‌باشد.

$$K(x, x) = \begin{pmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{pmatrix} \quad (2)$$

$k_{i,j}$ کوواریانس بین مقادیر توابع نهان $f(x_i)$ و $f(x_j)$ است. رگرسیون فرایند گاوسی به‌منظور محاسبه توزیع پیش‌بینی شده برای مقادیر تابع f^* در نقاط تست $X^* = [x_1^*, x_2^*, \dots, x_m^*]$ به کار می‌رود. طراحی روش‌های رگرسیون مبتنی بر فرایند گاوسی شامل استفاده از مفهوم تابع کرنل است. در واقع، با یک تبدیل غیرخطی از فضای ورودی به فضای خنثی با ابعاد بیشتر (حتی نامتناهی) می‌توان مسائل را به‌صورت خطی تفکیک‌پذیر ساخت. از مهم‌ترین

عنوان غربال کردن صورت می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مؤلفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (6) سیگنال اصلی $x(n)$ را به تعدادی مد ذاتی تجزیه می‌کند (Amirat et al., 2018).

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (6)$$

که $r_n(x)$ همان مؤلفه باقی‌مانده، بعد از n تعداد IMFها و $c_i(x)$ است. یک داده ممکن است در یک زمان دارای چندین مد ذاتی باشد. این مدهای نوسانی، تابع‌های مد ذاتی (IMF) نام دارند و دارای شرایط زیر هستند:

1. در کل داده، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند. 2. در هر نقطه میانگین پوش برازش‌داده‌شده بر نقاط حداکثر محلی و پوش برازش‌داده‌شده بر نقاط حداقل محلی باید صفر باشد.
- به علت وجود نویز در سیگنال‌ها، در برخی موارد به علت اختلاط مدها توزیع حوزه زمان-فرکانس دچار انقطاع شده و عملکرد EMD دچار نقض می‌گردد. جهت رفع این ایراد Wu و Huang (2004) روشی متفاوت با عنوان روش تجزیه مد تجربی یک‌پارچه (Ensemble Empirical Mode Decomposition) را پیشنهاد کردند. در روند تجزیه‌سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی شده و با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌گردد. در روش تجزیه مد تجربی یک‌پارچه کامل (CEEMD) نوفه سفید به صورت دوتایی (یکی مثبت و دیگری منفی) به داده اصلی اضافه می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نوفه‌ی اضافی وجود دارد که مجموع IMFها برابر سیگنال اصلی می‌شود.

معیارهای ارزیابی مدل‌ها

به منظور ارزیابی کارایی روش استفاده‌شده در مدل‌سازی خشک‌سالی، از سه پارامتر آماری استفاده گردید که عبارت‌اند از: ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی (Correlation Coefficient: R)، ضریب تعیین (R^2) (Determination Coefficient: R^2)، ریشه میانگین مربعات خطاها (Root Mean Square Errors: RMSE) و درصد خطای میانگین مطلق (Mean Absolute Percentage Error: MAPE). مقدار R می‌تواند بین یک یا منفی یک متغیر باشد که نشان‌دهنده‌ی همبستگی مثبت یا منفی است. برای یک مدل هر چه مقدار R به یک یا منفی یک نزدیک‌تر، مقدار R^2 به یک نزدیک‌تر و مقدار RMSE و MAPE کوچک‌تر باشد به معنی مطلوب بودن آن مدل است. روابط این پارامترهای آماری به صورت زیر می‌باشد:

توابع کرنل می‌توان به کرنل چندجمله‌ای ساده، چندجمله‌ای نرمال‌شده، تابع شعاع محور و تابع کرنل پیرسون اشاره کرد.

مدل GARCH

مدل GARCH یک مدل سری‌زمانی غیرخطی برای مدل‌سازی تغییرات واریانس در طول زمان است. در واقع، GARCH یک روش ARCH تعمیم‌یافته است که توسط Engle (1982) ارایه شده است. مدل خانواده ARCH را می‌توان در مطالعات مربوط به اقلیم‌شناسی به کار برد. شرط استفاده از این گونه مدل‌ها نقض فرض همسانی واریانس جزء خطا است. مدل‌های ARCH و GARCH برای مدل‌سازی معادله واریانس شرطی جمله خطا طراحی شده‌اند. برای تخمین این گونه مدل‌ها از روش حداکثر درست‌نمایی استفاده می‌شود. در مدل ARCH، فرض می‌شود که جزء اخلاص مدل دارای واریانس ناهمسانی بوده و این واریانس تابعی از رفتار جملات خطا است. در مدل GARCH واریانس مدل علاوه بر جملات خطا تابعی از وقفه‌های خود واریانس شرطی نیز هست. ساختار GARCH (p, q) به صورت معادله زیر بیان می‌شود:

$$\varepsilon_t = \sigma_t z_t \quad (3)$$

که در آن z_t متغیرهای تصادفی با توزیع یکنواخت و مستقل، σ_t واریانس شرطی و ε_t عبارت خطا یا باقی‌مانده مدل با میانگین صفر و واریانس یک است.

واریانس شرطی $(\sigma_t^2 = E[\varepsilon_t^2 | \phi_{t-1}])$ GARCH به شرح

زیر است:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (4)$$

$$p \geq 0, q \geq 0, \alpha_0 \& \alpha_i \geq 0, \beta_j \geq 0$$

q و p به ترتیب درجه مدل‌های ARCH و GARCH هستند. در معادله (4) اگر $p=0$ باشد در آن صورت GARCH(p, q) به ARCH(q) تبدیل می‌شود. در این مطالعه، مدل سری زمانی GARCH با درجه یک یعنی GARCH(1,1) برای مدل‌سازی بخش تصادفی داده‌های شاخص خشک‌سالی SPI به صورت زیر استفاده شده است:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (5)$$

روش تجزیه مد تجربی EMD

EMD (Empirical Mode Decomposition) روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرایندی تحت

توسط مدل رگرسیون فرایند گاوسی به دست آمد سپس نتایج به دست آمده با نتایج حاصل از روش GARCH که بخش تصادفی سری زمانی را ارائه می‌دهد، ترکیب گردید. در شکل (2) شماتیک مدل سازی صورت گرفته در تحقیق نشان داده شده است.

