



## مدل سازی خشکسالی بر پایه شاخص SPI با استفاده از داده‌های زمینی و ماهواره‌ای به کمک مدل تلفیقی GPR-CEEMD

کیومرث روشنگر<sup>۱\*</sup>، رقیه قاسم‌پور<sup>۲</sup>

تاریخ ارسال: ۱۳۹۸/۰۱/۰۶

تاریخ پذیرش: ۱۳۹۹/۰۴/۱۱

مقاله پژوهشی

### چکیده

خشکسالی یکی از مشکلات مهمی است که در بخش کشاورزی و منابع آب تأثیرگذار می‌باشد. امروزه استفاده از تکنیک سنجش از دور به عنوان یک ابزار مفید جهت پایش خشکسالی مورد توجه قرار گرفته است. هدف از این مطالعه پیش‌بینی زمانی خشکسالی با استفاده از داده‌های ایستگاه‌های زمینی و ماهواره‌ای محصول TRMM3B43 بین سال‌های ۱۹۹۸-۲۰۱۷ می‌باشد. در این راستا، ابتدا داده‌های بارش به شاخص SPI تبدیل گردید و سپس با استفاده از روش هوشمند رگرسیون فرآیند گاوسی (GPR) بر پایه روش تجزیه‌ی یکپارچه مد تجربی کامل (CEEMD) خشکسالی شهر تبریز مورد بررسی قرار گرفت. مدل‌های متفاوتی تعریف گردید و نرخ تأثیر پارامترهای ورودی مختلف بررسی شد. مشاهده گردید که مقادیر بارش حاصل از ماهواره TRMM در مقیاس ماهانه دارای همبستگی مطلوبی با مقدار بارش حاصل از ایستگاه تبریز بوده و نتایج تحلیل خشکسالی با استفاده از داده‌های ماهواره‌ای تقریباً منطبق بر داده‌های ایستگاه زمینی است. نتایج قابلیت و کارایی بالای روش به کار رفته را در تخمین شاخص خشکسالی SPI به خوبی نشان داد و مشاهده شد که تجزیه سری زمانی بر اساس روش تجزیه‌ی یکپارچه مد تجربی کامل منجر به نتایج دقیق‌تری می‌گردد. تجزیه داده‌های ورودی تقریباً ۳۰ تا ۴۰ درصد دقت پیش‌بینی را افزایش داد. ملاحظه گردید که در پیش‌بینی خشکسالی، عناصر اقلیمی شامل میانگین دما و رطوبت نسبی ماهانه و همچنین شاخص SPI‌های مربوط به ماه‌های گذشته تأثیرگذار می‌باشند و با حذف پارامترهای اقلیمی، خطای مدل‌سازی ۱۵ تا ۲۰ درصد افزایش می‌یابد. همچنین نتایج آنالیز حساسیت نشان داد که SPI-1 تأثیرگذارترین پارامتر در مدل‌سازی است.

واژگان کلیدی: خشکسالی، سنجش از دور، مد تجربی، SPI، GPR

<sup>۱</sup> استاد گروه آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران، kroschangar@yahoo.com (نویسنده مسئول)

<sup>۲</sup> دانشجوی دکتری مهندسی و مدیریت منابع آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران، ghassempourroghy@gmail.com



## مقدمه

خشکسالی طبیعتاً پدیده‌ای است که آهسته پیش‌روی می‌کند و پیش‌بینی وقوع آن تقریباً غیرممکن است. از دلایل اهمیت موضوع خشکسالی، آسیب و خساراتی است که می‌تواند بر تاسیسات زیر بنایی و اقتصادی به همراه داشته باشد. از همین‌رو شناخت هر چه بیشتر این پدیده، راه را برای برنامه‌ریزی و مدیریت هرچه بهتر این رخداد هموارتر نموده و ابزار قوی‌تری را جهت مدیریت بهتر ریسک در دست مبادی ذیربط قرار می‌دهد. در ایران نیز به دلیل کم بودن نزولات جوی سالانه و به طور کلی خشک بودن اقلیم منطقه، وقوع خشکسالی‌ها کشور را از لحاظ تامین آب با بحران روبه‌رو نموده و این موضوع نمود بیشتری پیدا می‌کند. به منظور مطالعه و شناسایی پدیده خشکسالی شاخص‌های متعددی از سوی دانشمندان و متخصصین علم آب و هواشناسی ارائه گردیده است که استفاده از هر یک از این شاخص‌ها در شرایط خاص و مکان‌های مختلف دارای نقاط ضعف و قوت می‌باشند. از مهمترین پارامترهایی که در محاسبات شاخص‌های خشکسالی مورد استفاده قرار می‌گیرد بارش است. بر این اساس هرگاه بارش طی یک دوره زمانی متوالی زیر حالت نرمال قرار گیرد خشکسالی رخ می‌دهد. از آن جایی که ایستگاه‌های اندازه‌گیری بارش پراکنده بوده و دسترسی به اندازه‌گیری‌های بارش معمولاً با تاخیر زمانی همراه است، از این رو وجود روش‌های دیگری برای برآورد بارش ضروری است. در این راستا اطلاعات ماهواره‌ای و سنجنش از دور می‌تواند مورد استفاده قرار گیرد. استفاده از داده‌های ماهواره‌ای امکان برآورد بارش در محدوده وسیعی از سطح زمین، بخصوص برای مناطق صعب‌العبور را امکان‌پذیر ساخته است، که این موضوع سبب توجه محققان به داده‌های ماهواره‌ای شده است. تصاویر ماهواره‌ای خام دارای معایبی نظیر وجود اعوجاج‌های ناشی از تغییر ارتفاع و موقعیت سنجنده و اختلاف ارتفاع و کرویت زمین و همچنین تاثیر میزان ابرناکی هوا هستند. لذا به منظور بهترین استفاده از تصاویر ماهواره‌ای، قبل از استفاده

کاربردی از داده‌های ماهواره‌ای لازم است این داده‌ها با داده‌های زمینی مقایسه شده، دقت آنها مشخص شود و تا حد امکان تصحیح شوند. تاکنون مطالعات زیادی در مورد پایش زمانی و مکانی خشکسالی صورت گرفته است. ادیب و گرجی‌زاده (۱۳۹۵) در تحقیقی به منظور بررسی خشکسالی در حوضه آبریز دز از داده‌های بارندگی سالانه ایستگاه‌های تنگ‌پنج و تله زنگ سد دز طی یک دوره آماری مشترک ۱۷ ساله استفاده کردند. نتایج نشان داد که بیشترین وقوع خشکسالی شدید براساس شاخص‌های ZSI, MCZI, PNI, مربوط به ایستگاه تله زنگ می‌باشد. مقیمی و همکاران (۱۳۹۷) با استفاده از شاخص RDI یک ماهه و مدل زنجیره مارکوف شدت حالت‌های مختلف خشکسالی و وقوع حالت‌های مورد انتظار در استان فارس را بررسی کردند. نتیجه نشان داد که احتمال انتقال به حالت نرمال بیشتر از دیگر حالت‌ها می‌باشد. سیرداس و سن (Sirdas and Sen, 2003) با تحلیل مکانی- زمانی خشکسالی در منطقه Trakya در ترکیه جهت بررسی شدت، مدت و فراوانی و سطح درگیر خشکسالی با استفاده از روش آماری Run و Z-score برای تعیین ویژگی‌های خشکسالی و از روش میانبایی kriging جهت تحلیل فضایی برای ترسیم نقشه توانستند به این نتیجه دست یابند که بین مدت و بزرگی خشکسالی ارتباط وجود دارد. فیشر و همکاران (Fisher et al., 2013) از نمایه دبی استاندارد شده در مقیاس دوساله برای تحلیل خشکسالی‌ها در ۶ حوضه جنوب چین استفاده نمودند. نتایج بررسی‌ها نشان داد که برخی از حوضه‌ها یک دوره خشکسالی را تجربه کرده‌اند که بیشتر شامل حوضه‌های شمالی در جنوب چین می‌باشند. ژیانگ و همکاران (Xiang-Hu et al., 2013) با استفاده از تصاویر TRMM تفاوت بین بارش TRMM و ایستگاه‌های باران‌سنج را در دو مقیاس روزانه و ماهانه، در حوضه Xinjiang طی سال‌های ۱۹۹۸ تا ۲۰۰۳ بررسی کردند. لی و همکاران (Li et al., 2013) به تحلیل زمانی و مکانی خشکسالی با استفاده از داده‌های ماهواره TRMM پرداختند و سیر تغییرات شدت خشکسالی را طی سال‌های ۲۰۰۸ و

