



Golestan University



Journal of the Climate Change Research

Scientific Journal of Golestan University
Vol. 6, No. 22, Summer 2025



Development of intelligent machine learning and Jenkins box models based on the full ensemble mode decomposition method for meteorological drought modeling (Case study: Khuzestan Province)

Sadaf Piri¹, Mohammad Ansari Ghojghar^{2*}

¹ Ph.D. candidate, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: Sadaf.piri@ut.ac.ir

² Corresponding Author, Assistant Professor, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: Ansari.ghojghar@ut.ac.ir

Article Info

Article type:
Research Full Paper

Article history:

Received: 2025-4-11
Accepted: 2025-5-10

Keywords:

Climate change
Standardized precipitation index
Gaussian process
Integrated seasonal moving average autoregressive model

ABSTRACT

Drought is one of the natural hazards, especially in arid and semi-arid regions. Khuzestan Province is highly vulnerable to drought due to its strategic geographical location and strong dependence on water resources. Therefore, in the present study, the analysis and prediction of meteorological drought in Khuzestan Province was investigated with the intelligent machine and Jenkins Box GPR models CEEMD- and CEEMD-SARIMA during the 30-year statistical period (1989-2020). To assess drought conditions, the Standard Precipitation Index (SPI) obtained from data from eight synoptic stations in Khuzestan Province was used. In the next step, the modeling results were compared with each other using the aforementioned models and goodness of fit indices. The results indicated that the CEEMD-GPR model is very efficient in estimating the SPI index in Khuzestan province. Also, the long-term SPI time windows had higher accuracy than the short-term time windows. For example, at Omidiyeh station, using the 12-month SPI instead of the 1-month SPI reduced the RMSE and MAE values from 0.178 and 0.097 to 0.167 and 0.087, respectively. In addition, the R and NS values also increased from 0.954 and 0.969 to 0.963 and 0.974. In general, it can be stated that the CEEMD-GPR model is able to learn a more complex dynamic structure of the data by using the components extracted from the CEEMD decomposition. Accordingly, the results of this study show that hybrid models based on CEEMD decomposition, along with machine learning, are powerful and highly efficient tools for analyzing and predicting meteorological drought in arid and semi-arid climates.

Cite this article: Piri, S., Ansari Ghojghar, M. (2025). Development of intelligent machine learning and Jenkins box models based on the full ensemble mode decomposition method for meteorological drought modeling (Case study: Khuzestan Province). Journal of the Climate Change research, 6 (22), 81-96.



©The author(s)

Publisher: Golestan University

Doi: [10.30488/CCR.2025.516420.1276](https://doi.org/10.30488/CCR.2025.516420.1276)



توسعه مدل‌های هوشمند یادگیری ماشین و باکس جنکینز مبتنی بر روش تجزیه مد گروهی کامل به منظور مدل‌سازی خشکسالی هواشناسی (مطالعه موردی: استان خوزستان)

صدف پیری^۱، محمد انصاری قوجقار^{۲*}

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

^۲ استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران، رایانامه: Ansari.ghojghar@ut.ac.ir

اطلاعات مقاله	چکیده
<p>نوع مقاله: مقاله کامل علمی</p> <p>تاریخ دریافت: ۱۴۰۴/۱/۲۳ تاریخ پذیرش: ۱۴۰۴/۲/۲۱</p> <p>واژه‌های کلیدی: تغییر اقلیم شاخص بارش استاندارد فراپند گاوسی مدل خودرگرسیو یکپارچه میانگین متحرک فصلی</p>	<p>خشک‌سالی از جمله بلایای طبیعی، علی‌الخصوص در مناطق خشک و نیمه‌خشک به‌شمار می‌آید. استان خوزستان به سبب دارا بودن موقعیت جغرافیایی استراتژیک و وابستگی شدید به منابع آب، در مقابل خشک‌سالی به‌شدت آسیب‌پذیر است. از این‌رو در پژوهش حاضر، تجزیه و تحلیل و پیش‌بینی خشک‌سالی هواشناسی در استان خوزستان به ترتیب با مدل‌های هوشمند یادگیری ماشین و باکس جنکینز CEEMD-GPR و CEEMD-SARIMA در طول دوره آماری ۳۰ ساله (۲۰۲۰-۱۹۸۹) مورد بررسی قرار گرفت. جهت ارزیابی شرایط خشک‌سالی، از شاخص استاندارد بارندگی (SPI) حاصل از داده‌های هشت ایستگاه سینوپتیک استان خوزستان استفاده شد. در گام بعدی نتایج مدل‌سازی توسط روش‌های ذکر شده و با استفاده از شاخص‌های نیکویی برازش با یکدیگر مقایسه شدند. نتایج حاصله بیانگر این بود که مدل CEEMD-GPR به‌منظور برآورد شاخص SPI در استان خوزستان از کارایی بسیار بالایی برخوردار است. همچنین پنجره‌های زمانی بلندمدت SPI از دقت بالاتری نسبت به پنجره‌های زمانی کوتاه مدت برخوردار بودند. به‌عنوان مثال در ایستگاه امیدیه، استفاده از SPI ۱۲ ماهه به جای SPI ۱ ماهه موجب کاهش مقادیر RMSE و MAE به‌ترتیب از ۰/۱۷۸ و ۰/۰۹۷ به ۰/۱۶۷ و ۰/۰۸۷ گردید. علاوه بر این، مقادیر R و NS نیز از ۰/۹۵۴ و ۰/۹۶۹ به ۰/۹۶۳ و ۰/۹۷۴ افزایش یافت. به‌طور کلی می‌توان عنوان نمود که مدل CEEMD-GPR قادر است با استفاده از مؤلفه‌های استخراج شده از تجزیه CEEMD، ساختار دینامیکی پیچیده‌تری از داده‌ها را فرا گیرد. بر همین اساس، نتایج این پژوهش نشان می‌دهد که مدل‌های ترکیبی مبتنی بر تجزیه CEEMD در کنار یادگیری ماشین، ابزارهایی قدرتمند و با کارایی بالا جهت تحلیل و پیش‌بینی خشک‌سالی هواشناسی در اقلیم‌های خشک و نیمه‌خشک هستند.</p>

استناد: پیری، صدف؛ انصاری، قوجقار محمد. (۱۴۰۴). توسعه مدل‌های هوشمند یادگیری ماشین و باکس جنکینز مبتنی بر روش تجزیه مد گروهی کامل به منظور مدل‌سازی خشک‌سالی هواشناسی (مطالعه موردی: استان خوزستان). نشریه پژوهش‌های تغییرات آب و هوایی، ۶ (۲۲)، ۹۶-۸۱.



مقدمه

کمبود بارش، قابلیت تحت تأثیر قرار دادن منابع طبیعی گوناگون از جمله آب، خاک، رودخانه‌ها و پوشش گیاهی را دارد و سبب خشک‌سالی‌های هواشناسی، هیدرولوژیکی و کشاورزی می‌گردد. شاخص‌های چندمتغیره اجتماعی، اقتصادی و... خشک‌سالی می‌توانند شدت و ضعف انواع گوناگون خشک‌سالی را به طور همزمان نشان داده و ارزیابی نمایند (Aghelpour et al., 2020). خشک‌سالی شامل چهار دسته می‌باشد؛ خشک‌سالی هواشناسی، خشک‌سالی کشاورزی، خشک‌سالی هیدرولوژیکی و خشک‌سالی اجتماعی-اقتصادی (Wilhite and Glantz, 1985). پیش‌بینی خشک‌سالی یکی از چالش‌های عمده مدیران آب، کشاورزان و سایر بهره‌برداران این حوزه است. ایران، به ویژه ناحیه کویر مرکزی آن، در کمر بند خشک و فراخشک جهان قرار دارد و تغییرات شدت خشک‌سالی، اثرات مستقیمی بر زندگی مردم، فعالیت‌های کشاورزی، آب‌های سطحی و زیرزمینی، اقتصاد، معیشت، امنیت، سطح رفاه اجتماعی و استراتژی‌های ملی دارد (Aghelpour et al., 2020). تحلیل شرایط، مشخصات و وضعیت خشک‌سالی به‌عنوان یک نوع خطر طبیعی در مناطق مختلف با تمرکز بر جمع‌آوری راهکارهای مبارزه با خشک‌سالی و مدیریت مخاطرات آن، از اهمیت بسیار ویژه‌ای برخوردار می‌باشد (Negahban et al., 2024). از این رو برای شناخت نوسانات مکانی و زمانی خشک‌سالی و برنامه‌ریزی در حیطه تدابیر مدیریتی مفید برای مواجهه با آن، پژوهش‌های پیرامون این موضوع، امری حیاتی است (Moisa et al., 2022). طی سالیان اخیر، مدل‌های فراوانی برای پیش‌بینی شاخص‌های خشک‌سالی مورد استفاده قرار گرفته است که از بین آن‌ها می‌توان مدل‌های مبتنی بر یادگیری ماشین را نام برد. این مدل‌ها به‌طور گسترده‌ای جهت پیش‌بینی شاخص SPI^۱، مورد استفاده قرار گرفته و عملکرد مناسب آن‌ها در شرایط گوناگون آب و هوایی گزارش شده است (Belayneh et al., 2014; Deo et al., 2017;)