به منظور مدل سازی خشک سالی، ابتدا داده های سری زمانی بارش به شاخص بارش استاندارد شده در دوره شش ماهه تبدیل شد. در شکل (3) نمودار نمایه SPI شش ماهه و سالانه در سه منطقه ارومیه، تبریز و اردبیل برای دوره 40 سال نشان داده شده است. زمانی که شاخص بارش استاندارد شده دارای توالی های منفی باشد؛ خشک سالی رخ می‌دهد. و زمانی که مقادیر آن برابر با منفی یک و یا کمتر شود، خشک سالی تشدید می‌شود. با مثبت شدن شاخص بارش استاندارد شده دوره خشک سالی خاتمه می‌یابد. مطابق با شکل (3) مشاهده می‌گردد که در طی سال های 1983-1985، 1983-1991-1988، 2001-1995، 2010-2005، 2013-2011، و 2017 سطوح مختلف خشک سالی در سه منطقه رخ داده است، اما بیشتر آن ها در شرایط خشک سالی نزدیک به حالت نرمال و متوسط $SPI \leq 1.5$ قرار دارند. خشک سالی شدیدی نیز در چند سال دیده می‌شود مانند سال 1990 در تبریز و 2005 در ارومیه. با بررسی شدت خشک سالی هر دوره می‌توان مقایسه کمی از شدت خشک سالی در ایستگاه ها و نواحی متفاوتی داشت. برای مثال ایستگاه های تبریز و ارومیه بیشترین تداوم خشک سالی را طی دوره خشک سالی 2000-1995 داشته اند و ایستگاه اردبیل نیز بیشترین تداوم خشک سالی را طی دوره 1987-1983 تجربه کرده است. نتایج نشان می‌دهد که خشک سالی ها از غرب به شرق در منطقه انتخاب شده افزایش یافته است. فراوانی خشک سالی در میان مناطق انتخابی برای شهر ارومیه بیشترین مقدار را داشته و به ترتیب 13 و 18 درصد بیشتر از شهر های تبریز و اردبیل است. در ادامه برای انتخاب تابع کرنل مناسب رگرسیون فرایند گاوسی مدل S(III) با کرنل های مختلف مورد ارزیابی قرار گرفت. از معیار ارزیابی RMSE برای تعیین کارایی هر یک از کرنل ها استفاده گردید. نتایج به صورت شکل (4) برای سری داده های آزمون ارائه گردیده است. مطابق با شکل (4) مشاهده می‌گردد که در بین تمامی توابع کرنل ها، تابع کرنل شعاع مداری در پیش بینی خشک سالی نسبت به توابع کرنل دیگر دارای ضریب همبستگی و تعیین بیشتر و خطای کمتری بوده و نتایج دقیق تری را ارائه کرده است. بنابراین، در تجزیه و تحلیل تمامی مدل ها از کرنل شعاع مداری استفاده شد.

$$R^2 = 1 - \frac{\sum_{i=1}^N (I_o - I_p)^2}{\sum_{i=1}^N (I_o - \bar{I}_p)^2} \quad (7)$$

$$R = \frac{\sum_{i=1}^N (I_o - \bar{I}_o) \times (I_p - \bar{I}_p)}{\sqrt{\sum_{i=1}^N (I_o - \bar{I}_o)^2 \times \sum_{i=1}^N (I_p - \bar{I}_p)^2}} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (I_o - I_p)^2}{N}} \quad (9)$$

$$MAPE = \frac{1}{I_o} \frac{\sum_{i=1}^n |I_o - I_p|}{N} \times 100 \quad (10)$$

در روابط بالا L_o : مقدار اندازه گیری شده، \bar{L}_o : متوسط مقدار اندازه گیری شده، L_p : مقدار پیش بینی شده، \bar{L}_p : متوسط مقدار پیش بینی شده و N تعداد داده ها است.

نتایج و بحث

با توجه به این که انتخاب مدل های ورودی در سامانه های هوشمند می‌تواند بر روی دقت جواب های حاصل از تحلیل تأثیر گذارد، لذا سعی گردید پارامترهای مناسب و مؤثر در مدل سازی SPI شش ماهه انتخاب گردد. در تحقیق کنونی، از شاخص SPI ماه های گذشته و عناصر اقلیمی شامل دما (T) و رطوبت نسبی (R) به عنوان پارامتر ورودی به صورت زیر برای پیش بینی SPI_t استفاده گردید.

S(I)	SPI_{t-1}
S(II)	SPI_{t-1}, SPI_{t-2}
S(III)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$
S(IV)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, T_{t-1}$
S(V)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, T_{t-1}, R_{t-1}$

در روش CEEMD-GPR پس از نرمال سازی داده ها، ابتدا سری های زمانی توسط روش CEEMD به زیر سری هایی تجزیه گردید و سپس این زیر سری ها به عنوان ورودی مدل GPR استفاده شد. در روش GARCH-GPR نیز ابتدا بخش قطعی سری زمانی