انطباقی مقاومت جریان را در رودخانه‌های مارپیچی بررسی کردند. باباعلی و دهقانی (۱۳۹۶) با استفاده از روش شبکه عصبی مصنوعی به برآورد شاخص بارش استاندارد پرداختند. ذو و همکاران (Zhu et al., 2019) از مدل رگرسیون فرآیند گاوسی برای پیش‌بینی دبی رودخانه استفاده کردند. همچنین، سامولسان و همکاران (Samuelsson et al., 2017) از این روش جهت بررسی فرآیندهای 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 فرآیند 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 معادلات مناسب برازش می‌یابد و مدل بدست‌آمده برای پیش‌بینی استفاده می‌شود. از جمله این روش‌ها روش جدید تجزیه مد تجربی یکپارچه کامل است. با توجه به پیچیده بودن پدیده خشکسالی و تاثیر پارامترهای مختلف در پیش‌بینی آن، در تحقیق کنونی با استفاده از داده‌های زمینی ایستگاه سنوپتیک تبریز و داده‌های سنجش از دور ماهواره TRMM3B43، کارایی روش رگرسیون فرآیند گاوسی (GRP) بر پایه تجزیه یکپارچه مد تجربی کامل (CEEMD) به‌عنوان یکی از روش‌های نوین داده کاوی در مدل‌سازی خشکسالی مورد بررسی قرار گرفت. با استفاده از روش تجزیه سیگنال CEEMD 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 خواهد شد. مدل‌های ورودی متفاوتی با استفاده از داده‌های مربوط به عناصر اقلیمی مانند میانگین دما و رطوبت نسبی ماهانه و شاخص SPI ماه‌های گذشته در بازه زمانی (۲۰۱۷-۱۹۹۸) تعریف شد و به پایش زمانی خشکسالی شهر تبریز با استفاده از

۲۰۰۹ بررسی کردند. یان و همکاران (Yan et al., 2014) داده‌های بارش ماهانه TRMM با داده‌های زمینی بارش ۴۰ ایستگاه در حوضه Hai، برای دوره آماری ۱۹۹۸-۲۰۱۰ مقایسه کردند و نشان دادند که همبستگی بسیار بالایی بین این دو منبع داده برقرار می‌باشد، سپس از این مقادیر بارش به عنوان ورودی برای محاسبه شاخص استاندارد بارش استفاده نمودند، نتایج نشان داد که شاخص استاندارد در مقیاس سه ماهه بهترین خروجی را نمایش می‌دهد. مدرس و همکاران (Modarres et al., 2016) به بررسی تغییرات شدت سیلاب و خشکسالی ایران در سال‌های ۱۹۵۰ تا ۲۰۱۰ در برخی از ایستگاه‌ها پرداختند. نتایج بیان‌گر وجود هر دو روند افزایشی و کاهش‌ی در شدت خشکسالی و میزان سیلاب در مناطق مختلف آب و هوایی ایران بود. سادا و ابوروم (Saada and Abu-Romman, 2017) از مدل‌های خطی مانند CARMA برای پیش‌بینی شاخص خشکسالی SPI ۱۲ ماهه استفاده کردند و بیان نمودند که روش به‌کار رفته از کارایی مناسبی برخوردار است. کاظم‌پور چورسی و همکاران (۱۳۹۸) به ارزیابی داده‌های ماهواره‌ای در پایش خشکسالی حوضه آبریز دریاچه ارومیه پرداختند و نشان دادند که شاخص ماهواره‌ای مطلوب برای پایش خشکسالی کشاورزی حوضه آبریز دریاچه ارومیه طی فصل رشد، شاخص وضعیت پوشش گیاهی است. از طرف دیگر، امروزه محققین با ابداع و پیشرفت علمی چون روش‌های هوشمند که ابزاری توانمند، انعطاف‌پذیر و مستقل از مدل‌های دینامیکی سیستم می‌باشند در جستجوی راه‌هایی برای پیشرفت و پیش‌بینی پارامترهای مهم هواشناسی می‌باشند. در دهه‌های اخیر روش‌های نرم برای شبیه‌سازی رفتار سیستم‌ها در زمینه مهندسی آب مورد استفاده قرار گرفته‌اند. این روش‌ها که اکثراً الهام گرفته از پدیده‌های موجود در طبیعت هستند به‌عنوان ابزاری توانمند در حل مسائل پیچیده به شمار می‌آیند (ASCE, 2000). به عنوان نمونه سیواپراگسام و لیئونگ از مدل SVM برای پیش‌بینی بارش-رواناب حوضه Tryggevælde واقع در کشور هلند استفاده کردند (Siviapragasam and Liong, 2001). روشنگر و قاسم‌پور (۱۳۹۷) با استفاده از روش‌های هوشمند رگرسیون بردار پشتیبان و سیستم استنتاج عصبی-فازی

منتهی‌الیه مشرق و جنوب شرق جلگه‌ی تبریز قرار گرفته است. مختصات جغرافیایی شهر تبریز ۳۸ درجه و ۳۶ دقیقه شمالی و ۴۶ درجه و ۴۹ دقیقه شرقی و ارتفاع شهر از سطح دریا ۱۳۴۸ تا ۱۵۶۱ متر می‌باشد. میانگین دمای سالانه شهر تبریز در حدود ۹/۱۱ درجه سانتی‌گراد، میانگین بارش سالانه آن در حدود ۳۰۰ میلی‌متر می‌باشد. در شهر تبریز معمولاً در طول فصل تابستان میزان بارندگی بسیار ناچیز بوده و به ندرت بارش رخ می‌دهد. جدول ۱ حاوی اطلاعات آماری سری زمانی بارندگی ماهانه این ایستگاه می‌باشد. در شکل ۱ نیز منطقه مورد مطالعه نمایش داده شده است.

شاخص SPI شش ماهه پرداخته شد. دو نوع مدل‌سازی با استفاده از داده‌های سری زمانی اصلی (بدون تجزیه داده‌ها) و با تجزیه داده‌ها بر اساس روش‌های تجزیه‌ی یکپارچه مد تجزیه کامل در نظر گرفته شد. همچنین با استفاده از آنالیز حساسیت موثرترین پارامترها در مدل‌سازی خشکسالی تعیین گردید.


## مواد و روش‌ها

### موقعیت و ویژگی‌های منطقه مورد مطالعه

منطقه‌ی مورد مطالعه شهر تبریز در استان آذربایجان شرقی است که مرکز استان آذربایجان شرقی بوده و در

جدول (۱): اطلاعات آماری سری زمانی بارندگی ماهانه ایستگاه انتخابی (۱۹۹۸-۲۰۱۷).

شهر	شاخص آماری			
	میانگین (mm)	بیشینه (mm)	کمینه (mm)	انحراف از معیار
تبریز	24.404	248.4	0	21.144
				درجه اوج
				3.1



شکل (۱): موقعیت منطقه مورد مطالعه و میزان بارندگی ماهانه در ایستگاه مورد نظر در بازه زمانی (۱۹۹۸-۲۰۱۷).

فرایند، تعمیمی طبیعی از توزیع گاوسی است که میانگین و کوواریانس آن به ترتیب یک بردار و یک ماتریس است. مدل‌های رگرسیون فرآیند گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره همدیگر باشد. یکی از جذابیت‌های فرآیند گاوسی تنوع بسیار توابع کوواریانس آن است که به ایجاد توابعی با درجات مختلف همواری یا انواع مختلف ساختارهای پیوستی منجر

### رگرسیون فرآیند گاوسی (GPR)

فرآیند گاوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد دلخواه محدودی از آنها با توزیع‌های گاوسی ادغام شده‌اند. فرآیند گاوسی به طور کامل توسط تابع میانگین  $m(x)$  و تابع کوواریانس  $k(x, x')$  آن تعیین می‌شود. این



می‌توان مسائل را به صورت خطی تفکیک‌پذیر ساخت. با تبدیل نمونه‌ها از فضای ورودی به فضای ویژگی، تفکیک‌کننده غیرخطی به حالت خطی تبدیل خواهد شد. از مهم‌ترین توابع کرنل می‌توان به کرنل چندجمله‌ای ساده، چندجمله‌ای نرمال‌شده، تابع شعاع محور و تابع کرنل پیرسون اشاره کرد.