(Mokhtarzad et al., 2017; Zahraie et al., 2017). در پژوهشی Ozger et al. (2020) به پیش‌بینی مقادیر شاخص شدت خشک‌سالی پالمر خود کالیبره شده با استفاده از سه مدل مستقل متفاوت و شش مدل ترکیبی با دو تکنیک تجزیه گوناگون، همچون تجزیه حالت تجربی (EMD^۲) و تجزیه موجک (WD^۳) پرداختند. نتایج نشان داد که دقت مدل‌های مستقل، به‌خصوص در پیش‌بینی‌های مقادیر شاخص شدت خشک‌سالی پالمر خود کالیبره شده میان‌مدت، رضایت‌بخش نبود. با این حال، دقت پیش‌بینی با معرفی تکنیک‌های EMD و WD به‌طور قابل ملاحظه‌ای افزایش یافته است. در تحقیقی دیگر Agana & Homaifar (2018) شبکه باور عمیق (DBN^۴)، رگرسیون بردار پشتیبان (SVR^۵)، پرسپترون چندلایه (MLP^۶) را با EMD ترکیب نمودند تا شاخص جریان استاندارد را برای یک گام جلوتر و دو گام جلوتر از مقیاس‌های زمانی پیش‌بینی نمایند. نتایج حاصله بیانگر آن بود که مدل‌های هیبریدی، برتری قابل ملاحظه‌ای نسبت به مدل‌های استاندارد دارند. Adnan et al. (2023) به بررسی مدل‌سازی خشک‌سالی در کشور پاکستان بر اساس روش‌های اکتشافی و جدید یادگیری ماشین پرداختند. این پژوهش نشان داد که مدل‌های اکتشافی، نتایج دقیقی در خصوص پیش‌بینی خشک‌سالی ارائه می‌دهند. پژوهش حاضر از چندین جهت دارای نوآوری و تمایز با مطالعات پیشین در حوزه مدل‌سازی خشک‌سالی هواشناسی است. در این تحقیق، با ترکیب روش‌های هوشمند و سنتی، برای نخستین بار مدل‌های یادگیری ماشین و سری زمانی باکس جنکینز، مبتنی بر روش تجزیه مد گروهی کامل به کار گرفته شدند تا دقت و پایداری پیش‌بینی خشک‌سالی افزایش یابد. برخلاف پژوهش‌های متداول که تنها از یک مدل بهره می‌گیرند، این تحقیق با طراحی یک چارچوب ترکیبی و چندمرحله‌ای، سعی در بهبود دقت و کارایی مدل‌سازی و پیش‌بینی خشک‌سالی دارد. این رویکرد می‌تواند

² Empirical Mode Decomposition

³ Wavelet decomposition

⁴ Deep belief network

⁵ Support vector regression

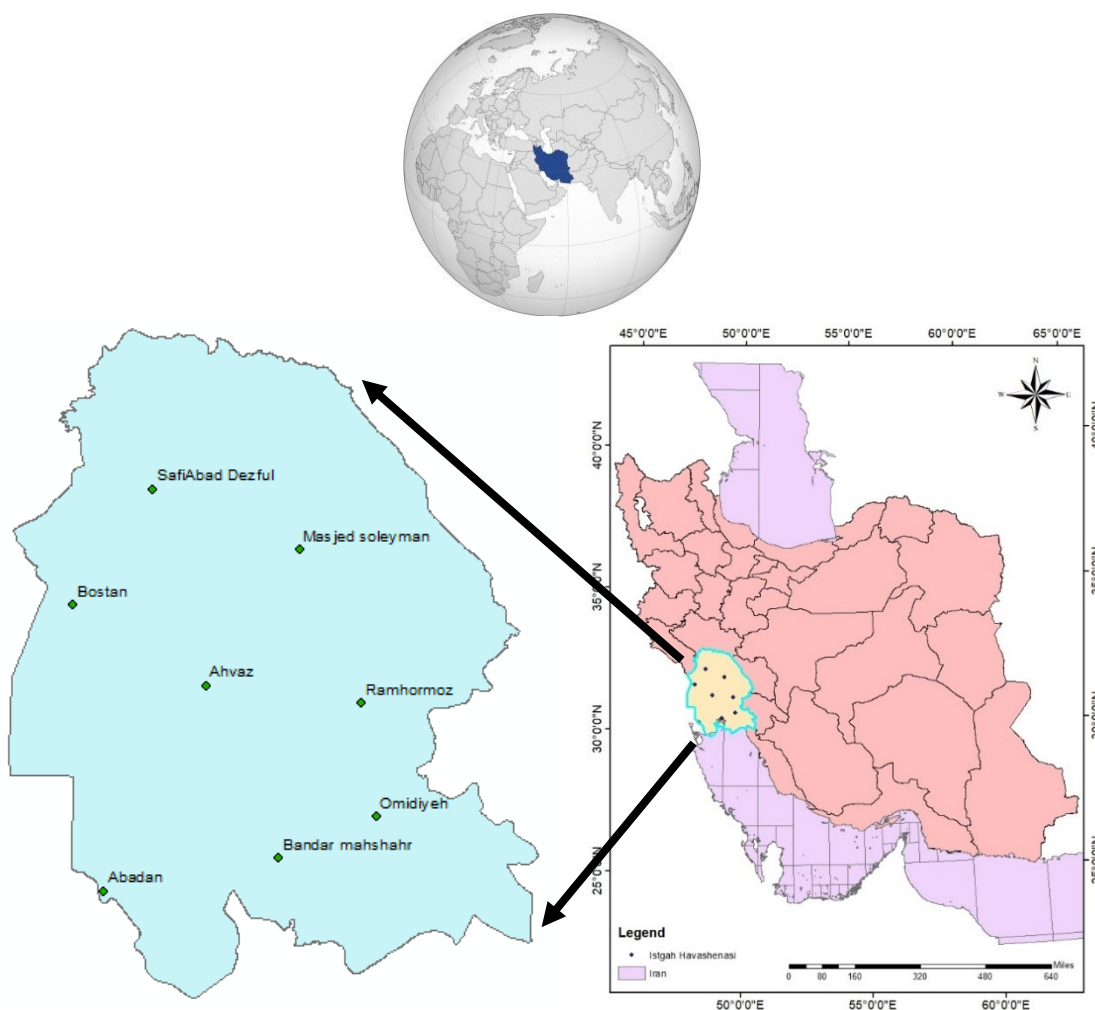
⁶ Multilayer perceptron

¹ Standardized precipitation index

داده‌ها و روش تحقیق

استان خوزستان در جنوب غربی ایران قرار دارد و یکی از مهم‌ترین و پرتنش‌ترین نواحی از لحاظ منابع آب و مخاطرات اقلیمی به‌شمار می‌آید. این استان با وسعتی بالغ بر ۶۴ هزار کیلومترمربع، دارای اقلیم گرم و نیمه‌خشک تا خشک است و میانگین بارندگی سالانه آن به‌طور متوسط حدود ۲۵۰ تا ۴۰۰ میلی‌متر است. قرارگیری رودخانه‌های بزرگ مانند کرخه، دز و کارون در این استان اهمیت منابع آبی را دوچندان کرده، با وجود این، تغییرات اقلیمی، خشک‌سالی‌های پی در پی و برداشت‌های بی‌رویه از منابع آبی، خوزستان را در معرض چالش‌ها و بحران‌های جدی محیط‌زیستی قرار داده است. موقعیت کشوری و استانی منطقه مورد مطالعه و ایستگاه‌های بررسی شده آن، مطابق شکل ۱ است.

مبنایی برای توسعه سامانه‌های هشدار در آینده باشد. روش‌های سنتی پیش‌بینی خشک‌سالی، مانند مدل‌های آماری ساده، به سبب ماهیت غیرخطی و غیرایستا بودن داده‌های هواشناسی، اغلب دقت لازم را ندارند. از سویی دیگر، روش‌های نوینی هم‌چون الگوریتم‌های یادگیری ماشین، توانایی مطلوبی در تحلیل سری‌های زمانی پیچیده و استخراج الگوهای پنهان دارند. هم‌چنین انتخاب استان خوزستان با عنایت به اهمیت استراتژیک، اقلیم خشک و نیمه‌خشک و آسیب‌پذیری بالای آن در برابر پدیده خشک‌سالی، کاربرد و ارزش عملی پژوهش را دوچندان می‌کند. افزون بر این تاکنون مطالعاتی با این سطح از جزئیات و با استفاده از چارچوب ترکیبی مذکور در این منطقه انجام نشده است.



شکل ۱: جایگاه جغرافیایی و پراکنش ایستگاه‌های مورد مطالعه

گرفتن ماهیت استانداردسازی شده این شاخص، اساسی‌ترین نقطه قوت آن، توانایی مقایسه ویژگی‌های خشک‌سالی در بازه‌های زمانی و مکانی گوناگون و همچنین انواع آب‌وهوا می‌باشد. برای ارزیابی این شاخص می‌توان مقادیر بارش ماهانه یا مجموع بارندگی در دوره‌های زمانی مدنظر را محاسبه کرد. این شاخص از طریق رابطه ۱ محاسبه می‌شود و طبقه‌بندی آن در جدول ۱ ارائه شده است.

$$SPI = \frac{(P - \mu)}{S} \quad \text{رابطه (۱)}$$

P مقدار بارش هر ماه، μ میانگین بارش بلندمدت و S انحراف معیار مقدار بارش است.