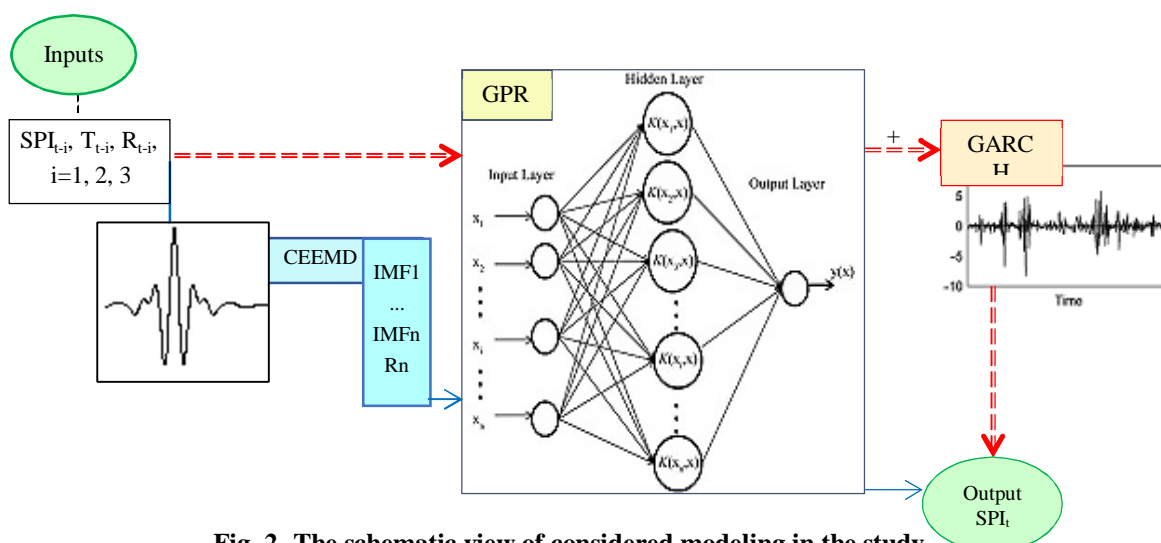


Fig. 2- The schematic view of considered modeling in the study

شکل 2- شماتیک مدل سازی صورت گرفته در تحقیق

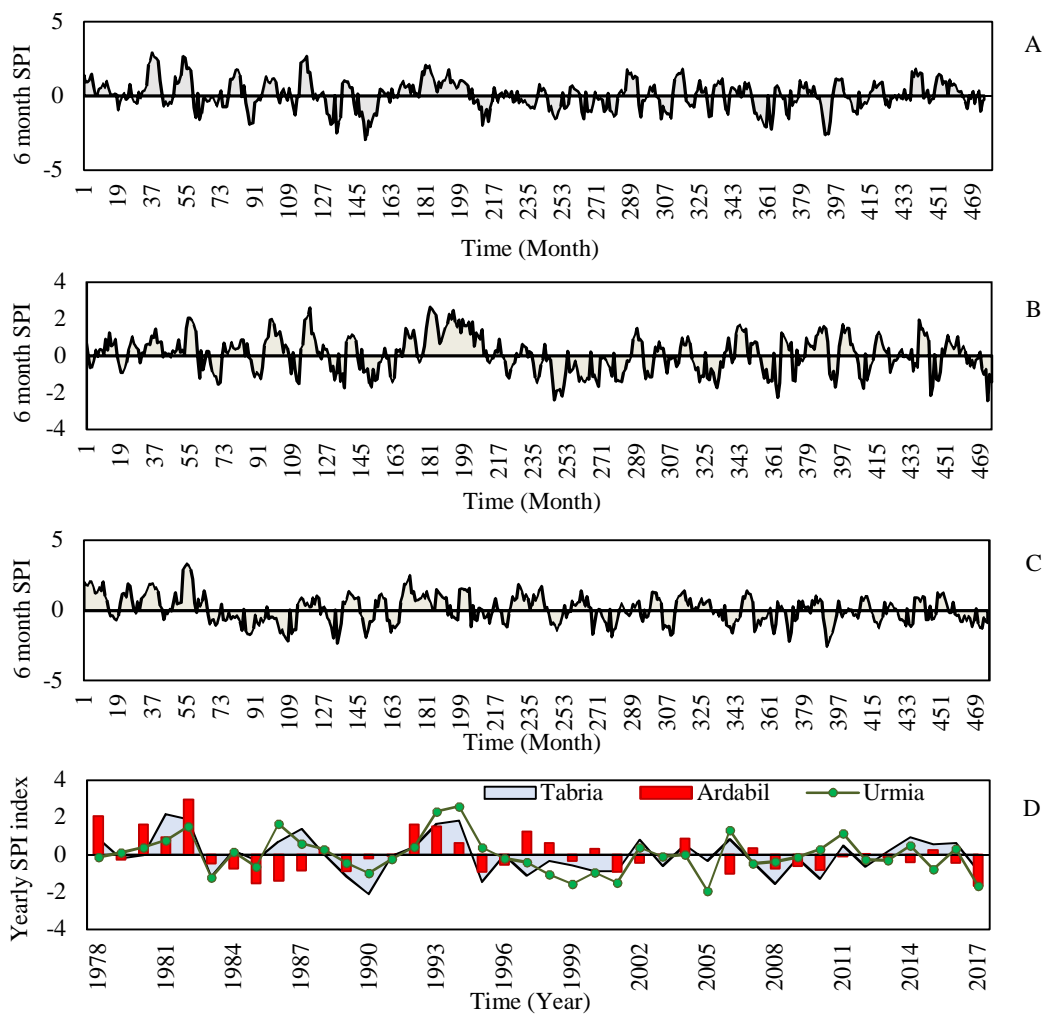


Fig. 3- The six month and yearly SPI index for the selected stations; A: Tabriz station, B: Urmia station, C: Ardabil station and D: Comparison of stations

شکل 3- نمودار SPI شش ماهه و سالانه ایستگاه های منتخب: A: ایستگاه تبریز، B: ایستگاه ارومیه، C: ایستگاه اردبیل و D: مقایسه ایستگاه ها




Fig. 4- Statistics parameters via GPR kernels function types for test data series; A: Tabriz station, B: Urmia station and C: Ardabil station

شکل 4- پارامترهای آماری مدل GPR با توابع کرنل متفاوت برای سری داده‌های آزمون؛ A: ایستگاه تبریز، B: ایستگاه ارومیه و C: ایستگاه اردبیل

