



اثر بهینه‌سازی کرنل در مدل‌سازی پدیده خشک‌سالی با بهره‌گیری از هوش محاسباتی (مطالعه موردی: شهر سندج)

جهانبخش محمدی^۱، علیرضا وفایی نژاد^۲، سعید بهزادی^۳، حسین آقامحمدی^۴، امیر هومن حمصی^۵

دریافت: ۱۴۰۰/۰۸/۱۳ / پذیرش: ۱۴۰۰/۱۱/۰۵ / دسترسی اینترنتی: ۱۴۰۲/۰۱/۰۱

چکیده

خشک‌سالی یکی از مهم‌ترین بلایای طبیعی است که اثرات مخرب و زیان‌باری در زمینه‌های مختلف اقتصادی، اجتماعی و زیست‌محیطی به‌جای می‌گذارد. با توجه به رفتار تکرارشوندگی این پدیده، در صورت عدم اجرای راهکارهای مناسب، آثار مخرب آن تا سال‌ها پس از وقوع می‌تواند در منطقه باقی بماند. اکثر بحران‌های طبیعی از قبیل سیل، زلزله، طوفان و رانش زمین در دوره‌ای کوتاه ممکن است جهانبخش محمدی^۱، علیرضا وفایی نژاد^۲ (✉)، سعید بهزادی^۳، حسین آقامحمدی^۴، امیر هومن حمصی^۵

۱. دانشجوی دکتری تخصصی سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده منابع طبیعی و محیط زیست، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران
۲. دانشیار دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران
۳. استادیار دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران
۴. استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران
۵. استاد، مهندسی منابع طبیعی، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات تهران، دانشگاه آزاد اسلامی، تهران، ایران

DOI: 10.30495/girs.2023.688408

پست الکترونیکی مسئول مکاتبات: a_vafaei@sbu.ac.ir

خسارات سنگین مالی و جانی به جامعه وارد کنند، اما خشک‌سالی ماهیت آرام و خزشی دارد و آثار مخرب آن به‌تدریج و در مدت طولانی‌تری ظاهر می‌شود. از این رو با مدل‌سازی خشک‌سالی می‌توان طرح‌هایی جهت آماده‌سازی در مقابل خشک‌سالی و کاهش خسارات ناشی از آن ارائه کرد. در این پژوهش از الگوریتم‌های هوش محاسباتی شبکه عصبی پرسپترون چندلایه (Multi-Layer Perceptron)، شبکه عصبی رگرسیونی تعمیم‌یافته (Generalized Regression Neural Network)، رگرسیون بردار پشتیبان با کرنل گوسین (Support Vector Regression) و رگرسیون بردار پشتیبان با کرنل پیشنهادی (New kernel Regression Support Vector) جهت مدل‌سازی خشک‌سالی با در نظر گرفتن شاخص استاندارد شده بارش (Standardized Precipitation Index) استفاده شده است. نتایج مدل‌سازی‌ها در اغلب حالات بیانگر کارایی بهتر مدل پیشنهادی SVR_N نسبت به دیگر مدل‌ها بود که در SPI ۴۸ ماهه بهترین دقت مدل‌سازی حاصل گردید و مقدار RMSE و R^2 به ترتیب برابر ۰/۰۹۳ و ۰/۹۹۱ به دست آمد. همچنین مدل‌های GRNN، MLP و SVR به ترتیب بعد از SVR_N کارایی بهتری در مدل‌سازی از خود نشان دادند. نتایج این تحقیق بیانگر اهمیت انتخاب و بهینه‌سازی

کرل بر رفتار مدل‌سازی پدیده خشک‌سالی در مدل‌سازی به روش رگرسیون بردار پشتیبان است.

پیشینه و هدف:

خشک‌سالی یا به عبارتی دوره کم‌آبی ازجمله خصوصیت ذاتی هر اقلیمی است، خشک‌سالی برخلاف خشکی که حالت دائمی از یک اقلیم است، یک اختلال موقتی است. شدت و مدت‌زمان خشک‌سالی از منطقه‌ای به منطقه دیگر متفاوت است. تعاریف مختلفی از خشک‌سالی ارائه شده است اما در حالت کلی خشک‌سالی کاهش میزان بارش به زیر مقدار نرمال یک منطقه در درازمدت است. از آنجایی که اثرات خشک‌سالی بسیار وسیع بوده و همه مسائل زندگی بشری از محیط‌زیست انسان‌ها تا وضعیت اقتصادی و معیشتی مردم را تحت‌الشعاع قرار می‌دهد، لذا مدل‌سازی و پیش‌بینی خشک‌سالی بسیار در کنترل و مدیریت منابع آب جهت مقابله با اثرات خشک‌سالی مؤثر است. در گذشته از مدل‌های ریاضی مانند روش رگرسیون ساده، میانگین متحرک و نیز ARIMA جهت مدل‌سازی خشک‌سالی استفاده می‌شد. در سال‌های اخیر استفاده از روش‌های هوش محاسباتی جهت مدل‌سازی و پیش‌بینی خشک‌سالی بسیار مورد توجه دانشمندان بوده است. ازجمله روش‌های هوش محاسباتی می‌توان به ابزارهایی مانند انواع شبکه‌های عصبی مصنوعی، منطق فازی، رگرسیون بردار پشتیبان و نیز مدل‌های فازی - عصبی اشاره کرد. یکی از شاخص‌هایی که بسیار مورد استفاده دانشمندان در مطالعات خشک‌سالی بوده است شاخص استاندارد شده بارش (SPI) است. هدف از این تحقیق بررسی اثر بهینه‌سازی کرل در مدل رگرسیون بردار پشتیبان جهت بهبود مدل‌سازی خشک‌سالی است. این مطالعه بر روی داده‌های بارش ایستگاه سینوپتیک شهر سنندج انجام شده است. شهر سنندج به‌عنوان مرکز استان کردستان منطقه‌ای کوهستانی بوده و دارای اقلیم نیمه‌خشک بر پایه شاخص اقلیمی دمارتن و نیمه‌خشک سرد بر پایه اقلیم آمبروزه است. در شهر سنندج میزان میانگین بارش سالانه ۴۵۸ میلی‌متر است.