در پژوهش حاضر برای استخراج پهنه‌های خشک‌سالی هشت ایستگاه هواشناسی (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) واقع در استان خوزستان، از داده‌های بارندگی طی ۳۰ سال آماری مشترک (۱۹۸۹-۲۰۲۰) استفاده گردید. در گام بعدی، پس از دریافت و آماده‌سازی داده‌های بارش از سایت هواشناسی کشور، مقادیر شاخص بارش استاندارد شده (SPI) جهت تشخیص سال‌های خشک و تر محاسبه گردید. این شاخص اولین بار توسط McKee et al. (1993) ارائه شد. این شاخص جهت ارزیابی خشک‌سالی مورد استفاده قرار می‌گیرد و به وسیله آن می‌توان زمان آغاز، شدت و همچنین مدت وقوع خشک‌سالی را در دوره‌های زمانی گوناگون اندازه‌گیری نمود. با در نظر

جدول ۱: رتبه‌بندی شدت خشک‌سالی بر اساس شاخص هواشناسی

SPI values	2.00 or more	1.50 to 1.99	1.00 to 1.49	0.0 to 0.99	0.0 to -0.99	-1.00 to -1.49	-1.50 to -1.99	-2.00 or less
Drought classification	Extreme Wet	Severe Wet	Moderate Wet	Mild Wet	Mild Drought	Moderate Drought	Severe Drought	Extreme Drought

نظر گرفته می‌شود و اطلاعات مدل‌سازی در تابع کرنل ذخیره شده است (Zhu et al., 2019).

روش تجزیه مد تجربی گروهی کامل
(CEEMD^۲): روش تجزیه مد تجربی (EMD^۳) توسط Huang و همکاران (۱۹۹۸) ارائه شد. این روش، یک روش تحلیلی و قدرتمند غیرخطی و غیرتابست در تجزیه فرکانس داده‌های زمانی است و بر این فرض بنا شده است که هر سیگنال دارای زیرمجموعه‌های گوناگونی تحت عنوان توابع مد ذاتی (IMF^۴) می‌باشد (Keshvari et al., 2022). در برخی موارد به علت اختلاف در مدها، سیگنال‌ها موجب تناوب و سیگنال تصادفی شده و سبب وقوع گسیختگی توزیع حوزه زمان-فرکانس می‌شود. در پی این عملکرد، میانگین IMFها مبهم شده و EMD نمی‌تواند کارایی مطلوبی از خود نشان دهد. جهت حل این مشکل، تجزیه مد

رگرسیون فرآیند گاوسی (GPR^۱): این روش، یکی از روش‌های مطلوب و انعطاف‌پذیر در حیطة یادگیری ماشین است که بر اساس چارچوب بی‌زین عمل می‌کند. رگرسیون فرآیند گاوسی جهت مدل‌سازی ارتباطات پیچیده و غیرخطی میان متغیرها بدون احتیاج به تعیین صریح ساختار تابع به کار برده می‌شود و از این‌رو برای مدل‌سازی پدیده‌های اقلیمی هم‌چون خشک‌سالی بسیار مناسب است. در GPR، به جای فرض تابعی مشخص میان ورودی و خروجی، فرض بر آن است که تابع هدف $F(x)$ از یک فرآیند گاوسی پیروی می‌کند که در رابطه زیر شرح داده شده است:

$$f(x) \sim GP(m(x), k(x, x')) \quad \text{رابطه (۲)}$$

که در آن $m(x)$ تابع میانگین و $k(x, x')$ تابع کواریانس یا کرنل است. در غالب موارد، تابع میانگین، صفر در

² Complete Ensemble Empirical Mode Decomposition

³ Empirical Mode Decomposition

⁴ Intrinsic Mode Function

¹ Gaussian Process Regression

فصلی را در داده‌ها دارد (Li et al., 2018). مدل SARIMA با استفاده از اپراتور تأخیر به صورت زیر بیان می‌شود:

$$\Phi_p(L^s)\phi_p(L)(1-L)^d(1-L^s)^p y_t = \theta_q(L^s)\theta_q(L)\varepsilon_t \quad \text{رابطه (۵)}$$

که در آن L اپراتور وقفه، ϕ_p و θ_q ضرایب خودرگرسیو و میانگین متحرک در بخش غیرفصلی، Φ_p و θ_q ضرایب خودرگرسیو و میانگین متحرک در بخش فصلی و ε_t جمله خطای سفید با میانگین صفر و واریانس ثابت است.

مدل‌های پیش‌بینی: در پژوهش حاضر، از مدل‌های پیش‌بینی شاخص SPI با پنجره‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه استفاده گردید. به‌عنوان مثال مدل اول پیش‌بینی می‌کند که میزان SPI_{12} در زمان $t+1$ (آینده)، تابعی از میزان SPI_{12} در زمان t (حال) است. به عبارتی دیگر، مدل از داده‌های SPI_{12} در زمان t به‌عنوان ورودی استفاده کرده و با بهره‌گیری از الگوریتم‌های مدنظر، میزان SPI_{12} را در زمان $t+1$ پیش‌بینی می‌نماید. در سایر مدل‌ها نیز بر حسب پنجره زمانی آن‌ها این عمل انجام می‌پذیرد.

$$SPI_{12(t+1)} = f(SPI_{12(t)}) \quad \text{مدل یک}$$

$$SPI_{6(t+1)} = f(SPI_{6(t)}) \quad \text{مدل دو}$$

$$SPI_{3(t+1)} = f(SPI_{3(t)}) \quad \text{مدل سه}$$

$$SPI_{1(t+1)} = f(SPI_{1(t)}) \quad \text{مدل چهار}$$

نمودار جریانی پژوهش حاضر در شکل ۳ نمایش داده شده است.

تجربی گروهی کامل (CEEMD) ارائه شد و شامل موارد زیر است (Torres et al., 2011):

در گام نخست، در هر مرحله درصدی از سیگنال تصادفی گوسین به داده‌ها افزوده می‌شود. برای I سیگنال تصادفی متفاوت گاوسی EMD انجام شده و میزان IMF اول (اولین تابع مد ذاتی) از میانگین I مد به دست می‌آید.

$$IMF_1 = \frac{1}{I} \sum_{i=1}^I E_1(x + \varepsilon w_i) \quad \text{رابطه (۳)}$$

که در آن: I تعداد آزمایش‌ها، E_1 عملگر EMD که اولین IMF را از سیگنال ورودی استخراج می‌کند، X سیگنال اصلی ورودی، ε دامنه سیگنال تصادفی و w_i سیگنال تصادفی گاوسی برای آزمایش i ام است.

در ادامه مقدار r_1 از رابطه زیر به دست می‌آید:

$$r_1 = x - IMF_1 \quad \text{رابطه (۴)}$$

که در آن r_1 اولین باقی‌مانده پس از استخراج IMF_1 می‌باشد. در گام بعدی، پس از محاسبه IMF ها، با بهره‌گیری از تبدیل هیلبرت^۱، فرکانس لحظه‌ای به دست آمده و به صورت تصویری دوبعدی از فرکانس لحظه‌ای متغیر نشان داده می‌شود.

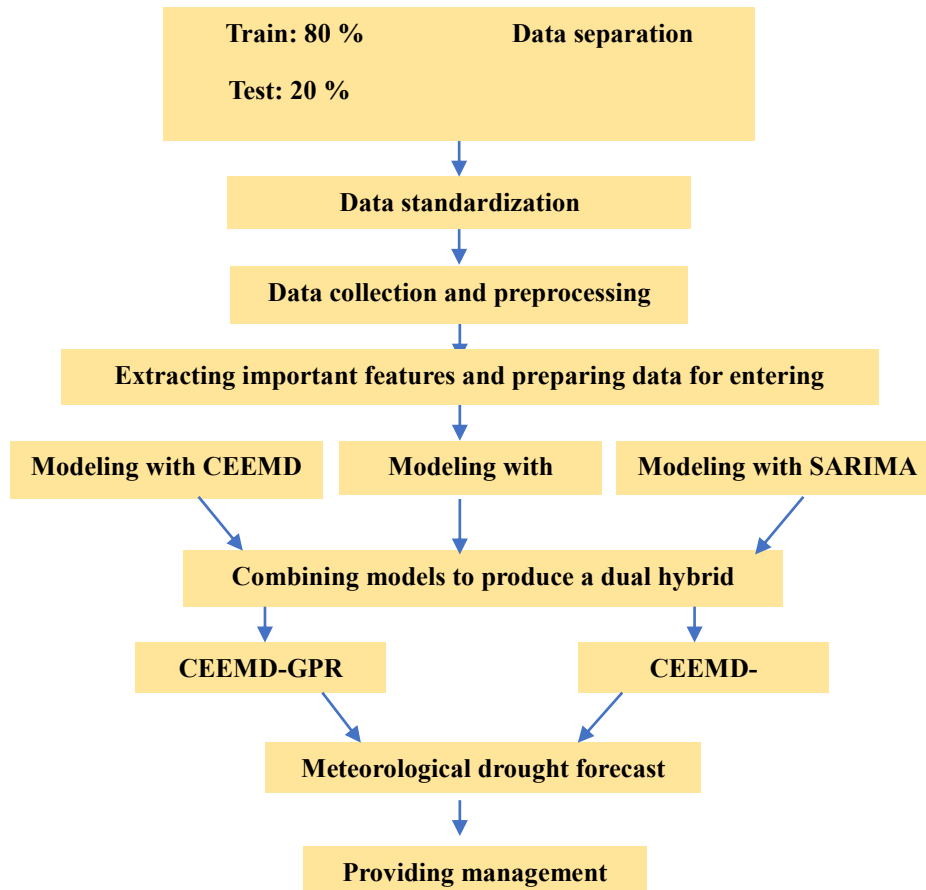
مدل خودرگرسیو یکپارچه میانگین متحرک

فصلی (SARIMA)^۲: مدل SARIMA از جمله

مدل‌های کلاسیک و بسیار کارآمد در تحلیل سری‌های زمانی است و قابلیت ارائه مدل‌سازی مولفه‌های روند، نوسانات تصادفی و الگوهای فصلی را به شکل همزمان دارد. این روش در واقع به‌عنوان مدل توسعه‌یافته مدل ARIMA، قابلیت در نظر گرفتن اثرات تکرار شونده