جدول 2- نتایج ارزیابی مدل‌های GPR برای سه ایستگاه

Table 2- Statistical parameters of the GPR models for three stations

Model	Performance criteria							
	Train				Test			
	R	R ²	RMSE	MAPE	R	R ²	RMSE	MAPE
Tabriz								
S(I)	0.792	0.438	0.384	15.24	0.731	0.410	0.410	17.14
S(II)	0.797	0.506	0.381	15.14	0.731	0.423	0.405	16.97
S(III)	0.805	0.598	0.371	14.79	0.795	0.540	0.385	15.12
S(IV)	0.845	0.613	0.367	12.01	0.835	0.554	0.379	13.07
S(V)	0.854	0.622	0.349	11.88	0.843	0.562	0.367	12.99
Urmia								
S(I)	0.817	0.498	0.339	14.69	0.751	0.469	0.482	17.62
S(II)	0.818	0.526	0.337	13.62	0.762	0.473	0.473	17.31
S(III)	0.822	0.607	0.329	13.34	0.776	0.546	0.469	17.17
S(IV)	0.863	0.622	0.318	11.21	0.815	0.560	0.455	14.94
S(V)	0.872	0.632	0.309	10.90	0.823	0.568	0.448	14.70
Ardabil								
S(I)	0.789	0.422	0.354	14.21	0.699	0.402	0.420	16.48
S(II)	0.792	0.508	0.359	14.38	0.704	0.433	0.396	15.66
S(III)	0.796	0.586	0.328	11.83	0.725	0.538	0.384	13.76
S(IV)	0.836	0.601	0.315	9.871	0.761	0.551	0.380	11.60
S(V)	0.844	0.610	0.299	9.530	0.769	0.560	0.361	10.95

پارامترهای ورودی SPI_{t-1} , SPI_{t-2} , SPI_{t-3} , T_{t-1} , R_{t-1} و پارامترهای ضریب همبستگی و ضریب تعیین و کمترین مقدار خطا را از روی داده و مدل برتر است. مشاهده می‌شود که در حالت استفاده از SPI_{t-1} به عنوان تنها پارامتر ورودی، نتایج دقیقی ارائه نشده است. با مقایسه نتایج مدل‌ها مشاهده می‌شود که با دخالت دادن عناصر اقلیمی دما و رطوبت نسبی دقت مدل‌ها تا حدودی افزایش یافته است. با این وجود، با توجه به نتایج سه معیار ارزیابی مشاهده می‌گردد که روش GPR از دقت مطلوبی برای مدل‌سازی شاخص خشک‌سالی به‌ویژه در نقاط حداکثر و حداقل سری زمانی SPI برخوردار نمی‌باشد. نمودار مدل برتر برای سری داده‌های آموزش و آزمون برای هر سه ایستگاه در شکل (5) نشان داده شده است.

نتایج به‌دست‌آمده برای مدل GPR

برای پیش‌بینی خشک‌سالی براساس شاخص استاندارد شده، پنج مدل براساس شاخص SPI مربوط به دوره‌های قبل و عناصر اقلیمی شامل میانگین دما و رطوبت نسبی ماهانه تعریف گردید و کارایی روش رگرسیون فرایند گاوسی مورد ارزیابی قرار گرفت. مدل‌های تعریف‌شده با روش GPR آنالیز گردید و نتایج حاصله به‌صورت جدول (2) و شکل (5) ارائه شد. با توجه به نتایج به‌دست‌آمده از سه معیار ارزیابی مدل برای هر سه منطقه منتخب مشاهده می‌شود که در حالت مدل‌سازی براساس SPI دوره‌های قبل مدل S(III) با پارامترهای ورودی SPI_{t-1} , SPI_{t-2} , SPI_{t-3} بیشترین کارایی را دارا است. اما در حالت کلی مدل S(V) با

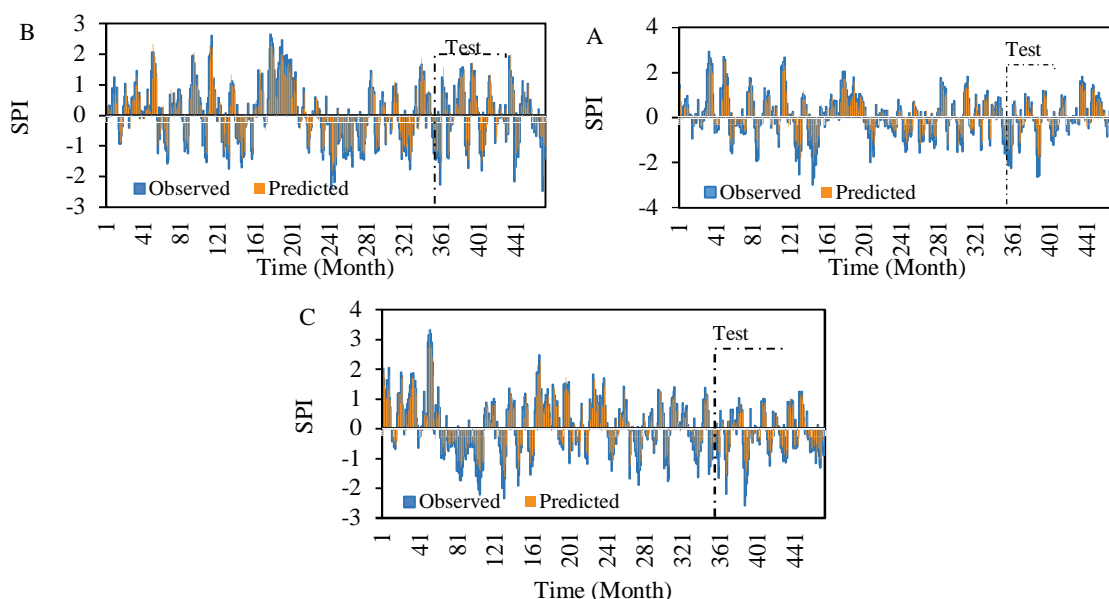


Fig. 5- Comparison of observed and GPR predicted results of SPI time series; A: Tabriz station, B: Urmia station and C: Ardabil station