مواد و روش:

جهت مدل‌سازی شاخص SPI در ایستگاه سینوپتیک سنندج از چهار روش هوش محاسباتی شامل شبکه عصبی پرسپترون چندلایه MLP، شبکه عصبی رگرسیون تعمیم‌یافته GRNN، رگرسیون بردار پشتیبان SVR و رگرسیون بردار پشتیبان با کرل جدید SVR-N در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه استفاده شد. در

مدل‌های هوش محاسباتی نیاز به تنظیم پارامترها در مدل‌سازی است. انتخاب مقدار بهینه پارامترهای مدل منجر به نتایج بهتر مدل‌سازی خواهد شد. یکی از پارامترهای مهم در رگرسیون بردار پشتیبان (SVR) انتخاب کرل بهینه برای مدل‌سازی است. هر تابعی که در تئوری مرسر صدق کند می‌تواند به‌عنوان کرل در SVR مورد استفاده قرار گیرد. در این پژوهش از دو کرل گوسین و یک کرل جدید (پیشنهادی) در مدل‌سازی خشک‌سالی با SVR استفاده شد. در این پژوهش ابتدا شاخص خشک‌سالی SPI در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه در بازه زمانی بین سال‌های ۱۳۵۹ تا ۱۳۹۶ هجری شمسی معادل ۱۹۸۱ تا ۲۰۱۷ میلادی از داده‌های بارش ایستگاه سینوپتیک محاسبه شد. در ادامه جداگانه هر چهار مدل هوش محاسباتی MLP، GRNN، SVR و SVR-N در محیط برنامه‌نویسی نرم‌افزار MATLAB پیاده‌سازی شد. سری زمانی SPI به‌صورت تصادفی به دودسته داده‌های آموزشی مدل‌های هوش محاسباتی و داده‌های تست مدل‌های هوش محاسباتی تقسیم‌بندی شد. ۸۰ درصد داده‌ها به‌عنوان داده‌های آموزشی و ۲۰ درصد باقی‌مانده به‌عنوان داده‌های تست انتخاب شد. از داده‌های آموزشی جهت تربیت هر چهار مدل MLP، GRNN، SVR و SVR-N استفاده شد و نیز از داده‌های تست جهت مقایسه نتایج حاصل از مدل‌سازی چهار مدل مذکور استفاده شد.

نتایج و بحث:

نتایج این پژوهش نشان داد هر چهار مدل توانایی بالایی در مدل‌سازی شاخص خشک‌سالی SPI دارند. از آنجایی که با افزایش مقیاس زمانی از ۶ ماهه به سمت ۴۸ ماهه سری زمانی SPI دارای رفتاری نرم‌تر یا به اصطلاحی هموارتر است لذا همه مدل‌ها با افزایش مقیاس زمانی دارای دقت بالاتری در مدل‌سازی شدند. با مقایسه خروجی‌های چهار مدل با داده‌های واقعی SPI در ۲۰ درصد داده‌های تست تقریباً در تمامی مقیاس‌های زمانی مدل SVR-N دارای نتایج بهتری در مدل‌سازی شد. همچنین مدل SVR با کرل گوسین (که در بیشتر مطالعات از این فرم استفاده می‌شود) نسبت به دیگر مدل‌ها برآورد ضعیف‌تری را از خود نشان می‌دهد که البته با تغییر کرل در SVR نتایج مدل‌سازی برای SPI های مختلف خیلی بهتر شد. نتایج بیانگر مقادیر کمتر RMSE و مقادیر بالاتر R^2 در مدل پیشنهادی نسبت به دیگر مدل‌ها در حالات SPI مختلف است. تفاوت بین مقادیر RMSE و R^2 مدل پیشنهادی و مدل SVR با

نتیجه‌گیری:

از یافته‌های این تحقیق می‌توان نتیجه گرفت تغییر پارامترهای مدل‌های هوش محاسباتی باعث تغییر رفتار مدل‌سازی این ابزارها خواهد بود. در مدل SVR انتخاب بهینه کرنل تأثیر بسزایی در نتایج مدل‌سازی داشت. پیشنهاد می‌شود در تحقیقات مشابه وظیفه یافتن پارامترهای بهینه مدل‌ها به الگوریتم‌های ابتکاری و فرا ابتکاری سپرده شود و نتایج با روش‌های آزمون و خطا مقایسه شود. از طرفی از آنجایی که پدیده‌هایی مانند بارش و شاخص‌های خشک‌سالی از جمله SPI دارای رفتاری فرکانسی پیچیده‌ای است لذا توصیه می‌گردد قبل از ورود شاخص SPI به مدل‌ها این شاخص قبلاً از فیلتر موجک عبور کند. این کار باعث تجزیه سری زمانی SPI به مؤلفه‌های فرکانسی می‌شود و در نتیجه باعث افزایش تعداد ورودی‌ها می‌شود. افزایش تعداد ورودی‌ها با فرکانس‌های مختلف باعث می‌شود که فرکانس‌هایی که تأثیر کمتری در نتایج دارند ضرایب کمتری در مدل‌ها داشته باشند و این امر باعث بهبود نتایج خواهد شد. در حالت کلی می‌توان نتیجه گرفت که با بهبود مدل‌های هوش محاسباتی شامل فیلتر کردن ورودی‌ها و نیز انتخاب مقدار بهینه پارامترهای مدل‌سازی نتایج بهتری در مدل‌سازی و پیش‌بینی خشک‌سالی حاصل می‌شود.

واژگان کلیدی: هوش محاسباتی، شبکه عصبی، کرنل، رگرسیون

بردار پشتیبان

کرنل گوسین نیز مشهود است که حاکی از اثربخش بودن تغییر کرنل بر مدل‌سازی است. هرچند مدل GRNN نیز در حالات مختلف مقادیر مناسب RMSE و R^2 نسبت به دیگر مدل‌ها داشته است. مدل GRNN برای SPI ۶ ماهه دارای بهترین حالت مقادیر RMSE و R^2 نسبت به دیگر مدل‌ها بوده است که البته اختلاف آن با مدل پیشنهادی بسیار جزئی است. بالاترین دقت در مدل‌سازی در بین مدل‌های مورد استفاده در مقیاس زمانی ۴۸ ماهه و مربوط به مدل SVR-N که به ترتیب مقدار RMSE و R^2 برابر ۰/۰۹۳ و ۰/۹۹۱ شد. پایین‌ترین دقت در مقیاس زمانی ۶ ماهه و مربوط به مدل MLP شد که در این مدل نیز به ترتیب مقدار RMSE و R^2 برابر ۰/۶۳۳ و ۰/۶۰۲ شد. در مقیاس زمانی ۱۲ ماهه به یک‌باره میزان RMSE و R^2 تغییر قابل ملاحظه‌ای نسبت به مقیاس زمانی ۶ ماهه در همه مدل‌ها دارد، این امر به ماهیت نرم‌تر شدن نمودار سری زمانی SPI ۱۲ ماهه برمی‌گردد که در تصاویر این تحقیق نمودار سری‌های زمانی ۶ تا ۴۸ ماهه نشان داده شده است. در حالت کلی مدل SVR-N دارای بهترین عملکرد در مدل‌سازی شاخص خشک‌سالی SPI در مقیاس‌های زمانی مختلف شد و بعد از آن مدل GRNN دارای عملکرد بهتری شد. مدل MLP به عنوان سومین مدل در مدل‌سازی شاخص خشک‌سالی SPI از لحاظ دقت شد و در انتها مدل SVR با کرنل گوسین قرار گرفت. نتایج این تحقیق حاکی از قدرت بالای ابزارهای هوش محاسباتی در مدل‌سازی خشک‌سالی بود.