¹ Hilbert

² Seasonal autoregressive integrated moving average



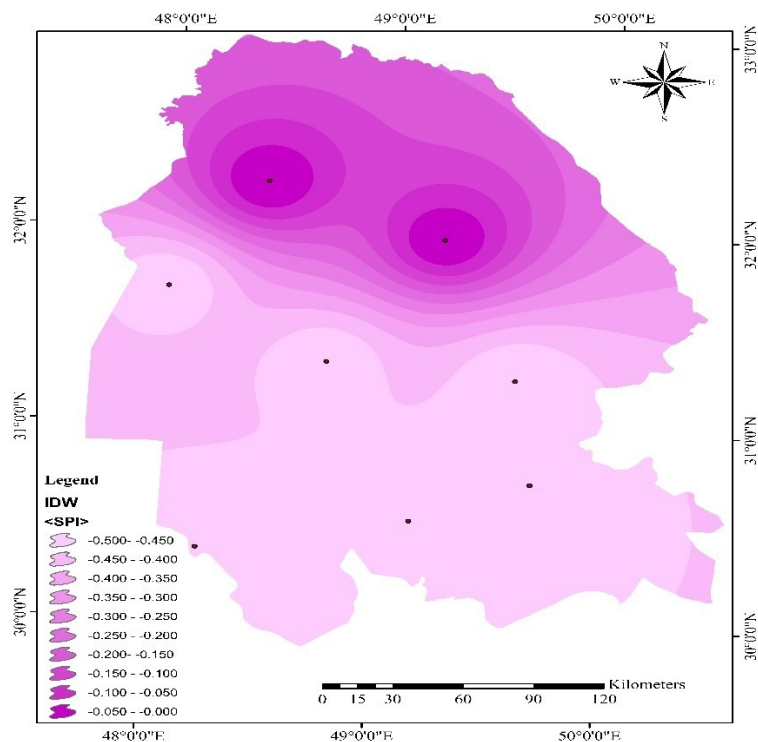
شکل ۳: روندنمای مراحل مدل‌سازی با مدل‌های CEEMD-GPR و CEEMD-SARIMA

نتایج و بحث

هدف از این پژوهش، پیش‌بینی خشک‌سالی هواشناسی و تعیین کارایی الگوریتم‌های هیبریدی یادگیری ماشین و باکس جنکینز برای نشان دادن شرایط خشک‌سالی است؛ از این‌رو هشت ایستگاه سینوپتیک واقع در استان خوزستان (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) مورد مطالعه و بررسی قرار گرفت. در شکل ۲، پهنه‌بندی خشک‌سالی هواشناسی ایستگاه‌های مورد مطالعه در طول دوره آماری ذکر شده نمایش داده شده است.

نتایج حاصل از محاسبه معیارهای ارزیابی R ، $RMSE$ ، NS و MAE برای تعیین بهترین مدل در جدول‌های ۲ تا ۴ ارائه گردیده است. بر اساس جدول ۲ و با توجه به نتایج به‌دست آمده از معیارهای ارزیابی نیکویی برآزش در هشت ایستگاه مورد مطالعه، به‌صورت کلی، SPI ۱۲ ماهه و ۶ ماهه نتایج بهتر و با

دقت بالاتری را نسبت به SPI ۳ ماهه و ۱ ماهه ارائه دادند. در مقایسه SPI ۱۲ ماهه با ۶ ماهه نیز SPI ۱۲ ماهه عملکرد بهتری از خود نشان داد. به‌عنوان مثال در ایستگاه امیدیه، استفاده از SPI ۱۲ ماهه به جای SPI ۱ ماهه موجب کاهش مقادیر $RMSE$ و MAE به‌ترتیب از $0/1178$ و $0/097$ به $0/167$ و $0/087$ گردید. علاوه بر این، مقادیر R و NS نیز از $0/954$ و $0/969$ به $0/963$ و $0/974$ افزایش یافت. بنابراین استفاده از پنجره‌های زمانی بلندمدت در مدل‌سازی و پیش‌بینی شاخص SPI در مقایسه با پنجره‌های زمانی کوتاه‌مدت توسط مدل $CEEMD-GPR$ در استان خوزستان سبب افزایش عملکرد و بهبود خروجی‌ها می‌گردد. این موضوع می‌تواند به سبب ماهیت نوسانی و پیچیده رفتار اقلیم منطقه و اثرات تجمعی بارش در دوره‌های زمانی طولانی‌تر باشد. در جدول ۳ نیز نتایج حاصله از شاخص‌های نیکویی برآزش مدل $CEEMD-SARIMA$ ارائه شده است.



شکل ۲: پهنه‌بندی خشکسالی هواشناسی در ایستگاه‌های مورد مطالعه در طول دوره آماری

کاهش، افزایش، افزایش و کاهش روبرو شد. به عنوان مثال در ایستگاه آبادان، مقادیر NS و R مدل CEEMD-SARIMA در مقایسه با مدل CEEMD-GPR، به ترتیب از ۰/۷۴۱ و ۰/۷۱۹ به ۰/۹۷۸ و ۰/۹۶۹ رسید. به طور کلی مقایسه میان دو مدل CEEMD-SARIMA و CEEMD-GPR نشان داد که مدل GPR در ایستگاه‌های مورد مطالعه، به خصوص در شرایط نوسانی و داده‌های نویزی، کارایی و عملکرد بهتری از خود نشان می‌دهد. این امر را می‌توان با خصیصه ذاتی فرآیند گاوسی در مدل‌سازی روابط غیرخطی و لحاظ نمودن عدم قطعیت پیش‌بینی مرتبط دانست. مدل SARIMA با وجود این‌که در شناسایی روندهای خطی و الگوهای فصلی عملکرد قابل قبولی از خود نشان می‌دهد، اما در رویارویی با مؤلفه‌های غیرخطی و متلاطم (که در خروجی CEEMD وجود داشت)، دقت پایین‌تری از خود نشان داد. به بیانی دیگر، الگوریتم GPR با بهره‌گیری از تابع‌های هسته‌ای، می‌تواند روابط غیرخطی پیچیده در داده‌ها را مدل‌سازی کند و برخلاف مدل‌های کلاسیک سری زمانی هم‌چون SARIMA، وابسته به فرض خطی

در این مدل نیز SPI ۱۲ ماهه، دقت و صحت بالاتری نسبت به سایر پنجره‌های زمانی دارا می‌باشد. به عنوان مثال در ایستگاه مسجدسلیمان، استفاده از SPI ۱۲ ماهه به جای SPI ۶ ماهه موجب کاهش مقادیر RMSE و MAE به ترتیب از ۰/۴۱۹ و ۰/۳۵۶ به ۰/۴۰۸ و ۰/۳۴۳ گردید. علاوه بر این، مقادیر R و NS نیز از ۰/۶۹۱ و ۰/۶۹۶ به ۰/۷۰۲ و ۰/۷۱۸ افزایش یافت. نتایج حاصله نشان‌دهنده آن است که در اقلیم گرم و نیمه‌خشک خوزستان، اثرات بارش و نوسانات اقلیمی به‌طور معمول در بازه‌های زمانی بلندمدت‌تر خود را بهتر نمایان می‌کنند. فلذا استفاده از مقیاس‌های زمانی طولانی‌تر در محاسبه شاخص SPI موجب می‌شود مدل‌ها اطلاعات کارآمدتر و جامع‌تری از رفتار اقلیمی را دارا باشند و این موضوع باعث بهبود دقت و صحت پیش‌بینی می‌گردد. بنابر نتایج حاصله از جدول ۲ و ۳، مدل CEEMD-GPR با اختلاف معنی‌داری نسبت به مدل CEEMD-SARIMA از دقت بیشتری برخوردار است. مقادیر RMSE، R، NS و MAE در مدل CEEMD-GPR نسبت به مدل CEEMD-SARIMA به ترتیب با

ابزارهایی قدرتمند و با کارایی بالا جهت تحلیل و پیش‌بینی خشک‌سالی هواشناسی در اقلیم‌های خشک و نیمه‌خشک هستند. نتایج این بخش با برخی از پژوهش‌ها مطابقت دارد (Bazrafshan et al., 2015; Hosseini-Moghari and Araghinejad., 2016; Mohammadi et al., 2022 and Mousazadeh et al., 2023).