شکل 5- مشاهده مقادیر مشاهداتی و پیش‌بینی GPR برای سری‌های زمانی SPI: A: ایستگاه تبریز، B: ایستگاه ارومیه و C: ایستگاه اردبیل

دقیق‌تر بوده و این روش‌ها تا حدود زیادی باعث بهبود نتایج گردیده‌اند. مطابق با جدول (3)، مدل $S(V)$ با پارامترهای ورودی SPI_{t-1} , SPI_{t-2} , SPI_{t-3} , T_{t-1} , R_{t-1} و استفاده از داده‌های اقلیمی باعث بهبود نتایج شده است. برای تمامی ایستگاه‌ها مقدار پارامتر خطا با استفاده از روش CEEMD-GPR و GPR-GARCH نسبت به حالتی که تنها از مدل GPR استفاده شود تقریباً 25 تا 40 درصد کاهش یافته است. برای مدل‌های توسعه‌یافته GARCH، مدل $S(I)$ برای منطقه انتخاب‌شده نتایج مطلوبی را ارائه کرده است و می‌توان نتیجه گرفت که با استفاده از روش GARCH، شاخص خشک‌سالی SPI می‌تواند با استفاده از SPI_{t-1} به‌عنوان تنها متغیر ورودی شبیه‌سازی شود. لازم به توضیح است که در مورد مدل انتخاب‌شده علاوه بر این که این مدل از نظر معیارهای ارزیابی برای تخمین پارامتر وابسته باید دارای دقت مطلوبی باشد، تعداد پارامترهای به‌کاررفته در مدل و ساده بودن آن نیز مهم است. استفاده از مدل با تعداد پارامترهای کمتر هم راحت‌تر بوده و هم زمان و حجم محاسبات را کاهش می‌دهد. با در نظر گرفتن این نکته و با توجه به نتایج جدول (3) و مدل $S(III)$ مشاهده می‌گردد که در صورت استفاده از پارامترهای SPI دوره‌های قبل، با استفاده از هر دو روش تلفیقی به‌کاررفته در تحقیق می‌توان به دقت مطلوبی در فرایند پیش‌بینی دست یافت و در صورت عدم دسترسی به سایر داده‌های اقلیمی از این مدل برای پیش‌بینی خشک‌سالی استفاده نمود. با مقایسه نتایج سه مدل $S(III)$ ، $S(IV)$ و $S(V)$ و با در نظر گرفتن مقادیر درصد خطای به‌دست‌آمده از معیار MAPE مشاهده می‌شود که در صورت حذف پارامترهای اقلیمی مقدار درصد خطا تقریباً بین 10 تا 25 درصد افزایش خواهد

نتایج به‌دست‌آمده برای مدل تلفیقی CEEMD-GPR و GARCH-GPR

در این قسمت، از تجزیه مد تجزیه یک‌پارچه کامل و روش مدل سری‌زمانی مبتنی بر واریانس ناهمسان شرطی برای افزایش دقت پیش‌بینی مدل GPR استفاده گردید. اساس روش CEEMD تجزیه سیگنال به IMFهای مختلف و یک سیگنال باقی‌مانده است که در نهایت مجموعه‌ی این‌ها، همان سیگنال اصلی خواهد بود. روش تشکیل IMFها براساس تفریق تابع پایه از سیگنال اصلی است. این پروسه تا وقتی ادامه می‌یابد که تقریباً سیگنال باقی‌مانده ثابت شود. در نهایت زیر سری‌های به‌دست‌آمده از تجزیه سیگنال، به‌عنوان ورودی به مدل GPR داده شد. در روش GARCH نیز مراحل زیر برای ادغام مدل GPR با این مدل سری‌زمانی مورد استفاده قرار گرفت:

- اجرای مدل‌های سری‌زمانی AR یا ARMA روی داده‌های SPI نرمال‌شده و استانداردشده

- محاسبه خطاها یا باقی‌مانده‌ها از مرحله قبل

- مدل‌سازی $GARCH(1, 1)$ بر روی داده‌های خشک‌سالی SPI

- ترکیب بخش قطعی حاصل از مدل GPR با بخشی تصادفی به‌دست‌آمده از مدل سری‌زمانی GARCH.

نتایج حاصل از مدل‌سازی‌های در نظر گرفته شده برای داده‌های آزمون در جدول (3) ارائه شده است. با مقایسه نتایج جدول (2) و (3) و با در نظر گرفتن مقادیر خطای RMSE و MAPE ملاحظه می‌شود که برای هر سه ایستگاه، روش‌های تلفیقی CEEMD-GPR و GARCH-GPR در مقایسه با روش GPR

گرفت. برای این منظور با حذف تک تک پارامترهای مدل برتر و اجرای دوباره مدل و تعیین معیارهای ارزیابی RMSE و MAPE، میزان تأثیر پارامتر حذف شده در کاهش دقت مدل مورد بررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت در شکل (7) نشان داده شده است. همان طور که از شکل مشخص است با حذف پارامتر SPI_{t-1} دقت مدل تا حدود زیادی کاهش یافته است. بنابراین، می توان نتیجه گرفت که SPI_{t-1} بیشترین تأثیر را در مدل سازی خشک سالی داراست. پارامتر دما نیز دومین پارامتر تأثیرگذار در مدل سازی است.

یافت. پراکنش مقادیر پیش بینی مدل های GPR-GARCH و CEEMD-GPR با مقادیر اندازه گیری مدل برتر برای همه ایستگاه ها در شکل (6) نشان داده شده است. ملاحظه می شود که مدل های تلفیقی دارای کارایی قابل قبولی در شبیه سازی مقدار حداقل و حداکثر سری زمانی SPI هستند.