مقدمه

خشک‌سالی به سبب تعداد، فراوانی، گستردگی و تبعات کوتاه و بلندمدت اقتصادی اجتماعی و زیست‌محیطی، ازجمله مهم‌ترین حوادث طبیعی به شمار می‌رود (۱۸). بر همین اساس، مطالعه این پدیده نقش مهمی در برنامه‌ریزی‌ها و تصمیم‌گیری‌های کلان مدیریتی برای رسیدن به اهداف توسعه پایدار دارد (۲۱). خشک‌سالی پدیده‌ای است که اساساً با کمبود بارش و یا در برخی موارد با تبخیر و تعرق زیاد در یک منطقه مرتبط است (۲۳). با توجه به اینکه خشک‌سالی در هر اقلیمی اعم از مناطق خشک، نیمه‌خشک تا مناطق مرطوب و خیلی مرطوب ممکن است اتفاق بیافتد و ایران نیز دارای تنوع اقلیمی مختلفی است، لذا بررسی و مدل‌سازی خشک‌سالی به صورت محلی و منطقه‌ای امری ضروری است. در این تحقیق شهر سنجند که دارای اقلیمی نیمه‌خشک است انتخاب شده است. با در نظر گرفتن مطالب فوق، ایجاد سیستمی که بتواند با دقت بالایی پدیده خشک‌سالی را مدل‌سازی کند امری ضروری و اجتناب‌ناپذیر است. روش‌های متفاوتی برای مدل‌سازی پدیده خشک‌سالی وجود دارد که می‌توان به مطالعه رحمتی و همکاران (۱۹) جهت مدل‌سازی خشک‌سالی کشاورزی در منطقه جنوب شرقی استرالیا با استفاده از روش‌های یادگیری ماشین اشاره کرد. روش‌های استفاده‌شده در این تحقیق شامل ماشین بردار پشتیبان، درختان طبقه‌بندی و رگرسیون، درختان رگرسیون تقویت‌شده، خطوط رگرسیون تطبیقی و تحلیل تفکیک انعطاف‌پذیر بود. نتایج این تحقیق نشان داد که مدل ماشین بردار پشتیبان توانایی بالایی در مدل‌سازی خشک‌سالی در منطقه جنوب شرقی استرالیا دارد. محمود زاده و عزیز مرادی (۱۳) جهت مدل‌سازی جنگل‌زدایی در جنگل‌های اطراف خرم‌آباد از شبکه عصبی و سیستم اطلاعات جغرافیایی استفاده کردند. نتایج حاصل از این تحقیق نشان داد شبکه عصبی پرسپترون چندلایه توانایی بالایی در مدل‌سازی و برآورد مقدار واقعی جنگل‌زدایی دارد. علیزاده و نیکو (۱) برای تخمین خشک‌سالی هواشناسی در استان فارس از یک روش مبتنی بر ادغام روش‌های مختلف هوش محاسباتی (MLP)،

Adaptive و SVR، Group Method of Data Handling


Neuro-Fuzzy Inference System) به همراه استفاده از داده‌های سنجش‌ازدور استفاده کردند. نتایج نشان‌دهنده دقت بالاتر روش ترکیبی نسبت به روش‌های منفرد است. غلام نیا و همکاران (۹) با استفاده از روش‌های آنالیز سری زمانی داده‌های NDVI به تحلیل مکانی - زمانی پارامترهای فنولوژی مستخرج شده از شاخص NDVI در مناطق نیمه‌خشک کردستان پرداختند. نتایج حاصل از این تحقیق نشان داد به‌طورکلی، نتایج رفتار NDVI را از نظر سربیزی، طول عمر، تغییرات ناگهانی برای پوشش‌های مختلف زمین و در طول سال‌های مختلف و ارتباط آن با شاخص خشک‌سالی نشان داد که چگونه شمال غرب و غرب منطقه مورد مطالعه می‌تواند بیشتر مستعد شرایط خشک‌سالی باشند. همچنین مطالعات مختلفی در زمینه کاربرد الگوریتم‌های یادگیری ماشین و هوش محاسباتی در مدل‌سازی پدیده‌های مختلف مورد مطالعه محققین قرار گرفته است. ازجمله می‌توان به مطالعه قاسمی و همکاران (۸) جهت پیش‌بینی سطح تاج پوشش جنگل‌های مانگرو از چهار الگوریتم نزدیک‌ترین همسایه، ماشین بردار پشتیبان، جنگل تصادفی و رگرسیون خطی چند متغیره با استفاده از تصاویر دوربین هوایی استفاده کردند. نتایج این تحقیق نشان‌دهنده دقت بالاتر روش‌های ناپارامتریک جنگل تصادفی، ماشین بردار پشتیبان و نزدیک‌ترین همسایه نسبت به الگوریتم پارامتریک رگرسیون چند متغیره دارد. نتایج تمامی تحقیقاتی که از مدل رگرسیون بردار پشتیبان استفاده شده است، حاکی از کارآمدی بالای این مدل در پیش‌بینی و مدل‌سازی خشک‌سالی دارد. به‌عنوان نمونه خسروی و همکاران (۱۱) برای مدل‌سازی خشک‌سالی هواشناسی در شرق اصفهان از چهار مدل رگرسیون بردار پشتیبان کمترین مربعات، رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه و فازی-عصبی استفاده کردند. نتایج این تحقیق نشان داد مدل رگرسیون بردار پشتیبان دارای بالاترین دقت و مدل شبکه عصبی پرسپترون چندلایه پایین‌ترین دقت را داشت. نتایج این تحقیق نشان داد رگرسیون بردار پشتیبان کمترین