### روش تجزیه مد تجربی EMD

در چند دهه اخیر از انواع روش‌های پردازش سیگنال در زمینه‌های مختلف استفاده شده است. تبدیل موجک یکی از روش‌های بررسی سیگنال در حوزه‌ی مشترک زمان-فرکانس است. در این روش، به جای استفاده از توابع سینوسی و کسینوسی (مانند تبدیل فوریه) از توابعی به نام موجک استفاده می‌شود. با این حال، محدودیت‌های خاصی در استفاده از تبدیل موجک وجود دارد. این روش در اصل برای سیگنال‌های خطی مناسب بوده و روش سازگاری برای تجزیه انواع مختلف سیگنال‌ها نیست چرا که تابع موجک ابتدایی باید از قبل انتخاب شود که ممکن است با ماهیت متفاوت سیگنال اصلی مطابقت نداشته باشد (Wang et al., 2014). در سال‌های اخیر از روش نسبتاً سازگار EMD برای تجزیه سیگنال‌های غیرخطی و غیرثابت استفاده شده است.

EMD روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرایندی تحت عنوان غربال کردن صورت می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (۳) سیگنال اصلی  $x(n)$  را به تعدادی مد ذاتی تجزیه می‌کند (Amirat et al., 2018).

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (3)$$

که  $r_n(x)$  همان مولفه باقی مانده، بعد از  $n$  تعداد IMFs 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 دارد و دارای شرایط زیر هستند ۱. در کل داده، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر

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. فرآیندهای گاوسی در مدل‌سازی آماری بسیار پراهمیت‌اند، زیرا خصوصیات نرمالی دارند. می‌توان  $n$  مشاهده را همیشه در مجموعه داده دلخواه  $Y = [y_1, y_2, \dots, y_n]$  به صورت یک نقطه تکی نمونه‌گیری شده از توزیع گاوسی چند متغیری ( $n$  متغیری) تصور کرد. از این‌رو، مجموعه داده‌ها را می‌توان با یک فرآیند گاوسی متناظر کرد. اغلب فرض می‌شود که میانگین فرآیند 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  $\varepsilon$  نیز مقدار نویز توزیع گاوسی با میانگین صفر و واریانس  $\sigma^2$  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 فرآیند گاوسی داشته به نحوی 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 فرآیند گاوسی به منظور 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 فرآیند گاوسی شامل استفاده از مفهوم تابع کرنل است. در واقع، با یک تبدیل غیرخطی از فضای ورودی به فضای خصیصه با ابعاد بیشتر (حتی نامتناهی)

فراخوانی تصاویر ماهواره‌ای، در سامانه Google Earth Engine با کدنویسی مورد پردازش قرار گرفته و مقادیر بارش ماهانه در طول دوره آماری ۲۰۱۷-۱۹۹۸ بر اساس موقعیت ایستگاه مد نظر، استخراج گردید. داده‌های ماهواره TRMM3B43 دارای قدرت تفکیک زمانی ماهانه و قدرت تفکیک مکانی ۰/۲۵ درجه هستند و ۵۰ درجه جنوب تا ۵۰ درجه شمال عرض جغرافیایی را پوشش می‌دهند.

#### 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، ذخائر آب سطحی و برف دارد، منجر به این گشت که شاخص SPI تدوین و ارائه گردد. سیستم طبقه‌بندی SPI بیانگر شدت‌های متفاوتی از خشکسالی در یک منطقه بوده و بر اساس آن می‌توان آستانه خشکسالی را برای هر دوره زمانی تعیین کرد. شاخص بارش استاندارد شده بر اساس احتمال بارش برای هر بازه زمانی است. این شاخص اساساً در مقیاس‌های کوتاه مدت یک و سه ماهه، میان مدت شش و نه ماهه و همچنین در مقیاس‌های بلند مدت ۱۲، ۲۴ و ۴۸ ماهه قابل محاسبه است و به منظور 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 دراز مدت قرار دارند. در این تحقیق از SPI میان‌مدت شش ماهه استفاده شد تا نوسانات مربوط به جریان‌های سطحی و تراز مخزن نیز لحاظ گردد. این شاخص امکان محاسبه مقادیر کمتر و بیشتر از حالت میانگین را به وجود می‌آورد و جهت پایش خشکسالی‌ها

دارای یک واحد اختلاف هستند. ۲. در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد. به علت وجود تناوب و نویز در سیگنال‌ها، در برخی موارد به علت اختلاط مدها؛ توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقض می‌شود (چون میانگین IMF ها حالتی نامشخص به خود می‌گیرد). جهت رفع این ایراد، وو و هوانگ (Wu and Huang, 2004) روش متفاوت با عنوان روش تجزیه مد تجربی یکپارچه (EEMD) را پیشنهاد کردند. در روند تجزیه‌سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. در روش تجزیه مد تجربی یکپارچه کامل (CEEMD) نوفه سفید بصورت 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 داریم که مجموع IMF ها برابر سیگنال اصلی می‌شود و نوفه‌ی اضافی دامنه‌ی موجی از مرتبه‌ی pm خواهد بود.

#### ماهواره TRMM

این ماهواره در ۲۸ نوامبر سال ۱۹۹۷ با همکاری سازمان فضایی دو کشور آمریکا و ژاپن به فضا پرتاب شد. هدف از پرتاب این ماهواره اندازه‌گیری بارش در سطح اقیانوس‌ها و دریاها است، چرا که معمولاً احداث ایستگاه‌های باران‌سنجی در دریاها دشوار است. علاوه بر این، از اطلاعات این ماهواره می‌توان در اندازه‌گیری بارش در سطح خشکی‌ها و مخصوصاً مناطقی که دارای آمار و اطلاعات ثبت شده مناسبی نمی‌باشند، استفاده نمود. این ماهواره در ارتفاع تقریبی ۳۵۰ کیلومتری زمین قرار داشته، با زاویه میل ۳۵ درجه در حال پایش ویژگی‌های جوی است. داده‌های مورد استفاده از ماهواره TRMM در این پژوهش، داده‌های ماهانه (میلادی) بارش با کد 3B43 است که پس از



را شناسایی کند (Michael, 2007). در جدول ۲ طبقه‌بندی شاخص SPI نشان داده شده است.

(بارش کمتر از حالت نرمال) و ترسالی‌ها (بارش بیشتر از حال نرمال) به کار رفته و این امکان را به تحلیل‌گر می‌دهد که شدت، مدت، فراوانی و زمان شروع و خاتمه خشکسالی‌ها

جدول ۲: طبقه‌بندی شدت خشکسالی براساس شاخص SPI

وضعیت خشکسالی	محدوده	وضعیت خشکسالی	محدوده
خیلی خیلی مرطوب	$SPI \geq 2$	خشکسالی متوسط	$-1.5 \leq SPI < -1$
خیلی مرطوب	$1.5 \leq SPI < 2$	خیلی خشک	$-2 < SPI < -1.5$
مرطوب متوسط	$1 \leq SPI < 1.5$	خیلی خیلی خشک	$SPI \leq -2$
نزدیک به نرمال	$-1 \leq SPI < 1$		

$$CC = \frac{\sum_{i=1}^N (I_o - \bar{I}_o) \times (I_p - \bar{I}_p)}{\sqrt{\sum_{i=1}^N (I_o - \bar{I}_o)^2 \times \sum_{i=1}^N (I_p - \bar{I}_p)^2}} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (I_o - I_p)^2}{N}} \quad (6)$$

در روابط بالا  $I_o$ : مقدار اندازه‌گیری شده،  $\bar{I}_o$ : متوسط مقدار اندازه‌گیری شده،  $I_p$ : مقدار پیش‌بینی شده،  $\bar{I}_p$ : متوسط مقدار پیش‌بینی شده و  $N$  تعداد داده‌هاست. از آنجا که وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود لذا نرمالیزه کردن داده‌ها کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. در تحقیق کنونی داده‌ها مطابق رابطه (۷) نرمالیزه شدند که در آن  $X_{max}$ ،  $X_{min}$  به ترتیب حداقل و حداکثر مقدار داده‌های مشاهده شده و  $x_n$  داده نرمال شده می‌باشد.

$$x_n = 0.05 + 0.95 \left( \frac{x - x_{min}}{x_{max} - x_{min}} \right) \quad (7)$$

۱۹۹۸ تا ۲۰۱۷ جهت مدل‌سازی و مقایسه نتایج با داده‌های زمینی استفاده گردید. بررسی منابع متعدد نشان می‌دهد که عناصر اقلیمی مانند دما (T) و رطوبت نسبی (R) می‌توانند در فرآیند پیش‌بینی به عنوان متغیرهای مستقل به کار روند (Morid et al., 2008). لذا، دو نوع مدل‌سازی در نظر گرفته شد: مدل‌سازی بر اساس شاخص SPI ماه‌های گذشته و مدل‌سازی بر اساس عناصر اقلیمی. بنابراین، پس از نرمالیزه کردن داده‌ها، ابتدا سری‌های زمانی توسط تجزیه مد تجزیه یکپارچه کامل به زیرسری‌هایی تجزیه گردید و