بودن داده‌ها یا ایستایی آن‌ها نمی‌باشد. مدل CEEMD-GPR قادر است با استفاده از مؤلفه‌های استخراج شده از تجزیه CEEMD، ساختار دینامیکی پیچیده‌تری از داده‌ها را فرا بگیرد. بر همین اساس، نتایج این پژوهش نشان می‌دهد که مدل‌های ترکیبی مبتنی بر تجزیه CEEMD در کنار یادگیری ماشین،

جدول ۲: نتایج آماری داده‌های ورودی به مدل CEEMD-GPR به منظور پیش‌بینی شاخص SPI

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	NS	MAE	RMSE	R	NS	MAE	RMSE
آبادان	SPI _{۱۲}	۰.۹۹۶	۰.۹۹۸	۰.۰۳۷	۰.۱۱۷	۰.۹۶۹	۰.۹۷۸	۰.۰۸۲	۰.۱۶۳
	SPI _۶	۰.۹۹۳	۰.۹۹۶	۰.۰۳۹	۰.۱۱۹	۰.۹۶۸	۰.۹۷۷	۰.۰۸۵	۰.۱۶۵
	SPI _۳	۰.۹۹۱	۰.۹۹۴	۰.۰۴۲	۰.۱۲۲	۰.۹۶۶	۰.۹۷۶	۰.۰۸۷	۰.۱۶۷
	SPI _۱	۰.۹۸۹	۰.۹۹۱	۰.۰۴۳	۰.۱۲۴	۰.۹۶۵	۰.۹۷۶	۰.۰۸۸	۰.۱۶۸
بستان	SPI _{۱۲}	۰.۹۹۵	۰.۹۹۷	۰.۰۳۸	۰.۱۱۸	۰.۹۶۸	۰.۹۷۷	۰.۰۸۳	۰.۱۶۴
	SPI _۶	۰.۹۹۲	۰.۹۹۵	۰.۰۴۱	۰.۱۲۱	۰.۹۶۷	۰.۹۷۵	۰.۰۸۶	۰.۱۶۶
	SPI _۳	۰.۹۸۸	۰.۹۹۳	۰.۰۴۴	۰.۱۲۳	۰.۹۶۴	۰.۹۷۴	۰.۰۸۹	۰.۱۶۹
	SPI _۱	۰.۹۸۷	۰.۹۹۰	۰.۰۴۵	۰.۱۲۵	۰.۹۶۳	۰.۹۷۴	۰.۰۹۱	۰.۱۷۱
اهواز	SPI _{۱۲}	۰.۹۹۴	۰.۹۹۶	۰.۰۳۹	۰.۱۱۹	۰.۹۶۷	۰.۹۷۶	۰.۰۸۴	۰.۱۶۵
	SPI _۶	۰.۹۹۱	۰.۹۹۴	۰.۰۴۳	۰.۱۲۴	۰.۹۶۶	۰.۹۷۵	۰.۰۸۷	۰.۱۶۷
	SPI _۳	۰.۹۸۸	۰.۹۹۱	۰.۰۴۶	۰.۱۲۶	۰.۹۶۵	۰.۹۷۳	۰.۰۹۲	۰.۱۷۲
	SPI _۱	۰.۹۸۶	۰.۹۸۹	۰.۰۴۸	۰.۱۲۷	۰.۹۶۳	۰.۹۷۲	۰.۰۹۵	۰.۱۷۳
بندر ماهشهر	SPI _{۱۲}	۰.۹۹۳	۰.۹۹۵	۰.۰۴۱	۰.۱۲۱	۰.۹۶۴	۰.۹۷۵	۰.۰۸۶	۰.۱۶۶
	SPI _۶	۰.۹۹۱	۰.۹۹۳	۰.۰۴۴	۰.۱۲۵	۰.۹۶۱	۰.۹۷۴	۰.۰۸۸	۰.۱۶۹
	SPI _۳	۰.۹۸۷	۰.۹۸۸	۰.۰۴۷	۰.۱۲۹	۰.۹۵۹	۰.۹۷۲	۰.۰۹۳	۰.۱۷۴
	SPI _۱	۰.۹۸۵	۰.۹۸۷	۰.۰۴۹	۰.۱۳۱	۰.۹۵۷	۰.۹۷۱	۰.۰۹۶	۰.۱۷۶
امیدیه	SPI _{۱۲}	۰.۹۹۲	۰.۹۹۴	۰.۰۴۳	۰.۱۲۲	۰.۹۶۳	۰.۹۷۴	۰.۰۸۷	۰.۱۶۷
	SPI _۶	۰.۹۸۹	۰.۹۹۱	۰.۰۴۵	۰.۱۲۷	۰.۹۶۱	۰.۹۷۳	۰.۰۸۹	۰.۱۷۱
	SPI _۳	۰.۹۸۶	۰.۹۸۷	۰.۰۴۸	۰.۱۳۳	۰.۹۵۶	۰.۹۷۲	۰.۰۹۴	۰.۱۷۵
	SPI _۱	۰.۹۸۴	۰.۹۸۴	۰.۰۵۱	۰.۱۳۵	۰.۹۵۴	۰.۹۶۹	۰.۰۹۷	۰.۱۷۸
رامهرمز	SPI _{۱۲}	۰.۹۹۱	۰.۹۹۳	۰.۰۴۴	۰.۱۲۴	۰.۹۶۲	۰.۹۷۴	۰.۰۸۹	۰.۱۶۸
	SPI _۶	۰.۹۸۸	۰.۹۹۱	۰.۰۴۶	۰.۱۲۹	۰.۹۵۹	۰.۹۷۱	۰.۰۹۱	۰.۱۷۳
	SPI _۳	۰.۹۸۵	۰.۹۸۶	۰.۰۴۹	۰.۱۳۶	۰.۹۵۵	۰.۹۶۸	۰.۰۹۵	۰.۱۷۶
	SPI _۱	۰.۹۸۳	۰.۹۸۳	۰.۰۵۳	۰.۱۳۷	۰.۹۵۳	۰.۹۶۶	۰.۰۹۸	۰.۱۸۱
مسجدسلیمان	SPI _{۱۲}	۰.۹۸۹	۰.۹۹۲	۰.۰۴۶	۰.۱۲۵	۰.۹۶۱	۰.۹۷۳	۰.۰۹۰	۰.۱۶۹
	SPI _۶	۰.۹۸۷	۰.۹۸۹	۰.۰۴۷	۰.۱۳۱	۰.۹۵۸	۰.۹۶۶	۰.۰۹۳	۰.۱۷۴
	SPI _۳	۰.۹۸۴	۰.۹۸۵	۰.۰۵۱	۰.۱۳۸	۰.۹۵۴	۰.۹۶۶	۰.۰۹۶	۰.۱۷۷
	SPI _۱	۰.۹۸۱	۰.۹۸۱	۰.۰۵۶	۰.۱۴۱	۰.۹۵۲	۰.۹۶۳	۰.۰۹۹	۰.۱۸۳
صفی‌آباد دزفول	SPI _{۱۲}	۰.۹۸۸	۰.۹۹۱	۰.۰۴۸	۰.۱۲۷	۰.۹۵۹	۰.۹۷۲	۰.۰۹۲	۰.۱۷۲
	SPI _۶	۰.۹۸۵	۰.۹۸۸	۰.۰۴۹	۰.۱۳۲	۰.۹۵۷	۰.۹۶۵	۰.۰۹۵	۰.۱۷۵
	SPI _۳	۰.۹۸۴	۰.۹۸۴	۰.۰۵۴	۰.۱۳۹	۰.۹۵۳	۰.۹۶۴	۰.۰۹۷	۰.۱۷۸
	SPI _۱	۰.۹۷۷	۰.۹۷۷	۰.۰۵۸	۰.۱۴۲	۰.۹۵۱	۰.۹۶۱	۰.۱۰۲	۰.۱۸۴

جدول ۳: نتایج آماری داده‌های ورودی به مدل ترکیبی CEEMD-SARIMA به منظور پیش‌بینی شاخص SPI