مربعات نسبت به بقیه مدل‌ها سرعت عملکرد بیشتر دارد. میسر و سینگ (۱۶) در یک مقاله مروری به انواع روش‌های مورد استفاده در مدل‌سازی خشک‌سالی پرداخته‌اند. نتایج این تحقیق حاکی از دقت بالای روش‌های هوش محاسباتی و روش‌های هیبریدی در کارهای گذشته دارد. تمام این پژوهش‌ها، بر کارایی روش‌های هوش محاسباتی در مدل‌سازی رفتار غیرخطی سری زمانی شاخص‌های خشک‌سالی اذعان دارند. شاخص‌های زیادی برای ارزیابی کمی و کیفی خشک‌سالی وجود دارد. برای تعریف خشک‌سالی از شاخص‌های مختلفی در پژوهش‌ها استفاده شده است. از جمله شاخص‌های خشک‌سالی می‌توان به شاخص دهک‌های بارندگی (Deciles Precipitation Index)، شاخص درصد نرمال بارش (Percent of Normal Precipitation Index)، شاخص ذخیره آب سطحی (Surface Water Storage Index)، شاخص خشک‌سالی احيایی (Reconnaissance Drought Index) و شاخص بارش استاندارد شده (Standardized Precipitation Index) اشاره کرد که می‌توان در میان شاخص‌های مختلف، شاخص بارش استاندارد شده (SPI) را به عنوان معروف‌ترین شاخص خشک‌سالی نام برد. یکی از مهم‌ترین ویژگی‌های مفید شاخص SPI توانایی بیان خشک‌سالی در مقیاس‌های زمانی مختلف است. ابراهیمی و همکاران (۶) در ارزیابی و پایش تغییرات رطوبت تالاب میقان از تکنیک سنجش از دور و ارتباط آن با شاخص هواشناسی SPI استفاده کردند. علیزاده و نیکو (۱) برای تخمین خشک‌سالی

هواشناسی در استان فارس از شاخص خشک‌سالی SPI استفاده کرده است. لازم به ذکر است در خصوص مدل‌سازی خشک‌سالی با استفاده از شاخص SPI در روش رگرسیون بردار پشتیبان، مطالعات مشخصی در خصوص میزان کارایی اثر کرنل و تغییر آن بر کارایی نتایج مدل‌سازی انجام نشده است. در این تحقیق به بررسی اثر تغییر کرنل بر رفتار رگرسیون بردار پشتیبان پرداخته شده است. جهت مقایسه نتایج با روش‌های دیگر در این پژوهش از چهار مدل رگرسیون بردار پشتیبان با کرنل گوسی، رگرسیون بردار پشتیبان با کرنل جدید (پیشنهادی)، مدل شبکه عصبی پرسپترون چندلایه و مدل شبکه عصبی رگرسیون تعمیم‌یافته جهت مدل‌سازی خشک‌سالی با استفاده از شاخص خشک‌سالی SPI در پنج مقیاس زمانی شامل ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه استفاده شده است.

منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق شهرستان سنندج از توابع استان کردستان است که در عرض جغرافیایی ۳۵ درجه و ۳ دقیقه عرض تا ۳۵ درجه و ۴۰ دقیقه شمالی و ۴۶ درجه و ۲۵ دقیقه تا ۴۷ درجه و ۲۰ دقیقه طول جغرافیایی شرقی است. این شهرستان منطقه‌ای کوهستانی بوده و دارای اقلیم نیمه‌خشک بر پایه شاخص اقلیمی دمارتن و نیمه‌خشک سرد بر پایه اقلیم آمبروزه است که میزان میانگین بارش سالانه ۴۵۸ میلی‌متر و با حداکثر و حداقل دمای سالانه ۳۶/۸ و ۵/۴- درجه است. شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه را نشان می‌دهد.



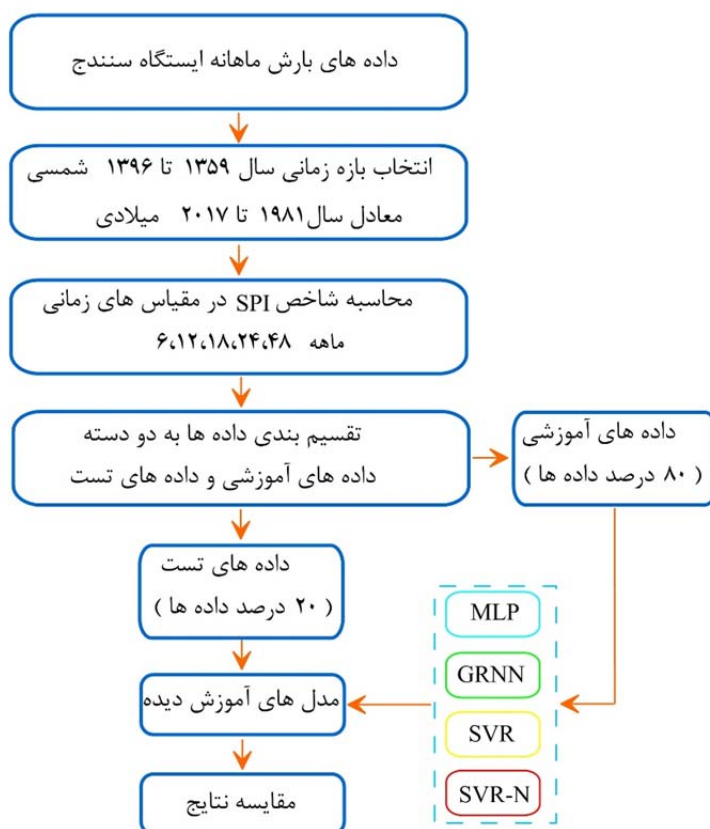
شکل ۱. موقعیت منطقه مورد مطالعه (شهرستان سنندج)

Fig.1. Study area (Sanandaj city)

روش‌شناسی

در این پژوهش ابتدا با مراجعه به سایت سازمان هواشناسی کشور به آدرس اینترنتی <https://Data.irimo.ir> اطلاعات بارش ماهانه ایستگاه سنندج دریافت شد. داده‌های بارش ماهانه ایستگاه سینوپتیک شهر سنندج از سال ۱۹۵۹ تا ۲۰۱۷ در زمان انجام تحقیق در دسترس بود. به توجه به نقص اطلاعات بارش ماهانه ایستگاه سنندج بین سال‌های ۱۹۵۹ تا ۱۹۸۰، از اطلاعات بارش ماهانه بین سال‌های ۱۹۸۱ تا ۲۰۱۷ در این تحقیق استفاده شد. با استفاده از داده‌های بارش تجمعی ماهانه ایستگاه سینوپتیک شهرستان سنندج شاخص خشک‌سالی SPI در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه استخراج