## معیارهای ارزیابی

به منظور ارزیابی کارایی روش استفاده شده در مدل‌سازی خشکسالی، از سه پارامتر آماری استفاده گردید که عبارت‌اند از: ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی (R)، ضریب تبیین (DC) که همبستگی خطی بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد و یکی از معیارهای مهم ارزیابی قابلیت یک مدل است و ریشه میانگین مربعات خطاها (RMSE) که بیانگر میزان انحراف بین مقادیر پیش‌بینی شده می‌باشد. هر چه مقدار R و DC برای یک مدل به یک نزدیک‌تر و مقدار RMSE کوچک‌تر باشد به معنی مطلوب بودن آن مدل می‌باشد. روابط این پارامترهای آماری به صورت زیر می‌باشد:

$$DC = 1 - \frac{\sum_{i=1}^N (I_o - I_p)^2}{\sum_{i=1}^N (I_o - \bar{I}_p)^2} \quad (4)$$

## شبیه‌سازی و نتایج و بحث

### تعریف مدل‌های ورودی

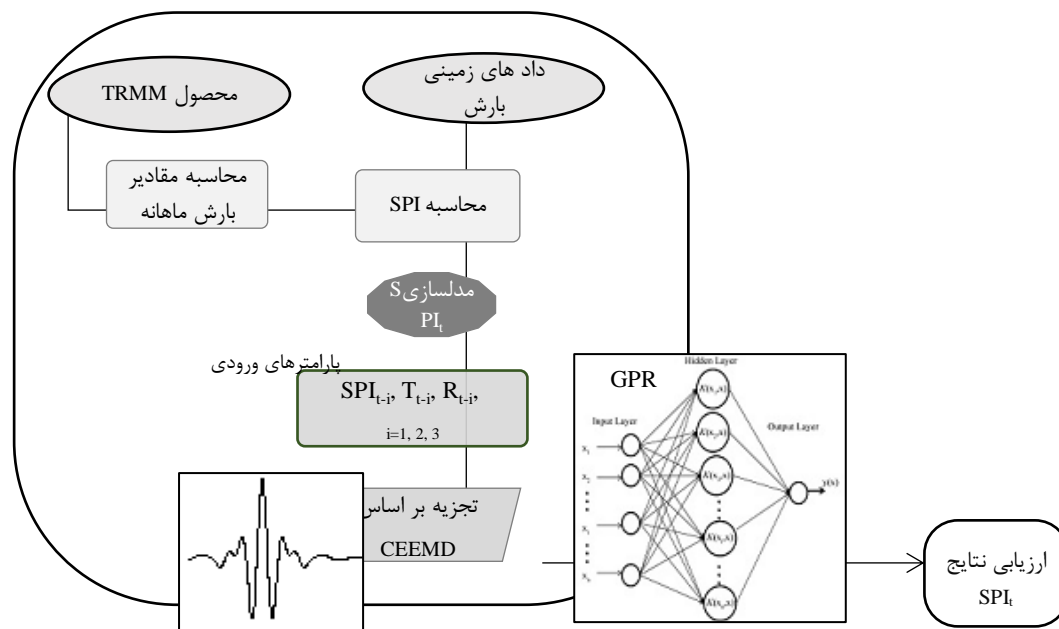
با توجه به اینکه انتخاب مدل‌های ورودی در سیستم‌های هوشمند می‌تواند بر روی دقت جواب‌های حاصل از تحلیل تأثیر گذارد، لذا سعی گردید پارامترهای مناسب و مؤثر در مدل‌سازی ۶ ماهه خشکسالی انتخاب گردد. در تحقیق کنونی با توجه به اینکه داده‌های ماهواره TRMM از سال ۱۹۹۸ در دسترس است از داده‌های بارش در بازه زمانی

تحقیق نشان داده شده است. همچنین جدول ۳ بیانگر مدل‌های تعریف شده می‌باشد.

سپس این زیرسری‌ها به عنوان ورودی مدل GPR استفاده شد. در شکل ۲ شماتیک مدل‌سازی صورت گرفته در

جدول (۳): مدل‌های تعریف شده در تحقیق.

مدل‌سازی بر اساس عناصر اقلیمی		مدل‌سازی بر اساس شاخص استاندارد شده بارش	
مدل	پارامترهای ورودی	مدل	پارامترهای ورودی
M(I)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, T_{t-1}$	S(I)	$SPI_{t-1}$
M(II)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, R_{t-1}$	S(II)	$SPI_{t-1}, SPI_{t-2}$
M(III)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, T_{t-1}, R_{t-1}$	S(III)	$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$



شکل (۲): شماتیک مدل‌سازی صورت گرفته در تحقیق.

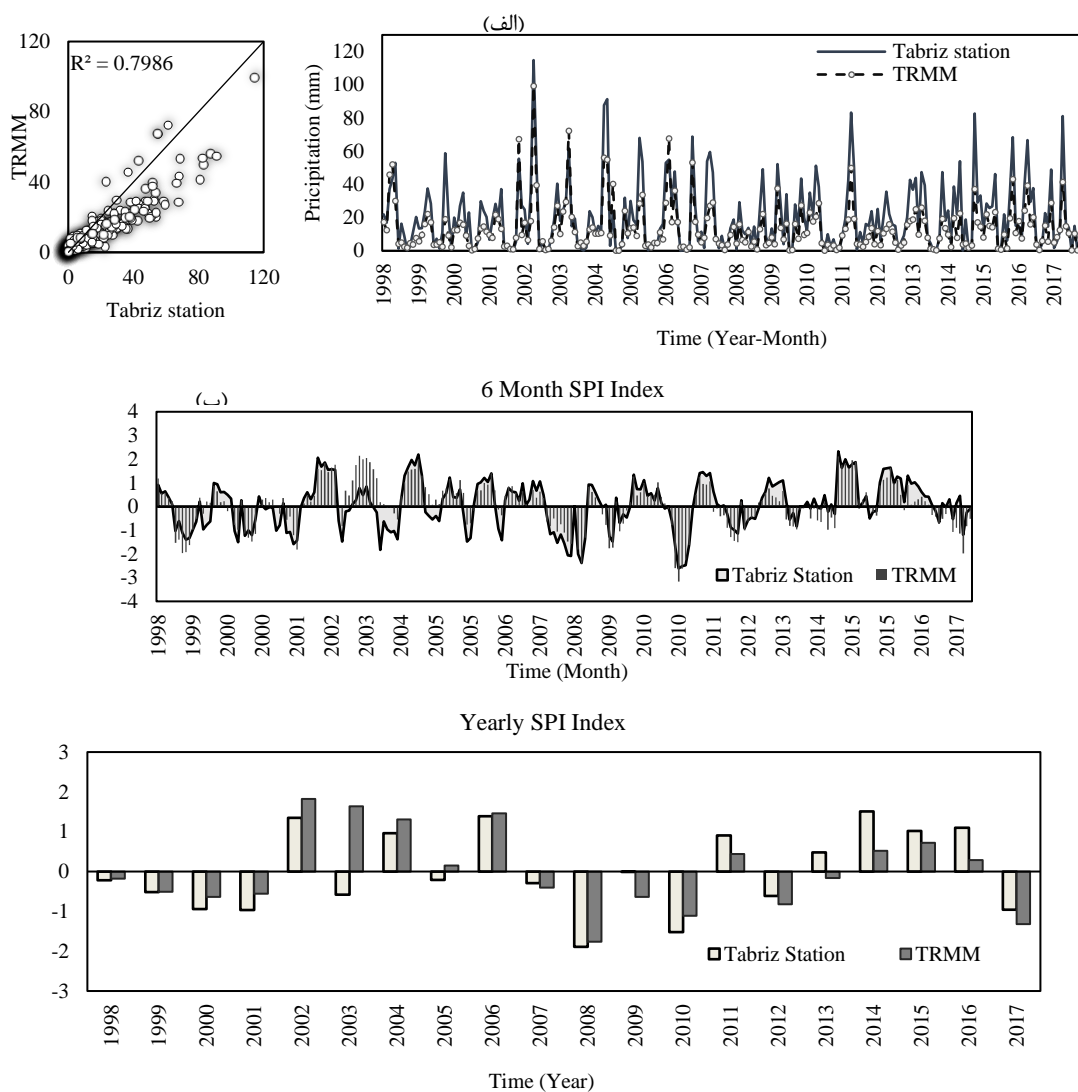
## نتایج و بحث

به نمودار، نتایج نشان می‌دهد که همبستگی بین مقدار بارش حاصل از ایستگاه هواشناسی و تصویر ماهواره‌ای TRMM در مقیاس ماهانه بسیار خوب است. همچنین در شکل ۳ نمودار نمایه SPI شش ماهه و سالانه شهر تبریز برای دوره مطالعاتی نشان داده شده است. مطابق با این شکل مشاهده می‌گردد که نتایج خشکسالی حاصل از ماهواره تقریباً منطبق بر داده‌های زمینی است. مشاهده می‌گردد که سال ۲۰۰۸ و ۲۰۱۰ خشکسالی شدید را تجربه