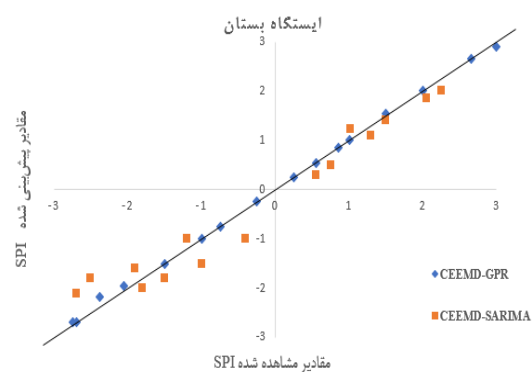


ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		RMSE	MAE	NS	R	RMSE	MAE	NS	R
آبادان	SPI _{۱۲}	۰,۳۶۷	۰,۳۰۳	۰,۷۹۸	۰,۷۷۶	۰,۴۰۱	۰,۳۳۴	۰,۷۴۱	۰,۷۱۹
	SPI _۶	۰,۳۶۹	۰,۳۰۵	۰,۷۹۶	۰,۷۷۳	۰,۴۰۳	۰,۳۳۵	۰,۷۳۷	۰,۷۱۶
	SPI _۳	۰,۳۷۱	۰,۳۰۶	۰,۷۹۴	۰,۷۷۱	۰,۴۰۴	۰,۳۳۶	۰,۷۳۶	۰,۷۱۴
	SPI _۱	۰,۳۷۴	۰,۳۰۶	۰,۷۹۳	۰,۷۶۹	۰,۴۰۶	۰,۳۳۶	۰,۷۳۴	۰,۷۱۱
بستان	SPI _{۱۲}	۰,۳۶۸	۰,۳۰۴	۰,۷۹۷	۰,۷۷۴	۰,۴۰۲	۰,۳۳۶	۰,۷۳۹	۰,۷۱۱
	SPI _۶	۰,۳۷۲	۰,۳۰۷	۰,۷۹۴	۰,۷۷۲	۰,۴۰۵	۰,۳۳۷	۰,۷۳۶	۰,۷۰۹
	SPI _۳	۰,۳۷۳	۰,۳۰۹	۰,۷۹۱	۰,۷۶۸	۰,۴۰۷	۰,۳۳۹	۰,۷۳۶	۰,۷۰۷
	SPI _۱	۰,۳۷۵	۰,۳۱۱	۰,۷۸۴	۰,۷۶۴	۰,۴۰۹	۰,۳۴۱	۰,۷۳۱	۰,۷۰۴
اهواز	SPI _{۱۲}	۰,۳۶۹	۰,۳۰۵	۰,۷۹۵	۰,۷۷۱	۰,۴۰۳	۰,۳۳۸	۰,۷۳۹	۰,۷۰۹
	SPI _۶	۰,۳۷۴	۰,۳۰۸	۰,۷۸۳	۰,۷۶۵	۰,۴۰۸	۰,۳۴۲	۰,۷۳۳	۰,۷۰۶
	SPI _۳	۰,۳۷۶	۰,۳۱۲	۰,۷۷۳	۰,۷۶۱	۰,۴۰۹	۰,۳۴۳	۰,۷۳۱	۰,۷۰۳
	SPI _۱	۰,۳۷۷	۰,۳۱۴	۰,۷۷۱	۰,۷۵۷	۰,۴۱۱	۰,۳۴۵	۰,۷۲۹	۰,۷۰۱
بندر ماهشهر	SPI _{۱۲}	۰,۳۷۱	۰,۳۰۶	۰,۷۸۷	۰,۷۶۹	۰,۴۰۵	۰,۳۳۹	۰,۷۳۷	۰,۷۰۶
	SPI _۶	۰,۳۷۵	۰,۳۰۹	۰,۷۸۱	۰,۷۶۲	۰,۴۰۹	۰,۳۴۳	۰,۷۳۵	۰,۷۰۳
	SPI _۳	۰,۳۷۸	۰,۳۱۳	۰,۷۷۲	۰,۷۵۶	۰,۴۱۲	۰,۳۴۷	۰,۷۲۶	۰,۷۰۱
	SPI _۱	۰,۳۷۹	۰,۳۱۷	۰,۷۶۹	۰,۷۵۱	۰,۴۱۴	۰,۳۴۹	۰,۷۲۱	۰,۶۹۸
امیدیه	SPI _{۱۲}	۰,۳۷۲	۰,۳۰۷	۰,۷۸۴	۰,۷۶۳	۰,۴۰۶	۰,۳۴۱	۰,۷۳۳	۰,۷۰۴
	SPI _۶	۰,۳۷۶	۰,۳۱۴	۰,۷۷۶	۰,۷۶۷	۰,۴۱۱	۰,۳۴۵	۰,۷۲۲	۰,۷۰۳
	SPI _۳	۰,۳۸۱	۰,۳۱۵	۰,۷۷۱	۰,۷۴۳	۰,۴۱۳	۰,۳۴۸	۰,۷۱۷	۰,۷۰۳
	SPI _۱	۰,۳۸۳	۰,۳۱۸	۰,۷۶۴	۰,۷۴۱	۰,۴۱۵	۰,۳۵۱	۰,۷۱۴	۰,۶۹۵
رامهرمز	SPI _{۱۲}	۰,۳۷۳	۰,۳۰۸	۰,۷۷۶	۰,۷۵۹	۰,۴۰۷	۰,۳۴۲	۰,۷۲۵	۰,۷۰۳
	SPI _۶	۰,۳۷۷	۰,۳۱۵	۰,۷۷۳	۰,۷۴۲	۰,۴۱۲	۰,۳۴۶	۰,۷۲۵	۰,۷۰۲
	SPI _۳	۰,۳۸۲	۰,۳۱۶	۰,۷۶۸	۰,۷۳۷	۰,۴۱۶	۰,۳۵۲	۰,۷۱۲	۰,۷۰۱
	SPI _۱	۰,۳۸۵	۰,۳۱۹	۰,۷۶۱	۰,۷۳۴	۰,۴۱۷	۰,۳۵۳	۰,۷۰۵	۰,۶۹۵
مسجد سلیمان	SPI _{۱۲}	۰,۳۷۵	۰,۳۰۹	۰,۷۷۴	۰,۷۵۶	۰,۴۰۸	۰,۳۴۳	۰,۷۱۸	۰,۷۰۲
	SPI _۶	۰,۳۷۹	۰,۳۱۶	۰,۷۷۱	۰,۷۴۱	۰,۴۱۳	۰,۳۴۷	۰,۷۰۹	۰,۷۰۱
	SPI _۳	۰,۳۸۴	۰,۳۱۷	۰,۷۶۶	۰,۷۳۳	۰,۴۱۷	۰,۳۵۴	۰,۷۰۳	۰,۶۹۳
	SPI _۱	۰,۳۸۷	۰,۳۲۱	۰,۷۵۹	۰,۷۳۱	۰,۴۱۹	۰,۳۵۶	۰,۶۹۶	۰,۶۹۱
صفی‌آباد دزفول	SPI _{۱۲}	۰,۳۷۷	۰,۳۱۱	۰,۷۷۱	۰,۷۴۴	۰,۴۰۹	۰,۳۴۴	۰,۷۱۴	۰,۷۰۲
	SPI _۶	۰,۳۸۱	۰,۳۱۷	۰,۷۶۳	۰,۷۳۶	۰,۴۱۴	۰,۳۴۸	۰,۷۰۲	۰,۶۹۸
	SPI _۳	۰,۳۸۵	۰,۳۱۹	۰,۷۵۴	۰,۷۲۷	۰,۴۱۸	۰,۳۵۷	۰,۷۰۱	۰,۶۹۱
	SPI _۱	۰,۳۹۱	۰,۳۲۴	۰,۷۴۶	۰,۷۲۳	۰,۴۲۱	۰,۳۶۱	۰,۶۹۴	۰,۶۸۵

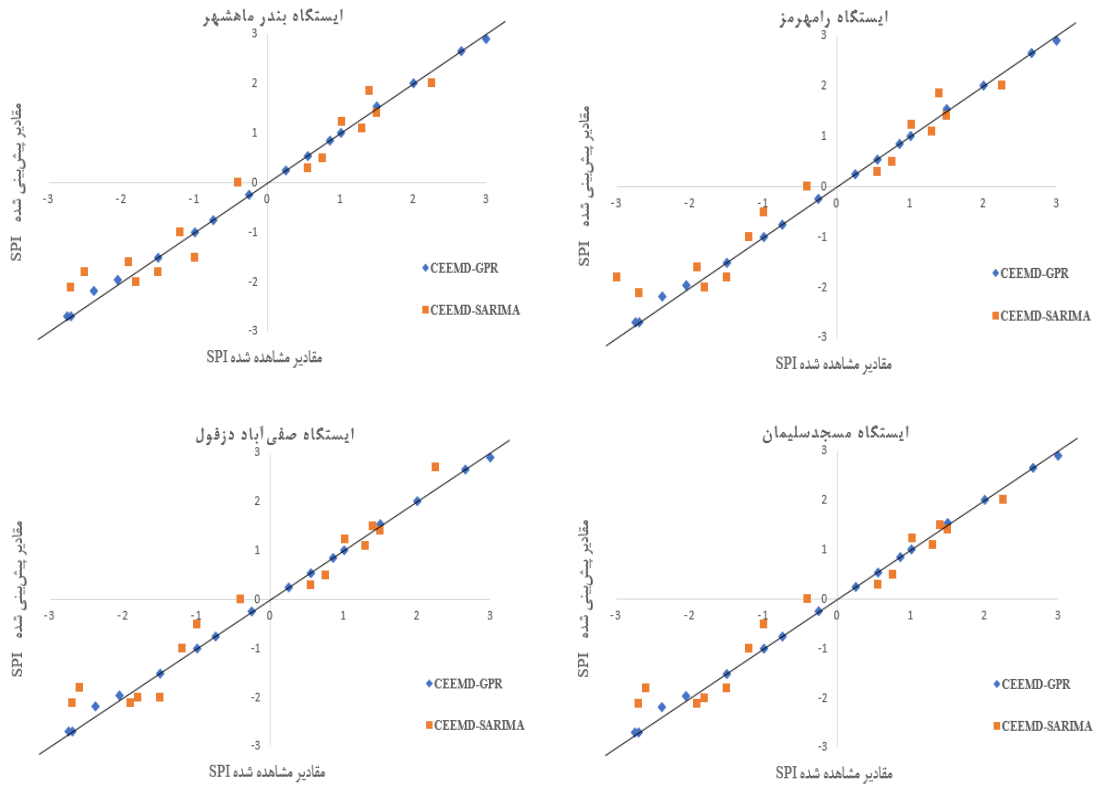
این استان می‌باشد. به‌کارگیری تجزیه CEEMD باعث این شده است که سری زمانی پیچیده شاخص SPI به مؤلفه‌های آسان‌تر و جداگانه‌ای با خصوصیات فرکانسی متمایز شکسته شود. این موضوع سبب کاهش نویز، جداسازی بهتر نوسانات کوتاه‌مدت و بلندمدت و تسهیل یادگیری به‌وسیله مدل‌های بعدی می‌شود. در مقابل،