آنالیز حساسیت

برای بررسی تأثیر پارامترهای به کار رفته در مدل برتر (مدل S(V) در مدل تلفیقی GPR-GARCH) آنالیز حساسیت انجام

جدول 3- نتایج پارامترهای آماری برای سری داده های آزمون بر اساس روش های تلفیقی

Table 3- Statistical parameters results for test series based on the integrated methods

Model	Performance criteria							
	CEEMD-GPR				GPR-GARCH			
	R	R ²	RMSE	MAPE	R	R ²	RMSE	MAPE
Tabriz								
S(I)	0.752	0.638	0.338	13.66	0.931	0.851	0.216	9.450
S(II)	0.804	0.793	0.305	12.52	0.841	0.801	0.270	10.31
S(III)	0.862	0.845	0.289	9.330	0.905	0.859	0.257	9.862
S(IV)	0.866	0.848	0.283	7.760	0.903	0.859	0.254	7.141
S(V)	0.871	0.852	0.282	7.130	0.908	0.861	0.251	6.980
Urmia								
S(I)	0.755	0.730	0.397	14.69	0.899	0.881	0.306	11.55
S(II)	0.816	0.887	0.356	13.28	0.872	0.811	0.325	12.21
S(III)	0.849	0.854	0.352	12.14	0.886	0.889	0.215	9.410
S(IV)	0.854	0.857	0.340	10.96	0.885	0.890	0.211	7.940
S(V)	0.858	0.861	0.334	10.29	0.889	0.891	0.209	7.050
Ardabil								
S(I)	0.733	0.626	0.346	12.93	0.899	0.864	0.221	8.620
S(II)	0.754	0.812	0.298	11.28	0.814	0.799	0.264	10.10
S(III)	0.793	0.842	0.288	9.340	0.899	0.878	0.218	7.039
S(IV)	0.797	0.843	0.284	7.791	0.888	0.879	0.214	6.140
S(V)	0.801	0.849	0.277	6.990	0.887	0.879	0.210	6.081



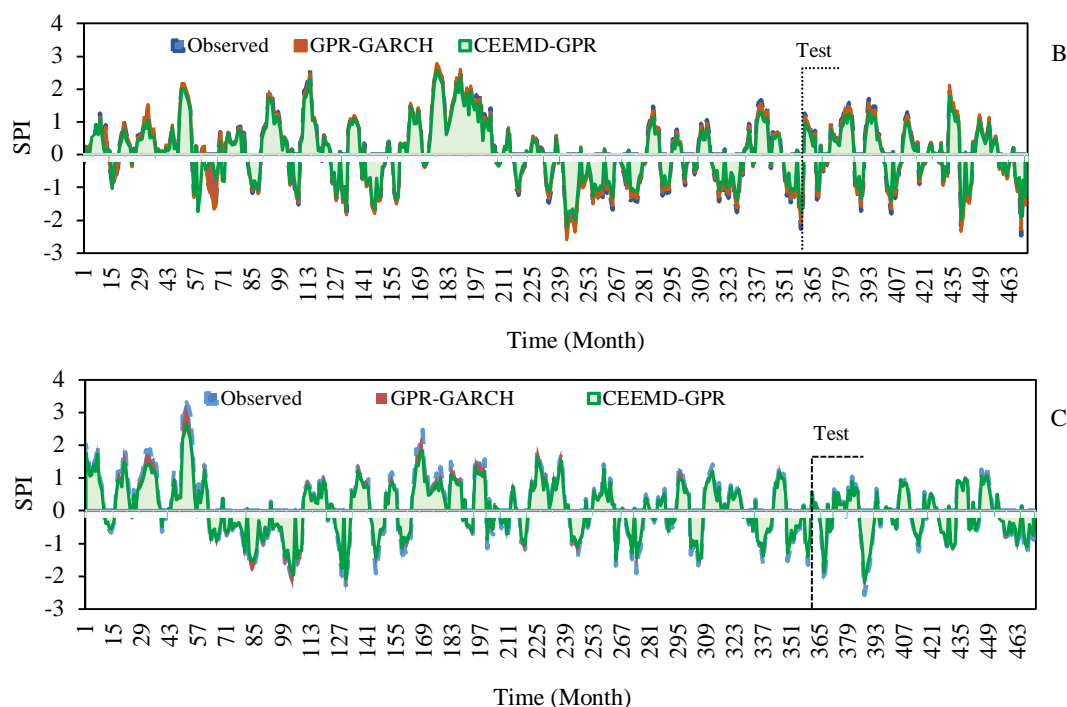


Fig. 6- Comparison of observed and integrated methods predicted results SPI time series; A: Tabriz station, B: Urmia station and C: Ardabil station

شکل 6- مقایسه نتایج مشاهداتی و پیش‌بینی روش‌های تلفیقی برای سری‌های زمانی SPI؛ A: ایستگاه تبریز، B: ایستگاه ارومیه و C: ایستگاه اردبیل

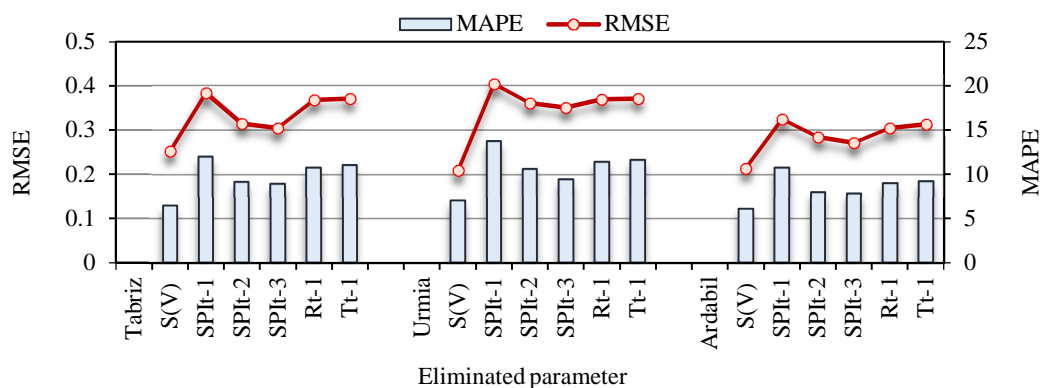


Fig. 7- Relative significance of each of input parameters of the best model.