به‌منظور مدل‌سازی خشکسالی، ابتدا داده‌های سری زمانی بارش با استفاده از نرم‌افزار DIP به شاخص بارش استاندارد شده در دوره شش ماهه تبدیل شد. داده‌های سری زمانی SPI از سال ۱۹۹۸-۲۰۱۱ به عنوان داده‌های آموزش و بقیه داده‌ها (۲۰۱۲-۲۰۱۷) به عنوان داده‌های آزمون مورد استفاده قرار گرفتند. شکل ۳ (الف)، همبستگی بارش محاسبه شده از داده‌های بارش ماهانه TRMM و ایستگاه زمینی تبریز را نشان می‌دهد. با توجه



کرده است. در ادامه جهت مدل سازی خشکسالی از روش هوشمند تلفیقی مبتنی بر رگرسیون فرایند گاوسی- تجزیه- ی یکپارچه مد تجربی کامل استفاده شده و نتایج به صورت جداول و نمودار ارائه می گردد.



شکل (۳): (الف) نمودار همبستگی بارش ماهانه ایستگاه تبریز و ماهواره TRMM و (ب) میزان نمایه SPI شش ماهه و سالانه شهر تبریز.

شکل ۴ (الف) تجزیه سیگنال SPIt-1 داده‌های ایستگاه تیریز را نشان می‌دهد.

جهت انتخاب تابع کرنل مناسب رگرسیون فرآیند گاوسی، مدل S(III) پس از تجزیه داده‌های ایستگاه تیریز توسط روش CEEMD با کرنل‌های مختلف مورد ارزیابی قرار گرفت. از سه معیار ارزیابی RMSE، DC و R جهت تعیین کارایی هر یک از کرنل‌ها استفاده گردید. نتایج به صورت شکل ۴ (ب) برای سری داده‌های تست ارائه گردیده است. مطابق با شکل ۴ مشاهده می‌گردد که در بین تمامی توابع کرنل‌ها، تابع کرنل شعاع مداری در پیش‌بینی خشکسالی نسبت به توابع کرنل دیگر دارای ضریب همبستگی و تبیین بیشتر و خطای کمتری بوده و نتایج دقیق‌تری را ارائه کرده است. بنابراین، در تجزیه و تحلیل تمامی مدل‌ها از کرنل شعاع مداری استفاده گردید.


### تجزیه داده‌ها با روش CEEMD و انتخاب تابع کرنل مناسب مدل GPR

اساس روش CEEMD تجزیه سیگنال به IMF‌های مختلف و یک سیگنال باقیمانده است که در نهایت مجموعه این‌ها، همان سیگنال اصلی خواهد بود. روش تشکیل IMF‌ها براساس تفریق تابع پایه از سیگنال اصلی می‌باشد. این پروسه تا وقتی ادامه می‌یابد که تقریباً سیگنال باقیمانده ثابت شود. طی این فرایند سیگنال اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. الگوریتم موردنیاز برای به دست آوردن توابع مد ذاتی شامل ۵ مرحله است:

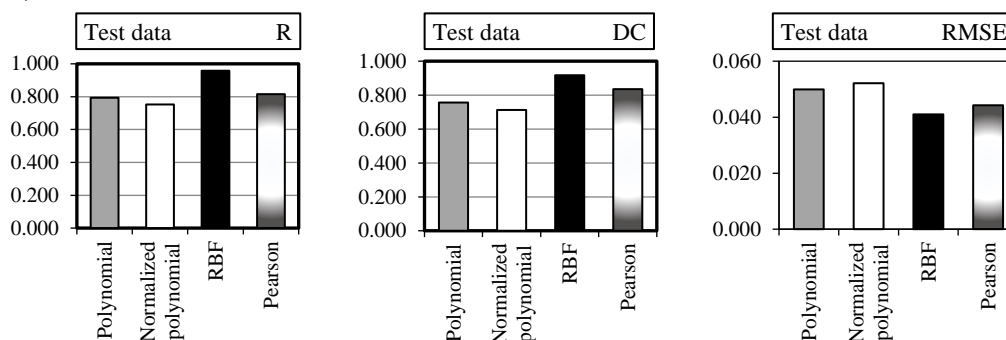
- ۱) تعیین نقاط بیشینه و کمینه محلی سیگنال  $x(n)$ ، (۲) به دست آوردن پوش بالایی و پایینی سیگنال با استفاده از برازش نقاط بیشینه و کمینه محلی به روش اسپلاین درجه سه (cubic spline) پس از آن محاسبه میانگین پوش بالا و پایین با نام  $m1(n)$ ، (۳) محاسبه اختلاف میان داده و میانگین پوش بالا و پایین. چنانچه  $h1(n)$  شرایط مربوط به یک تابع مد ذاتی را داشته باشد، درحکم اولین تابع مد ذاتی در نظر گرفته و محاسبات به مرحله بعدی الگوریتم منتقل می‌شود. درغیر اینصورت مراحل اول تا چهارم دوباره تکرار می‌شود؛ با این تفاوت که الگوریتم به جای سیگنال اولیه  $x(n)$  روی  $h1(n)$  اعمال می‌شود، (۴) محاسبه باقیمانده، (۵) چنانچه باقیمانده دارای حداقل دو فرین باشد، مراحل اول تا پنجم تکرار می‌شود و درغیر اینصورت الگوریتم متوقف می‌شود و آخرین باقیمانده درحکم باقیمانده سیگنال در نظر گرفته می‌شود. در این تحقیق IMF‌ها و باقیمانده با کدنویسی در نرم‌افزار متلب تعیین گردیدند.



(الف)



(ب)



شکل ۴: الف) تجزیه سیگنال  $SPI_{t-1}$  داده‌های ایستگاه تبریز و ب) پارامترهای آماری مدل GPR با توابع کرنل متفاوت.

ارزیابی مدل برای داده‌های آموزش و آزمون مشاهده می‌شود که برای هر دو حالت استفاده از داده‌های زمینی و ماهواره‌ای، برای مدل‌سازی اول بر اساس SPI مربوط به دوره‌های قبل مدل  $S(III)$  با پارامترهای ورودی  $SPI_{t-1}$ ,  $SPI_{t-2}$ ,  $SPI_{t-3}$  بیشترین کارایی را دارا می‌باشد. مطابق با نتایج ملاحظه می‌گردد که تنها استفاده از مقادیر  $SPI_{t-1}$  نمی‌تواند منجر به نتایج دقیقی گردد. برای مدل‌سازی دوم نیز مدل  $M(III)$  با پارامترهای ورودی  $SPI_{t-1}$ ,  $SPI_{t-2}$ ,  $SPI_{t-3}$ ,  $T_{t-1}$ ,  $R_{t-1}$  بیشترین ضریب همبستگی و تبیین و کمترین مقدار خطا را ارائه داده است. با مقایسه نتایج دو نوع مدل‌سازی مشاهده می‌شود که با دخالت دادن عناصر