نتایج پیش‌بینی شاخص SPI بیانگر عملکرد مطلوب مدل تلفیقی CEEMD-GPR در هشت ایستگاه مورد مطالعه در استان خوزستان است. علاوه بر این، مدل ذکر شده با دارا بودن بیشترین مقدار R و ضریب NS و کمترین مقدار MAE و RMSE، نسبت به مدل CEEMD-SARIMA بهترین مدل برای پیش‌بینی در

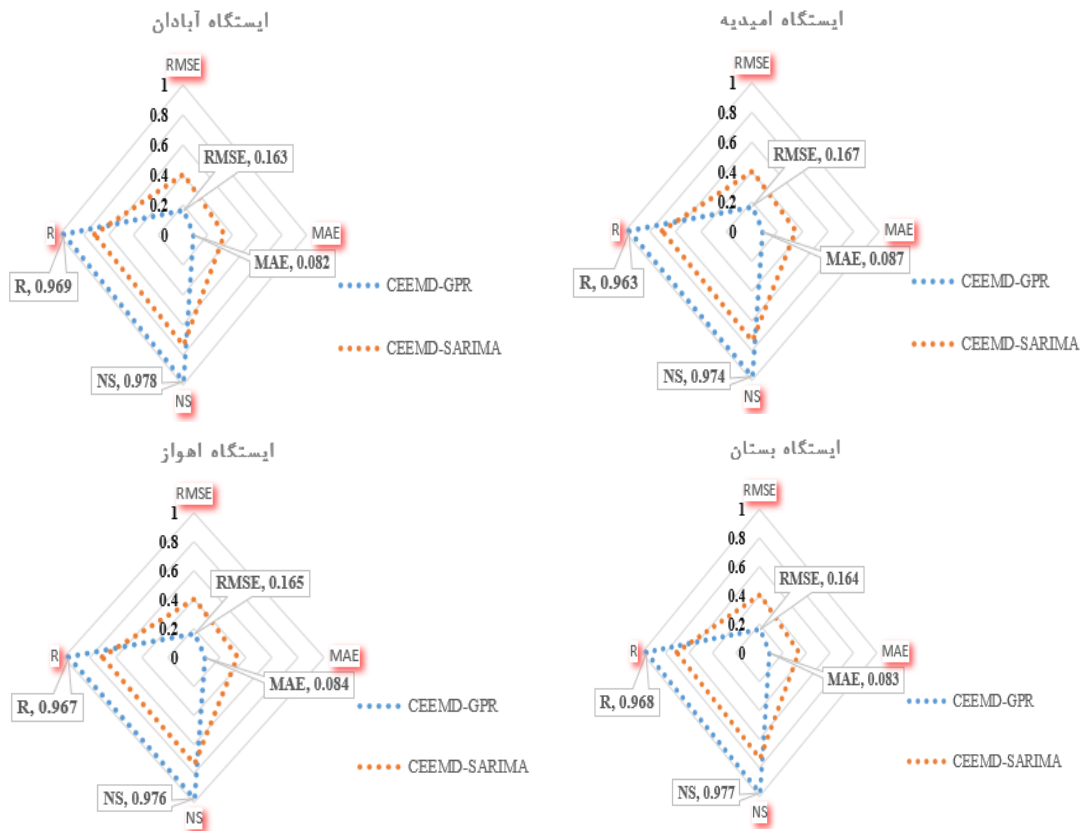
می‌دهد. مدل شکل ۴، مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI ۱۲ ماهه را برای داده‌های بخش آزمون ایستگاه‌های استان خوزستان نمایش می‌دهد. در این شکل، رابطه بین مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI در تمامی ایستگاه‌ها، با خطی با شیب ۴۵ درجه ارزیابی گردید. مدل CEEMD-SARIMA با دقت کمتر و پراکندگی بیشتر نسبت به مدل CEEMD-GPR، بیشترین اختلاف و فاصله را با نیم‌ساز ربع اول و سوم دارد. مدل تلفیقی CEEMD-GPR نیز با بیشترین تطابق نسبت به نیم‌ساز ربع اول و سوم، بیشترین بازدهی و کارایی را به همراه دارد. شکل ۵ نیز نشان دهنده مقایسه مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI با استفاده از شاخص‌های نیکویی برازش در استان خوزستان می‌باشد.

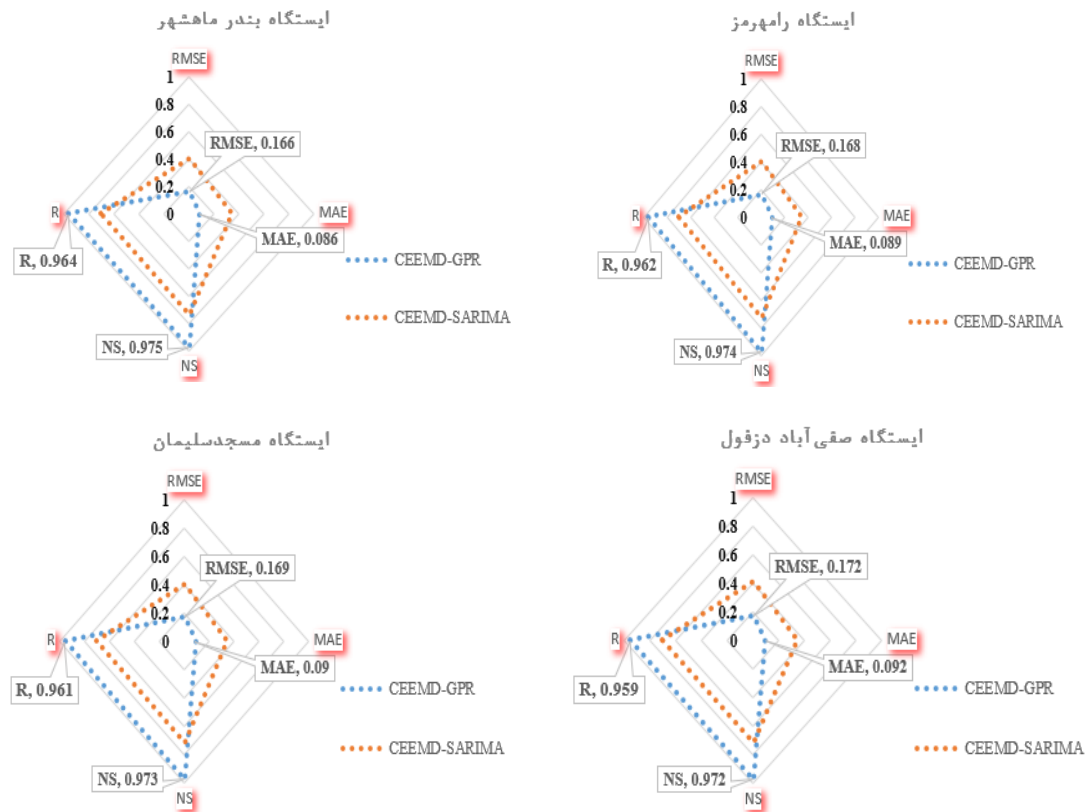
مدل CEEMD-SARIMA با وجود این‌که با بهره‌گیری از همان ساختار اولیه CEEMD قادر است مؤلفه‌های سری زمانی را به صورت تفکیک شده تحلیل کند، اما ماهیت مدل SARIMA به عنوان یک مدل خطی و بر پایه ایستایی، توان محدودی در یادگیری رفتارهای غیرخطی دارد. به خصوص در مقیاس‌های زمانی بلندمدت که الگوهای خشک‌سالی امکان دارای پیچیدگی‌های زمانی-مکانی بیشتری باشند، SARIMA قابلیت پایین‌تری در بازنمایی این دینامیک‌ها از خود نشان داده است. از این رو تلفیق قابلیت تفکیک مؤلفه‌ها به وسیله CEEMD و قدرت یادگیری غیرخطی GPR موجب ایجاد یک مدل کارآمد و قدرتمند شده که از لحاظ آماری و کاربردی، جهت پیش‌بینی شرایط خشک‌سالی در اقلیم‌هایی هم‌چون خوزستان، برتری قابل توجهی نسبت به مدل‌های کلاسیک از خود نشان