گردید. سپس با استفاده از روش‌های شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و رگرسیون بردار پشتیبان (SVR) با کرنل گوسی و رگرسیون بردار پشتیبان با کرنل جدید (پیشنهادی این تحقیق) مدل‌سازی سری زمانی خشک‌سالی انجام شد. در شکل ۲ فلوچارت کلی و روند انجام پژوهش نشان داده شده است. شاخص خشک‌سالی محاسبه‌شده به دو گروه داده‌های آموزشی مدل‌ها (۸۰ درصد داده‌ها) و داده‌های تست مدل‌ها (۲۰ درصد باقی‌مانده داده‌ها) تقسیم شد. از داده‌های آموزشی جهت آموزش مدل‌ها استفاده شد و از ۲۰ درصد باقی‌مانده داده‌ها جهت مقایسه کارایی چهار مدل استفاده شد.



شکل ۲. فلوچارت روند کلی انجام پژوهش

Fig. 2. Diagram of methodology

محاسبه شاخص SPI

$$Y = \frac{A}{B} = \frac{\sum_{i=1}^n w_i \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\delta^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T (X - X_i)}{2\delta^2}\right)} \quad [1]$$

که در آن δ تنها پارامتر قابل تنظیم است که مقدار آن در این تحقیق از طریق سعی و خطا محاسبه شد.


شبکه عصبی پرسپترون چندلایه

یکی از روش‌های خانواده بزرگ شبکه‌های عصبی، شبکه عصبی پرسپترون چندلایه است. این نوع از شبکه عصبی کارایی بالایی در حل مسائل غیرخطی دارد. MLP در حالت کلی شامل سه بخش لایه ورودی، لایه‌های مخفی و یک لایه خروجی است (۷). لایه‌های مخفی می‌تواند بیش از یک لایه باشد و معمولاً در مسائل غیرخطی از دو یا حداکثر سه لایه مخفی استفاده می‌شود. در این تحقیق از یک شبکه عصبی با دولایه پنهان استفاده شد. در لایه اول پنهان از ۵۰ نورون و در لایه دوم از پنج نورون استفاده شد. در شکل ۳ معماری شبکه عصبی MLP استفاده‌شده در این تحقیق آمده است. روش‌های مختلفی جهت آموزش شبکه عصبی MLP وجود دارد که از جمله کارآمدترین روش‌ها می‌توان به روش لونیبرگ - مارکواردت (Levenberg-Marquardt) اشاره کرد که در این تحقیق نیز جهت آموزش شبکه عصبی MLP از این روش استفاده شد. در لایه‌های پنهان اول و دوم از تابع فعال‌ساز سیگموئید و در لایه خروجی از تابع فعال‌ساز خطی استفاده شد (۱۷).

مراحل محاسبه SPI و نحوه استخراج آن برای مقیاس‌های زمانی مختلف در مراجع (۲ و ۱۴ و ۱۵) با جزئیات بیشتر بیان شده است. در این تحقیق الگوریتم محاسبه شاخص SPI در محیط نرم‌افزار MATLAB پیاده‌سازی گردید و ابتدا صحت سنجی کدهای پیاده‌سازی شده با دو نرم‌افزار علمی MDM (<https://agrimetsoft.com/mdm.aspx>) و Drinc (<https://drought-software.com/download>) کنترل گردید، سپس داده ماهانه بارش ایستگاه سندج بین سال‌های ۱۹۸۱ تا ۲۰۱۷ (داده‌های مربوط به ۳۷ سال) جهت استخراج مقادیر SPI در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ برای این دوره زمانی استفاده شد.

شبکه عصبی رگرسیونی تعمیم‌یافته

یکی از الگوریتم‌های استفاده‌شده در این تحقیق، الگوریتم شبکه عصبی GRNN است که نخستین بار در سال ۱۹۹۱ توسط اسپکت (Specht) معرفی شد (۲۰). شبکه عصبی GRNN که در این تحقیق استفاده شد، شامل چهار لایه ورودی، الگو، جمع و لایه خروجی است که ورودی با نماد X و خروجی شبکه GRNN با نماد Y نشان داده‌شده است که از رابطه ۱ محاسبه شد که در آن A, B خروجی دو نورون لایه جمع می‌باشند (۳).



شکل ۳. ساختار شبکه MLP استفاده‌شده در این تحقیق (دولایه پنهان با ۵۰ نورون در لایه اول و پنج نورون در لایه دوم)

Fig. 3. The structure of the MLP network used in this study (two hidden layers with 50 neurons in the first layer and five neurons in the second layer)

رگرسیون بردار پشتیبان

در این تحقیق از رگرسیون بردار پشتیبان که در واقع تعمیمی از ماشین بردار پشتیبان است و در سال ۱۹۹۵ توسط وپنیک معرفی شد به‌عنوان مبحث اصلی تحقیق استفاده شده است و به نحوی با تغییر در کرنل به توسعه و بهبود این الگوریتم پرداخته شده است. رگرسیون بردار پشتیبان برخلاف انواع شبکه‌های عصبی از جمله MLP، RBF و حتی ANFIS به‌جای کمینه کردن خطای مدل‌سازی، ریسک عملیاتی را به‌عنوان تابع هدف در نظر گرفته و مقدار بهینه آن را محاسبه می‌کند (۵). جهت حل مسائل غیرخطی از توابع کرنل که بر اساس ضرب داخلی داده‌ها است، استفاده می‌شود. هر تابعی که در تئوری مرسر صدق کند می‌تواند به‌عنوان تابع کرنل در رگرسیون بردار پشتیبان استفاده شود (۲۲ و ۴). در این تحقیق از کرنل سیگموئید (۲۵) به‌عنوان کرنل معمولی SVR و از کرنل توسعه‌یافته (پیشنهادی) در فرآیند الگوریتم SVR استفاده شد. معادلات ریاضی مربوط به کرنل سیگموئید و کرنل پیشنهادی در روابط ۲ و ۳ به ترتیب آمده است.

$$k(x_i, x_j) = \tanh[\gamma(x_i \cdot x_j) + c] \quad [2]$$

$$k(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|}{2\sigma^2}\right) \quad [3]$$

پارامتر σ یک عدد حقیقی است که در این پژوهش مقدار آن از طریق سعی و خطا محاسبه شد.