### نتایج به‌دست آمده برای مدل GPR بدون تجزیه داده‌ها

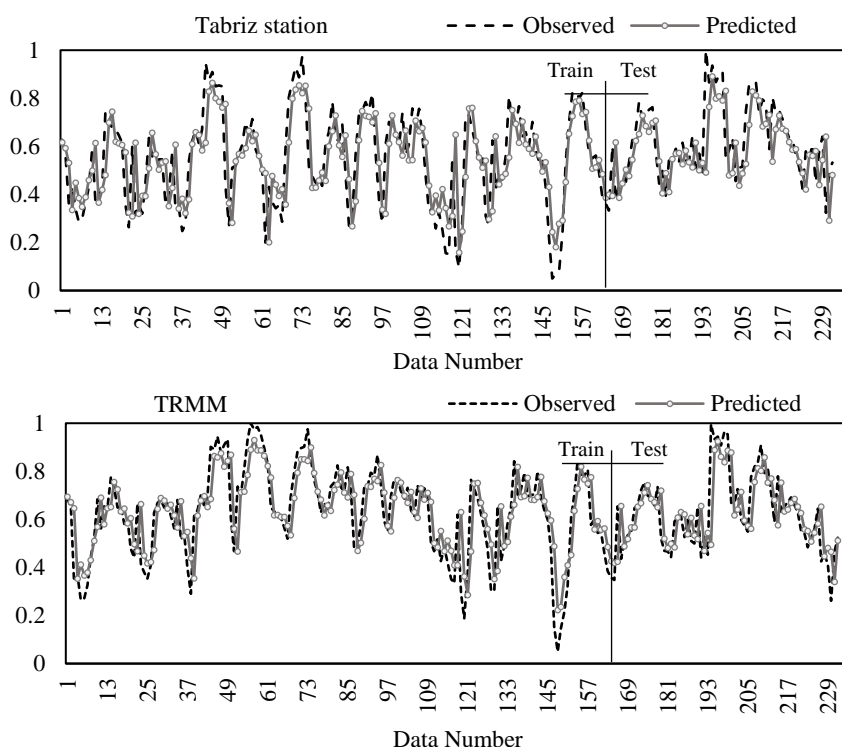
جهت پیش‌بینی خشکسالی بر اساس شاخص استاندارد شده بارش با استفاده از داده‌های زمینی و ماهواره‌ای بدون تجزیه سری‌های زمانی، سه مدل بر اساس شاخص SPI مربوط به دوره‌های قبل و سه مدل نیز با اضافه کردن عناصر اقلیمی شامل میانگین دما و رطوبت نسبی ماهانه تعریف گردید و کارایی روش رگرسیون فرایند گاوسی مورد ارزیابی قرار گرفت. مدل‌های تعریف شده با روش GPR آنالیز گردیده و نتایج حاصله به صورت جدول ۴ و شکل ۵ ارائه شد. با توجه به نتایج به‌دست‌آمده از سه معیار

بین ۵ تا ۱۰٪ دقیق تر از حالتی است که مدل سازی بر اساس داده های ماهواره ای انجام شده است. در حالت کلی، روش رگرسیون فرایند گاوسی به تنهایی نتایج مطلوبی در پیش بینی خشکسالی نشان نداده است. نمودار مدل برتر برای سری داده های آموزش و آزمون برای هر دو مدل سازی در شکل ۵ نشان داده شده است.

اقلیمی در مدل سازی، دقت مدل ها افزایش یافته است. بر اساس نتایج به دست آمده مشاهده می شود که با حذف پارامترهای اقلیمی مقدار درصد خطا تقریباً بین ۱۵ تا ۲۰ درصد افزایش یافته است. مشاهده می گردد که نتایج بدست آمده بر اساس داده های زمینی اندکی دقیق تر می باشد اما داده های ماهواره ای نیز تقریباً نتایج مشابهی را ارائه داده اند. در حالت مدل سازی بر اساس داده های زمینی تقریباً نتایج

جدول (۴): نتایج ارزیابی مدل های GPR بدون تجزیه داده ها

مدل	آزمون			تست		
	R	DC	RMSE	R	DC	RMSE
مدلسازی با داده های زمینی						
S(I)	0.551	0.329	0.219	0.504	0.233	0.231
S(II)	0.621	0.411	0.110	0.571	0.310	0.140
<b>S(III)</b>	<b>0.734</b>	<b>0.495</b>	<b>0.101</b>	<b>0.726</b>	<b>0.391</b>	<b>0.129</b>
M(I)	0.836	0.563	0.091	0.789	0.418	0.114
M(II)	0.840	0.569	0.087	0.811	0.445	0.109
<b>M(III)</b>	<b>0.847</b>	<b>0.587</b>	<b>0.081</b>	<b>0.822</b>	<b>0.500</b>	<b>0.101</b>
مدلسازی با داده های ماهواره ای						
S(I)	0.526	0.314	0.231	0.541	0.223	0.244
S(II)	0.593	0.402	0.114	0.556	0.301	0.145
<b>S(III)</b>	<b>0.701</b>	<b>0.483</b>	<b>0.104</b>	<b>0.693</b>	<b>0.389</b>	<b>0.131</b>
M(I)	0.799	0.558	0.096	0.753	0.399	0.121
M(II)	0.803	0.561	0.091	0.794	0.444	0.111
<b>M(III)</b>	<b>0.808</b>	<b>0.583</b>	<b>0.084</b>	<b>0.803</b>	<b>0.498</b>	<b>0.103</b>



شکل (۵): نتایج مدل برتر M(III) بدون تجزیه داده‌ها.

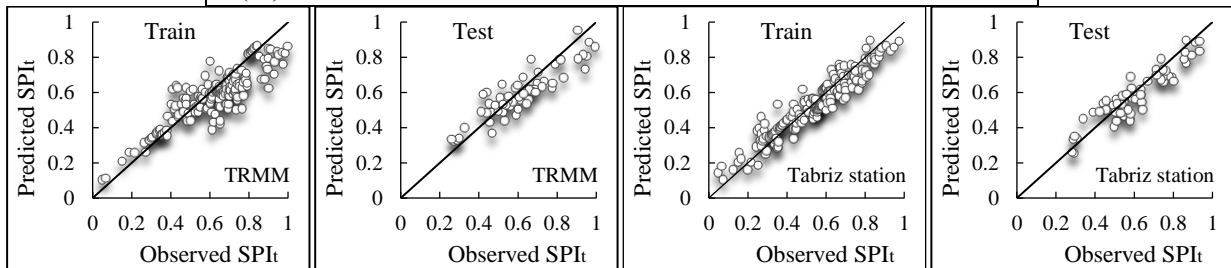
در اثر تجزیه سری‌های زمانی تقریباً ۳۰ تا ۴۰٪ می‌باشد. مطابق با جدول ۵، برای مدل‌های تعریف شده بر اساس داده‌های SPI، مدل S(III) با داشتن بیشترین مقدار R و DC و کمترین مقدار خطای RMSE مدل برتر می‌باشد. برای حالتی که از عناصر اقلیمی استفاده شده است نیز ملاحظه می‌شود که مدل M(III) دقیق‌ترین نتایج را ارائه داده است. با مقایسه مدل‌های تعریف شده مشاهده می‌گردد که استفاده از پارامترهای میانگین دما و رطوبت نسبی ماهانه باعث افزایش دقت مدل‌ها شده‌اند. نمودار مدل‌های برتر برای سری داده‌های آموزش و آزمون در حالت مدل-ساز بر اساس عناصر اقلیمی در شکل ۶ نشان داده شده است.

### نتایج به دست آمده برای مدل GPR بر پایه تجزیه یکپارچه مد تجزیه کامل

در این قسمت از روش تجزیه مد تجزیه یکپارچه کامل، برای تجزیه سیگنال شاخص استاندارد شده بارش و عناصر اقلیمی استفاده شد. سپس به منظور افزایش دقت مدل GPR، داده‌های پیش‌پردازش شده به‌عنوان ورودی‌های روش رگرسیون فرایند گاوسی در نظر گرفته شد. نتایج حاصل از مدل‌سازی‌های در نظر گرفته شده در جدول ۵ و شکل ۶ ارائه شده است. با مقایسه نتایج جدول ۴ و ۵ ملاحظه می‌شود که تجزیه سری‌های زمانی تا حدود زیادی باعث بهبود نتایج گردیده و میزان افزایش دقت مدل

جدول (۵): نتایج ارزیابی مدل‌ها براساس تجزیه سری‌های زمانی.

مدل	مدلسازی با داده‌های زمینی			تست		
	R	DC	RMSE	R	DC	RMSE
CEEMD- GPR						
S(I)	0.754	0.672	0.079	0.726	0.616	0.088
S(II)	0.824	0.784	0.056	0.776	0.765	0.068
<b>S(III)</b>	<b>0.850</b>	<b>0.844</b>	<b>0.040</b>	<b>0.832</b>	<b>0.815</b>	<b>0.046</b>
M(I)	0.948	0.862	0.033	0.890	0.825	0.041
M(II)	0.950	0.878	0.030	0.892	0.866	0.038
<b>M(III)</b>	<b>0.949</b>	<b>0.885</b>	<b>0.028</b>	<b>0.900</b>	<b>0.871</b>	<b>0.034</b>
	مدلسازی با داده‌های ماهواره‌ای					
CEEMD- GPR						
S(I)	0.735	0.648	0.081	0.708	0.594	0.085
S(II)	0.814	0.756	0.057	0.757	0.759	0.070
<b>S(III)</b>	<b>0.849</b>	<b>0.825</b>	<b>0.042</b>	<b>0.811</b>	<b>0.799</b>	<b>0.048</b>
M(I)	0.924	0.842	0.035	0.868	0.814	0.043
M(II)	0.926	0.865	0.032	0.872	0.863	0.039
<b>M(III)</b>	<b>0.925</b>	<b>0.872</b>	<b>0.030</b>	<b>0.878</b>	<b>0.869</b>	<b>0.036</b>







شکل ۶: نتایج مرحله آزمون و تست مدل برتر M(III) با استفاده از داده‌های تجزیه شده.