شکل ۴: مقایسه مقادیر مشاهده شده و پیش‌بینی شده SPI_{12} با استفاده از مدل‌های CEEMD-SARIMA و CEEMD-GPR





شکل ۵: مقایسه شاخص‌های نیکویی برازش در ایستگاه‌های استان خوزستان - ترکیب SPI_{12}

به مدل CEEMD-SARIMA از دقت بیشتری برخوردار است. از سویی دیگر فاصله قابل توجهی از لحاظ دقت میان دو مدل ذکر شده وجود دارد. از این رو می‌توان نتیجه گرفت که مدل CEEMD-GPR به‌منظور برآورد شاخص SPI در استان خوزستان از کارایی بالایی برخوردار است. هم‌چنین پنجره‌های زمانی بلندمدت SPI از دقت بالاتری نسبت به پنجره‌های زمانی کوتاه مدت برخوردار بودند. در نواحی خشک و نیمه‌خشک هم‌چون استان خوزستان که بارش اکثراً در فصول خاصی رخ می‌دهد و به‌طور معمول فرآیند بارندگی در آن پراکنندگی مکانی و زمانی دارد، SPI ۱۲ ماهه بهتر می‌تواند تغییرات الگوی بارش و مشخصات خشک‌سالی را نمایش دهد. برای مقابله با خشک‌سالی هواشناسی در استان خوزستان، ترکیبی از راهکارهای فنی (با بهره‌گیری از مدل‌های CEEMD و یادگیری ماشین)، مدیریتی (مدیریت یکپارچه منابع آب و کشاورزی پایدار) و محیط‌زیستی (کنترل طوفان‌های گردوغبار و احیای

نتیجه‌گیری

خشک‌سالی از جمله بلاهای طبیعی، علی‌الخصوص در مناطق خشک و نیمه‌خشک به‌شمار می‌آید. استان خوزستان به سبب دارا بودن موقعیت جغرافیایی استراتژیک و وابستگی شدید به منابع آب، در مقابل خشک‌سالی به‌شدت آسیب‌پذیر است. خشک‌سالی در این استان می‌تواند تبعاتی هم‌چون کاهش سطح آب تالاب‌ها، کاهش آب مورد نیاز صنایع گوناگون، کاهش تولیدات کشاورزی، تشدید مشکلات اجتماعی و مهاجرت روستاییان به شهرها و عدم امنیت غذایی را به دنبال داشته باشد. بر همین اساس در پژوهش حاضر، دقت و عملکرد دو مدل CEEMD-GPR و CEEMD-SARIMA در هشت ایستگاه سینوپتیک استان خوزستان (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) در طول دوره آماری ۳۰ ساله (۱۹۸۹ تا ۲۰۲۰) مقایسه و تحلیل گردید. طبق نتایج مدل‌ها، به‌طور کلی مدل CEEMD-GPR با اختلاف معنی‌داری نسبت

تاب‌آوری این مناطق در برابر بحران‌های احتمالی زیست‌محیطی خواهد شد. علاوه بر این، نتایج تحقیق نشان می‌دهد که مدل‌های هوشمند ترکیبی، از ظرفیت بالایی در بهبود و تحول پیش‌بینی‌های اقلیمی برخوردارند. بنابراین، پیشنهاد می‌شود که از این مدل‌های دقیق هیبریدی در طراحی سیستم‌های پیش‌آگاهی و هشدار استفاده شود. هم‌چنین، به کارگیری فناوری‌های نوین برای عملیاتی کردن مدل‌سازی‌ها و اطلاع‌رسانی به مردم از طریق اپلیکیشن‌های مبتنی بر این مدل‌ها، می‌تواند به عنوان راهکارهای مدیریتی جامع برای کاهش خسارات ناشی از پدیده‌های مخرب اقلیمی مورد توجه قرار گیرد.

تالاب‌ها) پیشنهاد می‌گردد. به‌طور کلی می‌توان عنوان نمود که مدل CEEMD-GPR قادر است با استفاده از مؤلفه‌های استخراج شده از تجزیه CEEMD، ساختار دینامیکی پیچیده‌تری از داده‌ها را فرا بگیرد. بر همین اساس، نتایج این پژوهش نشان می‌دهد که مدل‌های ترکیبی مبتنی بر تجزیه CEEMD در کنار یادگیری ماشین، ابزارهایی قدرتمند و با کارایی بالا جهت تحلیل و پیش‌بینی خشک‌سالی هواشناسی در اقلیم‌های خشک و نیمه‌خشک هستند. مطالعات انجام شده پیرامون وضعیت خشک‌سالی در استان خوزستان و پیش‌بینی آن، می‌تواند به مسئولین مربوطه نگرشی جامع و یکپارچه در راستای مدیریت بهینه و اصولی ارائه دهد. این امر به نوبه خود، باعث افزایش چشمگیری

منابع

1. Adnan, R. M., Dai, H. L., Kuriqi, A., Kisi, O., & Kermani, M. Z. (2023). Improving drought modeling based on new heuristic machine learning methods. *Ain Shams Engineering Journal*, 14(2023), 1-13.
2. Agana, N.A., Homaifar, A., (2018). EMD-based predictive deep belief network for time series prediction: an application to drought forecasting. *Hydrology* 5. <https://doi.org/10.3390/hydrology5010018>.
3. Aghelpour, P., Mohammadi, B., Biazar, S. M., Kisi, O., & Sourmirinezhad, Z. (2020). A Theoretical Approach for Forecasting Different Types of drought Simultaneously, Using Entropy Theory and Machine-Learning Methods. *ISPRS International Journal of Geo-Information*, 9(12). <https://doi.org/10.3390/ijgi9120701>
4. Bazrafshan, O., Salajegheh, A., Mahdavi, Mohammad, & Fatehi, A. (2015). A study of Efficiency of the Hybrid model Artificial Neural Network Models-stochastic in Hydrological Drought Forecasting using kappa statistics (case study: Gamasiab Watershed Basin). *Iranian Journal of Watershed Management Science*. 8(27), 35-48.
5. Belayneh, A., Adamowski, J., Khalil, B., & Ozga-Zielinski, B. (2014). Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology*, 508, 418-429.
6. Deo, R.C., Kisi, O., & Singh, V.P. (2017a). Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. *Atmospheric Research*, 184, 149-175.
7. Hosseini-Moghari, S. M., & Araghinejad, S. (2016). Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e Kavous Station). *Water and Soil*, 30(1), 247-259.
8. Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N.C., Tung, C.C. & Liu, H.H. 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*. 454(1971): 903- 995.
9. Negahban, S., Mokarram, M., & Moradizadeh Kermani, R. (2024). Assessing the effects of drought hazards on rural communities surrounds Maharlu Lake, Iran. *Environmental Hazards Management*, 11(1), 1-13.

10. Özger, M., Başakın, E. E., Ekmekcioğlu, Ö., & Hacısüleyman, V. (2020). Comparison of wavelet and empirical mode decomposition hybrid models in drought prediction. *Computers and Electronics in Agriculture*, 179. <https://doi.org/10.1016/j.compag.2020.105851>
11. Li, M., Shouwen Ji, S., & Liu, G. (2018). Forecasting of Chinese E-commerce sales: An empirical comparison of ARIMA, nonlinear autoregressive neural network, and a combined ARIMA-NARNN Model. *Mathematical Problems in Engineering*, 6924960, 1024-1038.
12. McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. *Proceedings of the 8th Conference on Applied Climatology*.
13. Moisa, M. B., Merga, B. B., & Gameda, D.O. (2022). Multiple indices-based assessment of agricultural drought: A case study in Gilgel Gibe Sub-basin, Southern Ethiopia. *Theoretical and Applied Climatology*, 148(1), 455-464. DOI: 10.1007/s00704-022-03962-4.
14. Mohammadi, J., Vafaeinezhad, A., Behzadi, S., Aghamohammadi, H., & Hemmasi, A. (2022). Drought prediction and modeling by hybrid wavelet method and neural network algorithms. *RS and GIS for Natural Resources*, 4(13), 87-111.
15. Mokhtarzad, M.; Eskandari, F.; Jamshidi Vanjani, N., Arabasadi, A. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environ. Earth Sci.* 2017, 76, 729. [CrossRef]
16. Mousazadeh, N., Akhundali, A. M., & Ahmadi, F. (2023). Development of Integrated Machine Learning Models Based on Complete Ensemble Empirical Mode Decomposition Method for Estimating Dam Inflow (case study: Dez Dam), 17(4), 701-985
17. Torres, M.E., Colominas, M.A., Schlotthauer, G. & Flandrin, P. 2011. A complete ensemble empirical mode decomposition with adaptive noise. In 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 4144-4147). IEEE.
18. Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the drought phenomenon: the role of definitions. *Water international*, 10(3), 111-120
19. Zahraie, B., Nasser, M., & Nematizadeh, F. 2017. Exploring spatiotemporal meteorological correlations for basin scale meteorological drought forecasting using data mining methods. *Arab. J. Geosci.*, 10, 419.
20. Zhu, S., Luo, X., Xu, Z. & Ye, L. (2019). Seasonal streamflow forecasts using mixture-kernel GPR and advanced methods of input variable selection. *Hydrology Research*. 50(1): 200-214.