معیارهای ارزیابی نتایج مدل‌سازی

برای ارزیابی مدل‌ها و مقایسه بین نتایج چهار روش مدل‌سازی ذکر شده، از دو معیار ارزیابی ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) جهت اندازه‌گیری اختلاف بین مقادیر مشاهداتی و برآورد شده استفاده شده است. این معیارها به‌صورت روابط ۴ و ۵ به ترتیب تعریف می‌شوند (۱۲).

$$R = \sqrt{1 - \frac{\sum_{i=0}^n (y_0 - y_p)^2}{\sum_{i=0}^n (y_0 - \frac{\sum y_0}{n})^2}} \quad [4]$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (y_0 - y_p)^2} \quad [5]$$


در این روابط، y_0 مقادیر مشاهداتی (واقعی) پارامتر SPI می‌باشد که به عنوان داده تست در نظر گرفته شده است و y_p مقادیر برآورد شده SPI به روش مدل‌سازی با استفاده از چهار مدل مورد استفاده در این مطالعه می‌باشد. پارامتر n بیانگر تعداد داده‌های تست مورد استفاده می‌باشد که برای هر مقیاس زمانی این تعداد داده متفاوت می‌باشد. در تفسیر کلی مدل‌هایی با نتایج R^2 بیشتر و RMSE کمتر مطلوب‌تر است. با توجه به اینکه ۳۷ سال داده بارش معادل ۴۴۴ داده ماهانه بارش می‌باشد و در محاسبه شاخص ۶ ماهه SPI پنج داده اول به دلیل فرمولاسیون تجمعی SPI کم می‌شود که در نهایت ۴۳۹ داده باقی می‌ماند و از این تعداد داده ۳۵۲ داده (معادل ۸۰ درصد داده‌های SPI) برای آموزش مدل‌ها و ۸۷ داده (معادل ۲۰ درصد داده‌های SPI) نیز به‌عنوان داده تست مدل‌ها استفاده گردید. به همین ترتیب در محاسبه شاخص ۱۲ ماهه SPI، از ۴۳۳ داده SPI، ۳۴۷ داده (معادل ۸۰ درصد داده‌های SPI) برای آموزش مدل‌ها استفاده شد؛ و ۸۶ (معادل ۲۰ درصد داده‌های SPI) داده نیز به‌عنوان داده تست مدل‌ها استفاده شد. در محاسبه شاخص ۱۸ ماهه SPI، ۳۴۲ داده برای آموزش مدل‌ها و ۸۵ داده نیز به‌عنوان داده تست مدل‌ها استفاده شد. در محاسبه شاخص ۲۴ ماهه SPI، ۳۳۷ داده برای آموزش مدل‌ها و ۸۴ داده نیز به‌عنوان داده تست مدل‌ها استفاده شد و در نهایت برای محاسبه شاخص ۴۸ ماهه SPI، ۳۱۸ داده برای آموزش مدل‌ها و ۷۹ داده نیز به‌عنوان داده تست مدل‌ها استفاده شد.

نتایج

در شکل ۴ سری زمانی بارش در بازه زمانی ۱۳۵۹ تا ۱۳۹۶ و مقادیر SPI برای مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸


مقدار واقعی داده‌های تست نزدیکتر است. هرچند در برآورد داده‌های SPI در مقیاس‌های زمانی پایین (۶، ۱۲ و ۱۸ ماهه) خطای بیشتری برای هر چهار مدل وجود دارد اما در مدل SVR با کرنل گوسین (ستون چهارم) به نحوی رفتاری سیستماتیک در برآورد مقادیر بالای SPI (بدون در نظر گرفتن علامت) وجود دارد. همان‌طور که در این نمودارها دیده می‌شود در بیشتر مدل‌سازی‌ها و مقیاس‌های مختلف، برای مقادیر SPI نزدیک به صفر پیش‌بینی‌های مدل‌ها نسبت به دیگر مقادیر SPI نتایج بهتری بدست آمده است و داده‌های برآورد شده به داده‌های تست نزدیک‌تر است. هرچند مدل SVR با کرنل گوسین (که در بیشتر مطالعات از این فرم استفاده می‌شود) نسبت به دیگر مدل‌ها برآورد ضعیف‌تری را از خود نشان داد ولی با تغییر این کرنل به کرنل پیشنهادی شاهد مدل‌سازی به مراتب بهتری برای مقیاس‌های زمانی مختلف SPI هستیم. نمودارهای شکل ۵ بیانگر این موضوع است که در تمامی مقیاس‌های زمانی مدل SVR با کرنل پیشنهادی بهتر از مدل SVR با کرنل گوسین در مدل‌سازی بوده است.

ماهه برای ایستگاه سنجش در همان بازه زمانی نشان داده شده است. همان‌طور که در این شکل مشخص است رفتار سری زمانی SPI با افزایش مقیاس زمانی هموارتر می‌گردد. با استفاده از این داده‌های استخراج شده و ۸۰ درصد داده‌های آموزشی پارامترهای مربوط به مدل‌سازی SVR با کرنل گوسین، MLP، GRNN و مدل پیشنهادی (که درواقع مدل SVR با کرنل تغییر یافته است) بهینه‌سازی گردید. در شکل ۵ مقادیر برآورد شده داده‌های تست برای همه مدل‌های مورد مطالعه در این تحقیق به صورت مرتب شده از کوچک به بزرگ نمایش داده شده است. ستون‌های این شکل به ترتیب شامل SVR با کرنل پیشنهادی (ستون اول)، مدل شبکه عصبی GRNN (ستون دوم)، مدل شبکه عصبی MLP (ستون سوم) و ستون آخر مدل SVR با کرنل گوسین است که به نحوی ستون‌های این نمودار به ترتیب بهترین نتایج بدست آمده چیده شده است. سطرهای این نمودار به ترتیب شامل SPI در مقیاس زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه است. رفتار کلی نمودارها در همه مدل‌سازی‌ها بیانگر این موضوع است که در SPI هایی با مقیاس زمانی بالاتر برآورد بهتر انجام شده است و SPI مدل‌سازی شده به



شکل ۴. نمودار مقادیر بارش و SPI در بازه‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه

Fig. 4. Precipitation and SPI graph in 6,12,18,24 and 48 monthly time scale




شکل ۵. نمودار مقادیر SPI مشاهداتی و پیش‌بینی با استفاده مدل‌های مورد بررسی
Fig. 5. Observed and predicted amount of SPI with processing models