در کاهش دقت مدل مورد بررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت به صورت شکل ۷ ارائه گردیده است. همانطور که از شکل مشخص است با حذف پارامتر  $SPI_{t-1}$  دقت مدل تا حدود زیادی کاهش یافته است. بنابراین، می‌توان نتیجه گرفت که  $SPI_{t-1}$  بیشترین تاثیر را در مدل‌سازی خشکسالی داراست.

### آنالیز حساسیت

جهت بررسی تاثیر پارامترهای به کاررفته در مدل برتر M(III) آنالیز حساسیت انجام گرفت. برای این منظور با حذف تک تک پارامترهای مدل برتر و اجرای دوباره مدل و تعیین معیار ارزیابی RMSE، میزان تاثیر پارامتر حذف شده



شکل (۷): تاثیر نسبی هر یک از پارامترهای ورودی مدل بر تر.

حاصل از ماهواره TRMM تقریباً منطبق بر داده‌های زمینی است. مطابق با نتایج، در بین توابع کرنل روش GPR، تابع کرنل شعاع مداری در پیش‌بینی خشکسالی نسبت به توابع کرنل دیگر موفق‌تر می‌باشد. ملاحظه شد که روش رگرسیون فرایند گاوسی به تنهایی نمی‌تواند منجر به نتایج مطلوبی در پیش‌بینی خشکسالی شود، اما با تجزیه سری‌های زمانی با روش CEEMD تا حدود زیادی کارایی مدل و دقت پیش‌بینی‌ها افزایش می‌یابد. برای مدل‌های تعریف شده بر اساس SPI ماه‌های پیشین، مدل S(III) با پارامترهای ورودی، SPIt-1، SPIt-2، SPIt-3 با داشتن بیشتر R و DC و کمترین مقادیر خطای RMSE مدل برتر شد. در حالت مدل‌سازی بر اساس عناصر اقلیمی نیز مدل با پارامترهای ورودی، SPIt-1، SPIt-2، SPIt-3، Tt-1، Rt-1 نتایج دقیق‌تری را نشان داد در حالت کلی، مشاهده شد که اضافه کردن پارامترهای اقلیمی شامل میانگین دما و رطوبت نسبی ماهانه به ترکیب متغیرهای ورودی، دقت مدل‌ها را افزایش می‌دهد که با نتایج گانگولی و ردی (Ganguli

## نتیجه‌گیری

خشکسالی به عنوان یکی از بلایای طبیعی می‌تواند اثرات مخرب و زیان‌باری در زمینه‌های مختلف اقتصادی، اجتماعی و زیست محیطی به جای گذارد. بنابراین، در این تحقیق با استفاده از داده‌های زمینی ایستگاه سنوپتیک تبریز و داده‌های سنجش از دور ماهواره TRMM، کارایی روش GRP بر پایه تجزیه یکپارچه مد تجزیه کامل (CEEMD) در مدل‌سازی خشکسالی بر اساس شاخص SPI شش ماهه مورد بررسی قرار گرفت. مدل‌هایی با ورودی متفاوتی بر اساس داده‌های مربوط به شاخص بارش استاندارد شده ماه‌های قبل و عناصر اقلیمی مانند میانگین دما و رطوبت نسبی ماهانه در بازه زمانی (۲۰۱۷-۱۹۹۸) تعریف گردید و مورد ارزیابی قرار گرفت. نتایج حاصله نشان داد که همبستگی مناسبی بین مقدار بارش حاصل از ایستگاه تبریز و تصویر ماهواره‌ای TRMM در مقیاس ماهانه وجود دارد و نتایج خشکسالی

تحقیق مرید و همکاران (Morid et al., 2008) که نشان دادند در تعیین شاخص‌های خشکسالی با استفاده از شبکه عصبی مصنوعی، بهترین مدل‌ها در تمام مقیاس‌های زمانی آن‌هایی هستند که شامل مقادیر شاخص خشکسالی دوره گذشته باشند، مطابقت دارد.

(Reddy, 2014) and که نشان دادند پارامترهای اقلیمی دارای دقت مطلوبی در تخمین شاخص SPI هستند و در کنار سایر پارامترها مانند الگوهای پیوند از دور باعث بهبود دقت نتایج می‌شوند، همخوانی دارد. نتایج حاصل از آنالیز حساسیت نیز نشان داد که پارامتر SPIt-1 بیشترین تاثیر را در مدل‌سازی خشکسالی داراست که با نتایج حاصل از

### منابع

- ارش ادیب، ا. و ع. گرجی زاده. ۱۳۹۵. بررسی و پایش خشکسالی با استفاده از شاخص‌های خشکسالی: مطالعه موردی حوضه آبریز دز. نشریه مهندسی آبیاری و آب ایران، دوره ۷، شماره ۲، ص ۱۷۳-۱۸۵.
- باباعلی، م. و ر. دهقانی. ۱۳۹۶. کاربرد مدل شبکه عصبی موجک در تخمین شاخص بارش استاندارد. نشریه مهندسی آبیاری و آب ایران، دوره ۷، شماره ۲۷، ص ۸۱-۹۶.
- روشنگر، ک. و ر. قاسم‌پور. ۱۳۹۷. بررسی عملکرد روش‌های کلاسیک و هوش مصنوعی در تخمین ضریب زبری در پیچانرودها. نشریه آبیاری و زهکشی ایران، جلد ۱۲، شماره ۴، ص ۸۱۱-۸۲۲.
- کاظم‌پور چورسی، س.، عرفانیان، م. و زعبادی نهاری. ۱۳۹۸. ارزیابی داده‌های ماهواره‌ای MODIS و TRMM در پایش خشکسالی حوضه آبریز دریاچه ارومیه. نشریه جغرافیا و برنامه‌ریزی محیطی، دوره ۳۰، شماره ۲، ص ۱۷-۳۴.
- مقیم، م.، کوهی، ا. و ع. زارعی. ۱۳۹۷. پایش و پیش‌بینی وضعیت خشکسالی در استان فارس با استفاده از شاخص RDI و مدل ریاضی زنجیره مارکوف، نشریه مهندسی آبیاری و آب ایران، دوره ۸، شماره ۳، ص ۱۵۳-۱۶۵.

Amirat, Y., Benbouzidb, MEH., Wang, T., Bacha, K. Feld, G. 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133: 202-209.

ASCE, Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. *Artificial Neural Networks in hydrology. I: Preliminary concepts. J. Hydrologic Eng, ASCE. 5(2): 115-123.*

Fisher, T., Gemmer, M., Su, B. and Scholten, T. 2013. Hydrological long-term dry and wet periods in the Xijiang River basin, South China. *Hydrology and Earth system Sciences*, 17: 135-148.

Ganguli, P., Reddy, M. J. 2014. Ensemble prediction of regional droughts using climate inputs and the SVM-copula approach. *Hydrological processes*, 28(19): 4989-5009.

Li, J.G., H.X. Ruan, J.R. Li and S.F. Huang. 2010. Application of TRMM precipitation data in meteorological drought monitoring. *Journal of China Hydrology*, 30: 43-46 (in Chinese).

Michael, J.H. 2007. What is drought: drought in dices, climate impacts specialist, national drought mitigation center. <http://Ulysses Atmosp. Colostate. Edu/spi.html>.

Modarres, R., Sarhadi, A. and Burn, D.H. 2016. Changes of extreme drought and flood events in Iran. *Global and Planetary Change*, 144: 67-81.

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: 2103-2111.

Saada, N., Abu-Romman, A. 2017. Multi-site modeling and simulation of the standardized precipitation index (SPI) in Jordan. *Journal of Hydrology: Regional Studies*, 14: 83-91.





Samuelsson, O., Bjork, 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): 2952-2963.

Sirdas, S., Şen, Z. 2003. Spatio-temporal drought analysis in the Trakya region, Turkey. *Journal of Hydrological Sciences*, 48(5):809-820.

Siviapragasam, C. and Liong, S. 2001. Rainfall and runoff forecasting with SSA-SVM approach. *Journal of Hydroinformatics*. 3: 141-152.

Wang, C.J., Li, H.Y., Xiang, W. and Zhao, D. 2014. A new signal classification method based on EEMD and FCM and its application in bearing fault diagnosis. *Applied Mechanics and Materials*, 602: 1803-1806.

Wu, Z., Huang, NE. 2004. A study of the characteristics of white noise using the empirical mode decomposition method. *Proc RS Lond* 460A: 1597–1611.