شکل 7- تاثیر نسبی هر یک از پارامترهای ورودی مدل برتر

سال‌های مختلف سطوح متفاوتی از خشک‌سالی در سه منطقه رخ داده است که بیشتر آن‌ها در شرایط خشک‌سالی نزدیک به حالت نرمال و متوسط قرار داشتند. مشاهده شد که شدیدترین خشک‌سالی در منطقه مطالعاتی برای شهر تبریز در سال 1990 رخ داده است. در طی بازه زمانی انتخابی، خشک‌سالی‌ها از غرب به شرق در منطقه افزایش یافته و فراوانی خشک‌سالی در شهر ارومیه به ترتیب 13 و 18 درصد بیشتر از شهرهای تبریز و اردبیل بود. نتایج حاصله نشان داد که روش‌های تلفیقی در مقایسه با روش GPR دارای دقت بالاتری بوده و مقدار پارامتر خطا را تقریباً به اندازه 25 تا 40 درصد

نتیجه‌گیری

در پژوهش حاضر، به پیش‌بینی خشک‌سالی سه منطقه ارومیه، تبریز و اردبیل واقع در شمال غرب کشور با استفاده از دو روش تلفیقی CEEMD-GPR و GARCH-GPR پرداخته شد. برای بررسی کارایی این دو روش، مدل‌هایی با در نظر گرفتن داده‌های مربوط به شاخص بارش استاندارد شده ماه‌های قبل و عناصر اقلیمی مانند میانگین دما و رطوبت نسبی ماهانه در بازه زمانی (1978-2017) به عنوان پارامترهای ورودی تعریف شد و به ارزیابی شاخص SPI شش ماهه پرداخته شد. نتایج نشان داد که در طی

خشک‌سالی دوره گذشته باشند، مطابقت دارد. در این تحقیق مطابق با Hayes et al. (1999) و Hung et al. (2005) که بیان نمودند شاخص SPI به علت ساده بودن محاسبات، استفاده از داده‌های بارندگی قابل دسترس، قابلیت محاسبه برای مقیاس زمانی دلخواه و قابلیت بسیار زیاد در مقایسه مکانی نتایج، به‌عنوان مناسب‌ترین شاخص برای بررسی خشک‌سالی شناخته می‌شود، از شاخص SPI شش‌ماهه برای شبیه‌سازی خشک‌سالی استفاده شد و نتایج نشان داد که این شاخص قابلیت محاسبه دوره‌های خشک‌سالی و ترسالی را داراست و با استفاده از روش‌های تلفیقی استفاده‌شده در این تحقیق می‌توان به تخمین دقیقی از این شاخص دست یافت. با این حال، با توجه به این که در محاسبه این شاخص تنها از پارامتر بارش استفاده می‌شود و یکی از محدودیت‌های آن عدم لحاظ بیلان آب براساس میزان تبخیر تعرق است، در مطالعات آبی می‌توان کارایی روش‌های معرفی‌شده را برای مدل‌سازی شاخص بارش - تبخیر تعرق استاندارد شده (SPEI) با در نظر گرفتن مقیاس‌های زمانی مختلف، استفاده کرد و نتایج حاصله را با تحقیق حاضر مقایسه نمود.

تشکر و قدردانی

بدین وسیله نویسندگان از حمایت دانشگاه تبریز در انجام این پژوهش تشکر و قدردانی می‌نمایند.

کاهش می‌دهند. همچنین روش‌های تلفیقی در شبیه‌سازی مقادیر حداقل و حداکثر سری‌زمانی SPI نسبت به روش GPR موفق‌تر هستند. برای تمامی ایستگاه‌ها، ملاحظه شد که مدل با پارامترهای ورودی SPI_{t-1} , SPI_{t-2} , SPI_{t-3} , T_{t-1} , R_{t-1} داده است و استفاده از داده‌های اقلیمی باعث بهبود نتایج و کاهش مقدار خطا به میزان 10 تا 25 درصد شده است که با نتایج Khosravi et al. (2014) که نشان دادند پارامترهای اقلیمی به تنهایی دارای دقت مطلوبی در تخمین شاخص SPI نیستند اما اگر در کنار سایر پارامترها مانند الگوهای پیوند از دور استفاده شوند باعث بهبود دقت نتایج می‌شوند، هم‌خوانی دارد. در حالت استفاده از مقادیر SPI دوره‌های قبل نیز با استفاده از هر دو روش تلفیقی به‌کاررفته در تحقیق دقت مطلوبی در فرایند پیش‌بینی به‌دست آمد. بنابراین، در صورت عدم دسترسی به سایر داده‌های اقلیمی می‌توان از مقادیر SPI دوره‌های قبل برای پیش‌بینی خشک‌سالی استفاده کرد. هم‌چنین برای مدل‌های توسعه‌یافته روش GARCH، مشاهده شد که شاخص خشک‌سالی SPI می‌تواند با استفاده از SPI_{t-1} به‌عنوان تنها متغیر ورودی شبیه‌سازی شود. نتایج حاصل از آنالیز حساسیت نشان داد که پارامتر SPI_{t-1} بیشترین تأثیر را در مدل‌سازی خشک‌سالی داراست که با نتایج حاصل از تحقیق Morid et al. (2008) که نشان دادند در تعیین شاخص‌های خشک‌سالی SPI و EDI با استفاده از شبکه عصبی مصنوعی، بهترین مدل‌ها در تمام مقیاس‌های زمانی آن‌هایی هستند که شامل مقادیر شاخص