است که در آن به نحوی جدایی بین مقادیر مشاهداتی و برآورد شده در مقادیر مختلف SPI نمایش داده شده است. شکل ۶ شامل چهار ستون و پنج سطر است که ستون اول تا چهارم به ترتیب مدل SVR با کرنل پیشنهادی، مدل GRNN، مدل MLP و مدل SVR با کرنل گوسی است. سطرهای این شکل به ترتیب مربوط به شاخص SPI در مقیاس‌های زمانی ۶ تا ۴۸ ماهه است. تعداد نمودارهای این شکل، ۲۰ نمودار است که هر کدام دو محور x و y دارند که محور x هر کدام بیانگر مقدار SPI مشاهداتی (واقعی) و محور y بیانگر مقدار مدل‌سازی شده

شکل ۶ بیانگر پراکنش مقادیر بین SPI مشاهداتی و نتایج حاصل از مدل‌سازی با چهار مدل استفاده‌شده در تحقیق است که نمودار رگرسیون خطی بین مقادیر برآوردشده و مشاهداتی نیز نمایش داده‌شده است. به همراه این نمودار رگرسیون خطی باند عدم قطعیت ۹۵ درصد برآوردها نیز آورده شده است که به نحوی نشان‌دهنده میزان خطای برآورد در رگرسیون خطی است. هر مقدار این باند پهنای بیشتری داشته باشد عدم قطعیت بیشتری در برآوردها برای آن بخش از مشاهدات بوده است. به عبارتی دیگر این نمودار شکل دیگری از نمودار ۵

گوسین بیشترین عدم قطعیت را نسبت به دیگر مدل‌ها در حالات مختلف SPI را دارد.

(خروجی مدل‌ها) است. همان‌طور که در این اشکال دیده می‌شود میزان عدم قطعیت برآورد مدل‌ها در SPI شش‌ماهه بیشتر از دیگر حالات SPI است. همچنین مدل SVR با کرنل



شکل ۶. نمودار پراکنش دویعدی مقادیر SPI مشاهداتی و پیش‌بینی با استفاده مدل‌های مورد مطالعه به همراه نمودار رگرسیون بین آن‌ها.

Fig. 6. Scatter plot of observed and predicted SPI for each model with its regression line

قرمز تیره نزدیک‌تر باشد باشد، دقت بالاتر (RMSE کمتر) است. در قسمت ب شکل ۷ نیز هر چه رنگ سلولی به سبز تیره نزدیک‌تر باشد دقت بالاتر (R^2 بیشتر) و هر چه رنگ سلولی به قرمز تیره نزدیک‌تر باشد باشد، دقت پایین‌تر (R^2 کمتر) است. در حالت کلی هرچه مقدار RMSE به عدد صفر و مقدار R^2 به عدد یک نزدیک‌تر باشد مدل‌سازی بهتری انجام شده است. مقادیر RMSE به ترتیب با افزایش مقیاس زمانی از ۶ به ۴۸ برای همه مدل‌ها روند کاهشی دارد و این مقادیر دقیقاً متناظر با رفتار مدل‌سازی‌های مربوط به نمودارهای شکل ۵ می‌باشد. بررسی نتایج عددی نشان می‌دهد که مدل GRNN

در شکل ۷ پارامترهای ارزیابی مدل‌ها شامل مقادیر RMSE و R^2 مربوط به مدل‌های مختلف برای حالات SPI شش تا ۴۸ ماهه آورده شده است. ستون‌های شکل ۷ به ترتیب RMSE و R^2 مربوط به مدل‌های SVR با کرنل جدید (پیشنهادی)، مدل GRNN، مدل MLP و مدل SVR با کرنل گوسی است. سطرهای این شکل نیز مربوط به شاخص SPI در مقیاس‌های زمانی مختلف است. مقادیر هر سلول شکل بیانگر مقدار عددی RMSE و R^2 است. در رنگ‌بندی شکل، قسمت الف که مربوط به RMSE است، هر چه رنگ سلولی به سبز تیره نزدیک‌تر باشد دقت پایین‌تر (RMSE بیشتر) و هر چه رنگ سلولی به

SVR دارد. به عنوان مثال مقدار $RMSE$ و R^2 مربوط به SPI در مدل SVR با کرنل پیشنهادی به ترتیب 0.093 و 0.991) در مقایسه با مقدار $RMSE$ و R^2 مربوط به SPI48 در مدل SVR با کرنل گوسی به ترتیب (0.321 و 0.893) حاکی از تأثیر بالای انتخاب بهینه کرنل (کرنل پیشنهادی) دارد.


تنها در مقیاس زمانی شش ماهه (با $RMSE=0.495$ و $R^2=0.757$) توانسته بهتر از مدل پیشنهادی (با $RMSE=0.603$ و $R^2=0.64$) باشد. در تمامی مقیاس‌های زمانی دیگر مدل پیشنهادی عملکرد بهتری داشته است. مقایسه نتایج عددی بین مدل SVR با کرنل گوسی و مدل SVR با کرنل پیشنهادی نشان می‌دهد که انتخاب بهینه کرنل تأثیر بالایی در رفتار مدل

	الف					ب				
	SVR_N	GRNN	MLP	SVR		SVR_N	GRNN	MLP	SVR	
SPI_6	0.603	0.495	0.633	0.609		0.64	0.757	0.602	0.633	SPI_6
SPI_12	0.217	0.227	0.268	0.359		0.953	0.948	0.928	0.872	SPI_12
SPI_18	0.212	0.271	0.266	0.422		0.959	0.933	0.935	0.839	SPI_18
SPI_24	0.131	0.131	0.18	0.389		0.983	0.982	0.967	0.847	SPI_24
SPI_48	0.093	0.094	0.11	0.321		0.991	0.99	0.987	0.893	SPI_48

شکل ۷. مقایسه نتایج مدل‌سازی روش‌های SVR، GRNN، MLP و SVR_N در SPI‌های مختلف. الف) مقادیر $RMSE$ ، ب) مقادیر R^2
Fig. 7. Comparison of MLP، GRNN، SVR and SVR_N models results. A) $RMSE$, B) R^2

سه مدل دیگر است. ($RMSE$ کمتری دارد). در SPI شش ماهه مدل GRNN بهتر ظاهر شده است. قسمت ب شکل که نتایج R^2 مدل‌های مختلف است نیز نشان می‌دهد مدل SVR با کرنل پیشنهادی تحقیق غیر از مقیاس زمانی شش ماهه در بقیه مقیاس‌های زمانی عملکرد بهتری داشته است. (مقدار R^2 بیشتر است).