Xiang-Hu, L., Q. Zhang and Xu. Chong-Yu. 2012. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang Catchment, Poyang lake Basin. *Journal of Hydrology*, 426: 28–38.

Yan, N., Wu, B., Chang, S. and Bao, X. 2014. Evaluation of TRMM Precipitation Product for Meteorological Drought Monitoring in Hai Basin. In *IOP Conference Series: Earth and Environmental Science* (Vol. 17, No. 1, p. 012093). IOP Publishing.

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): 200-214.



## Drought Modeling Based on SPI Index using Satellite and Ground station Data via the Integrated GPR-CEEMD Model

Kiyoumars Roushangar<sup>1\*</sup>, Roghayeh Ghasempour<sup>2</sup>

### Abstract

Drought is one of the most important problems which affects agriculture section and water resources. Nowadays, the use of the remote sensing technique has been considered as useful tool for drought monitoring. This study aimed to predict the temporal drought using ground station and TRMM3B43 satellite data between the years of 1998-2017. Therefore, precipitation data were first converted to the SPI index, and then, using the intelligent Gaussian Process Regression (GPR) method based on Complementary Ensemble Empirical Mode Decomposition (CEEMD), Tabriz drought was investigated. Different models were defined and the impact of different input parameters were assessed. It was observed that the rainfall amounts from the TRMM satellite in the monthly scale had a good correlation with the Tabriz station precipitation and the results of drought analysis using satellite data were almost similar with ground station data. The obtained results proved the high capability and efficiency of the applied method in predicting the SPI drought index and it was observed that time series decomposition based on the complementary ensemble empirical mode decomposition led to more accurate outcomes. The input data decomposition increased the predictive accuracy by approximately 30 to 40 percent. It was observed that in prediction of drought the climatic elements including mean monthly temperature and relative humidity, as well as SPI indexes related to the previous months, were effective and by climatic parameters eliminating, the modeling error increased up to 15-20%. Also, the results of sensitivity analysis showed that SPIt-1 is the most effective parameter in modeling.

**Keywords:** Drought, Empirical mode, GPR, Remote sensing, SPI

<sup>1</sup>Professor, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran, [kroshangar@yahoo.com](mailto:kroshangar@yahoo.com) (corresponding author)

<sup>2</sup>PhD Candidate, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran, [ghasempourroghy@gmail.com](mailto:ghasempourroghy@gmail.com)



## Drought Modeling Based on SPI Index using Satellite and Ground station Data via the Integrated GPR-CEEMD Model

Kiyoumars Roushangar<sup>1\*</sup>, Roghayeh Ghasempour<sup>2</sup>

### Introduction

Drought as a severe natural disaster has devastating effects on the environment; therefore, reliable drought prediction is an important issue. Drought has serious negative effects on different parts of human life. Some of these effects are water supply shortage, low agricultural produce, reduced soil moisture, economic losses, migration, and famine. These widespread negative effects can be seen anywhere in the world. Accurate understanding of spatial and temporal variation in rainfall and drought will provide a good insight into the arranging and management of drought subordinate exercises. So far, numerous drought prediction methods have been proposed in 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. On the other hand, the traditional drought indices are usually obtained from hydro-meteorological data from stations, the spatial resolution of which does not necessarily meet the drought monitoring requirements in large-scale areas. According to Yan et al. (2014), spatially and temporally continuous information can be provided by data obtained from meteorological satellites. Therefore, the use of satellite data can compensate the limitation of point-based observation data for hydro-meteorological variables, and makes it possible to monitor drought conditions in ungauged regions. Meteorological satellites can acquire multi-temporal, multispectral, continuous and complete data. Also, 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 shown to be effective in improving prediction accuracy of time series prediction methods, as indicated in. 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 its importance, in this study, the temporal drought was investigated using ground station and TRMM3B43 satellite data between the years of 1998-2017. The SPI index was used in this regard. Using the intelligent Gaussian Process Regression (GPR) method based on Complementary Ensemble Empirical Mode Decomposition (CEEMD), Tabriz drought was investigated.

### Methodology

In this study, monthly rainfall data from the three stations namely Tabriz was used during the period of 1998-2017. The time series of the drought SPI index was calculated via DIP software. 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,

<sup>1</sup>Professor, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran, [kroshangar@yahoo.com](mailto:kroshangar@yahoo.com) (corresponding author)

<sup>2</sup>PhD Candidate, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran, [ghasempourroghy@gmail.com](mailto:ghasempourroghy@gmail.com)

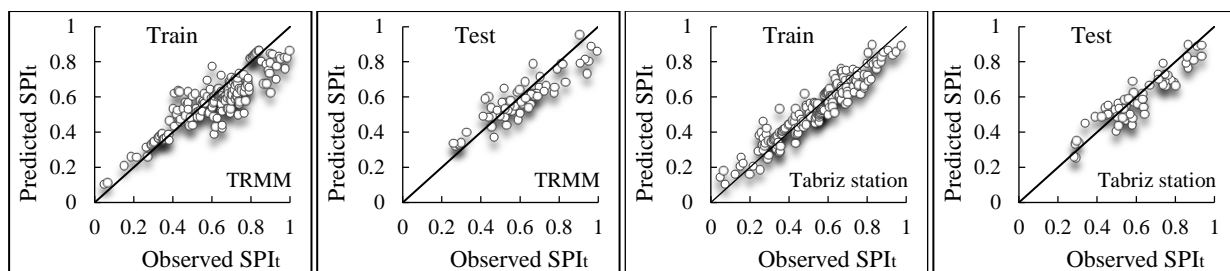
respectively. The Gaussian distribution is over vectors, whereas the Gaussian process is over functions. Thus, due to prior knowledge about the data and functional dependencies, no validation process is required for generalization, and GP regression models are able to understand the predictive distribution corresponding to the test input (Ramussen and William, 2006). 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 and 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

For evaluating and reviewing the performance of the tested models and determine the accuracy of the selected models, three error criteria named Correlation Coefficient (CC), Determination Coefficient (DC), and Root Mean Square Errors (RSME) were used according to Table 1. The results indicated that the accuracy of the integrated CEEMD-GPR models was higher than the GPR model. The integrated model decreased the error criteria between 30 to 40 %. It was observed that in prediction of drought the climatic elements including mean monthly temperature and relative humidity, as well as SPI indexes related to the previous months, were effective in modeling process.

**Table 1:** Statistical parameters results for test series based on the integrated method

Model	Ground-based data					
	Train			Test		
	R	DC	RMSE	R	DC	RMSE
CEEMD- GPR						
S(I)	0.754	0.672	0.079	0.726	0.616	0.088
S(II)	0.824	0.784	0.056	0.776	0.765	0.068
<b>S(III)</b>	<b>0.850</b>	<b>0.844</b>	<b>0.040</b>	<b>0.832</b>	<b>0.815</b>	<b>0.046</b>
M(I)	0.948	0.862	0.033	0.890	0.825	0.041
M(II)	0.950	0.878	0.030	0.892	0.866	0.038
<b>M(III)</b>	<b>0.949</b>	<b>0.885</b>	<b>0.028</b>	<b>0.900</b>	<b>0.871</b>	<b>0.034</b>
	Satellite-based data					
CEEMD- GPR						
S(I)	0.735	0.648	0.081	0.708	0.594	0.085
S(II)	0.814	0.756	0.057	0.757	0.759	0.070
<b>S(III)</b>	<b>0.849</b>	<b>0.825</b>	<b>0.042</b>	<b>0.811</b>	<b>0.799</b>	<b>0.048</b>
M(I)	0.924	0.842	0.035	0.868	0.814	0.043
M(II)	0.926	0.865	0.032	0.872	0.863	0.039
<b>M(III)</b>	<b>0.925</b>	<b>0.872</b>	<b>0.030</b>	<b>0.878</b>	<b>0.869</b>	<b>0.036</b>



**Fig. 1:** The observed vs. predicted SPI scatter plots for the superior model



### Conclusions

The developed models' accuracy showed that the applied integrated model had higher efficiency compared with single GPR model in drought modeling. CEEMD-GPR method approximately decreased the error criteria between 30 to 40 %. In addition, sensitivity analysis showed that  $SPI_{t-1}$  was the most effective parameter in drought modeling.

### The most important references

Yan, N., Wu, B., Chang, S. and Bao, X. 2014. Evaluation of TRMM Precipitation Product for Meteorological Drought Monitoring in Hai Basin. In IOP Conference Series: Earth and Environmental Science (Vol. 17, No. 1, p. 012093). IOP Publishing.

Rasmussen, C.E. and Williams, C.K.I., 2006. Gaussian Processes for Machine Learning. The MIT Press, Cambridge, MA.

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.