References

- 1- Agarwal, A., Maheswaran, R., Sehgal, V., Khos, R., Sivakumar, B. and Bernhofer, C., 2016. Hydrologic regionalization using wavelet-based multiscale entropy method. *Journal of Hydrology*, 538, pp.22–32.
- 2- Amirat, Y., Benbouzid, M., Wang, T., Bacha, K. and Feld, G., 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133, pp.202–209.
- 3- Govindaraju, R.S., 2000. Artificial neural networks in hydrology. I: Preliminary concepts. *Hydrologic Engineering*, ASCE, 5(2), pp.115-123.
- 4- Engle, R.F., 1982. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflations. *Econometrica*, 50, pp.987-1007.
- 5- Hayes, M.J., 2007. What is drought: drought indices. National drought mitigation center, University of Nebraska. (Online). <http://drought.unl.edu/whatis/indices.htm>, 2007.
- 6- Hayes, M.J., Svoboda, M.D., Wilhite, D.A. and Vanyarkho, O.V., 1999. Monitoring the 1996 drought using the standardized precipitation index. *Bulletin of the American Meteorological Society*, 80(3), pp.429- 437.
- 7- Hung, W.U., Hayes, M.J., Wilhite, D.A. and Svoboda, M. D., 2005. The effect of the length of record on the standardized precipitation index calculation. *International journal of climatology*, 25, pp.505-520.
- 8- Khosravi, M., Nasiri, M., Safavi, A.A. and Pourjafarian, N., 2014. Drought forecasting using artificial neural network, case study: Siraz station. *Journal of Geographical Studies of Arid Regions*, 2(8), pp.103-119. (In Persian).

- 9- Laux, P., Vogl, S., Qiu, W., Knoche, H.R. and Kunstmann, H., 2011. Copula-based statistical refinement of precipitation in RCM simulations over complex terrain hydrology. *Earth System Science*, 15, pp.2401-2419.
- 10- McKee, T.B., Doesken, J. and Kleist, J., 1993. The Relationship of drought frequency and duration to time scales. In *Eighth Conference on Applied Climatology, Anaheim, California*.
- 11- Modarres, R. and Ouarda, T.B., 2013. Modeling rainfall-runoff relationship using multivariate GARCH model. *Journal of Hydrology*, 499, pp.1-18.
- 12- Modarres, R. and Ouarda, T.B., 2014. Modeling the relationship between climate oscillations and drought by a multivariate GARCH model. *Water Resources Research*, 50(1), pp.601-618.
- 13- Modarres, R., Sarhadi, A. and Burn, D.H., 2016. Changes of extreme drought and flood events in Iran. *Global and Planetary Change*, 144, pp.67-81.
- 14- Morid, S., Smakhtin, V. and Bagherzadeh, K., 2008. Drought forecasting using artificial neural networks and time series of drought indices. *International Journal of Climatology*, 27, pp.2103-2111.
- 15- Morid, S., Smakhtin, V. and Moghaddasi, M., 2006. Comparison of seven meteorological indices for drought monitoring in Iran. *International Journal of Climatology*, 26(7), pp.971-985.
- 16- Neal, R.M., 1997. Monte carlo implementation of gaussian process models for bayesian regression and classification. *Technical report, no. 9702*.
- 17- Nosrati, K., Eslamian, S., Shahbazi, A., Malekian, A. and Saravi, M.M., 2009. Application of daily water resources assessment model for monitoring water resources indices. *International Journal of Ecological Economics and Statistics*, 13, pp.88-99.
- 18- Rezazadeh, A. and Sattari, M.T., 2016. Estimation of scour depth of piers in hydraulic structures using Gaussian process regression. *Journal of Applied Research in Irrigation and Drainage Structures Engineering*, 16(65), pp.19-36. (In Persian).
- 19- Saada, N. and Abu-Romman, A., 2017. Multi-site modeling and simulation of the standardized precipitation index (SPI) in Jordan. *Journal of Hydrology: Regional Studies*, 14, pp.83-91.
- 20- Samuelsson, O., Björk, A., Zambrano, J. and Carlsson, B., 2017. Gaussian process regression for monitoring and fault detection of wastewater treatment processes. *Water Science and Technology*, 75(12), pp.2952-2963.
- 21- Shokrikochak, S. and Behnia, A., 2013. Monitoring and prediction of Khuzestan province, Iran drought using SPI drought index and Markov chain. *Irrigation Sciences and Engineering*, 36(3), pp.1-12. (In Persian).
- 22- Siviapragasam, C. and Liong, S., 2001. Rainfall and runoff forecasting with SSA-SVM approach. *Hydroinformation*, 3(5), pp.141-152.
- 23- Wang, W., Van Gelder, P.H. and Vrijling, J.K., 2005. Testing and modeling autoregressive conditional heteroskedasticity of streamflow processes. *Nonlinear Processes in Geophysics*, 12, pp.55-66.
- 24- Wu, Z. and Huang, N.E., 2004. A study of the characteristics of white noise using the empirical mode 4decomposition method. *Proceedings of the Royal Society of London 460A*, pp.1597-1611.
- 25- Younesi, M., Shahraki, N., Marofi, S. and Nozari, H., 2018. Drought forecasting using artificial wavelet neural network integrated model (WA-ANN) and time series model (ARIMA). *Irrigation Sciences and Engineering*, 41(2), pp.167-181. (In Persian).
- 26- Zhu, S., Luo, X., Xu, Z. and Ye, L., 2019. Seasonal streamflow forecasts using mixture-kernel GPR and advanced methods of input variable selection. *Hydrology Research*, 50(1), pp.200-14.