شکل ۸ مقادیر $RMSE$ و R^2 مدل‌های استفاده شده در تحقیق را بر روی موقعیت مکانی ایستگاه سینوپتیک شهر سنندج نشان می‌دهد. قسمت الف شکل ۸ که مربوط به نتایج $RMSE$ مدل‌های استفاده شده در تحقیق در SPI‌های مختلف است، نشان می‌دهد که به غیر از SPI شش ماهه در بقیه مقیاس‌های زمانی مدل SVR با کرنل پیشنهادی تحقیق بهتر از



شکل ۸. نمایش مقادیر $RMSE$ و R^2 مدل‌های SVR، GRNN، MLP و SVR_N در SPI‌های مختلف بر روی نقشه ارتفاعی. الف) مقادیر $RMSE$ ، ب) مقادیر R^2

Fig. 8. $RMSE$ and R^2 values of MLP، GRNN، SVR and SVR_N models in different SPIs on Elevation map. A) $RMSE$ values, b) R^2 values

بحث و نتیجه‌گیری

خشک‌سالی به‌عنوان یکی از بحران‌های طبیعی زمین است که همیشه خسارت‌های زیادی را در حوزه‌های مختلف اجتماعی - اقتصادی - فرهنگی و سیاسی باعث شده است. یکی از روش‌های کاهش اثرات مخرب خشک‌سالی مدل‌سازی و پیش‌بینی این پدیده است. در این مطالعه با بهره‌گیری از سه الگوریتم هوش محاسباتی شامل شبکه عصبی GRNN، شبکه عصبی MLP، مدل SVR با کرنل گوسی و نیز با معرفی کرنل جدید به مدل SVR به مدل‌سازی خشک‌سالی در ایستگاه سینوپتیک سنندج پرداخته شد. در این مطالعه از ۳۷ سال داده بارش ماهانه ایستگاه سینوپتیک شهر سنندج، جهت استخراج شاخص خشک‌سالی SPI در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه استفاده شد. در ادامه به مدل‌سازی شاخص SPI در مقیاس‌های زمانی ذکرشده با استفاده از مدل‌های SVR، GRNN، MLP و SVR با کرنل جدید پرداخته شد. یکی از نتایج تحقیق این است که مدل GRNN نسبت به دو مدل MLP و SVR با کرنل گوسی دارای کارایی بهتری در مدل‌سازی است. این موضوع با نتیجه حاصل از پژوهش سیگیزاوغلو که به پیش‌بینی جریان ماهانه در رودخانه گوکسو در شرق مدیترانه در کشور ترکیه با استفاده از مدل شبکه عصبی FFBP و مدل GRNN پرداخته است و نشان داد که مدل GRNN دارای عملکرد بهتری نسبت به مدل FFBP است مطابقت دارد. نتایج تحقیق حاضر نشان داد که با تغییر و بهبود کرنل در الگوریتم SVR می‌توان خشک‌سالی را با دقت بالاتری مدل‌سازی نمود که این کار در تحقیقات قبلی تاکنون موردتوجه واقع نشده است. به‌عنوان مثال در تحقیقی که توسط رحمتی و همکاران (۱۹) جهت مدل‌سازی خشک‌سالی کشاورزی در منطقه جنوب شرقی استرالیا انجام شده است، مدل SVR نسبت به دیگر روش‌های درختان طبقه‌بندی و رگرسیون، درختان رگرسیون تقویت‌شده، خطوط رگرسیون تطبیقی و تحلیل تفکیک انعطاف‌پذیر کارایی بیشتری را از خود نشان داده بود که این امر نشان‌دهنده اهمیت و قدرت بالای مدل‌سازی پدیده خشک‌سالی با SVR است. لازم به ذکر است در این

مطالعه روی کرنل SVR بحثی نشده بود. در تحقیق مشابهی دیگر عزیززاده و نیکو (۱) برای تخمین خشک‌سالی هواشناسی در استان فارس از یک روش مبتنی بر ادغام روش‌های مختلف هوش محاسباتی (MLP، Group Method of Data Handling، SVR و Adaptive Neuro-Fuzzy Inference System) به همراه استفاده از داده‌های سنجش‌ازدور استفاده کردند. در این تحقیق نیز از آنجایی که از الگوریتم SVR و چند الگوریتم دیگر هوش محاسباتی و نیز ترکیب آن‌ها استفاده شده است اما به موضوع تغییر و تأثیر کرنل پرداخته است. همچنین نتایج به‌دست‌آمده در مطالعات خسروی و همکاران (۱۱)، میسرا و سینگ (۱۶) که برای مدل‌سازی خشک‌سالی از الگوریتم SVR استفاده کرده‌اند نیز بیانگر کارایی این الگوریتم نسبت به دیگر روش‌ها بوده است و در این تحقیق‌ها نیز اشاره‌ای به موضوع کرنل در SVR نشده است. با توجه به اینکه در مطالعات زیادی از الگوریتم GRNN و MLP نیز در مدل‌سازی خشک‌سالی استفاده شده بود در این مطالعه نیز از این دو الگوریتم در کنار روش SVR با کرنل گوسین و کرنل پیشنهادی جهت مقایسه نتایج استفاده گردید. نتایج به‌دست‌آمده در این تحقیق نشان‌دهنده تغییر چشمگیری در کارایی مدل پیشنهادی (SVR با کرنل بهبودیافته) نسبت به SVR با کرنل گوسین و دو الگوریتم GRNN و MLP بوده است. این امر به نحوی نشان‌دهنده اهمیت انتخاب و تغییر در کرنل برای مدل‌سازی سری زمانی SPI است. به ترتیب مدل‌های GRNN، MLP و SVR بعد از SVR_N کارایی بهتری در مدل‌سازی از خود نشان دادند. البته در این تحقیق صرفاً از یک کرنل پیشنهادی استفاده شده است که می‌توان از کرنل‌های مختلف دیگری علاوه بر کرنل پیشنهادی استفاده کرد. در این تحقیق تنها به مدل‌سازی سری زمانی شاخص SPI پرداخته شد که در مطالعات آتی می‌توان از پارامترهای مهم محیطی و اقلیمی و تأثیرگذار در پدیده خشک‌سالی نظیر میزان رطوبت، درجه حرارت، میزان تبخیر و تعرق در مدل‌سازی خشک‌سالی استفاده کرد. پیشنهاد می‌شود در مطالعات آتی به انتخاب بهینه پارامترهای هوش محاسباتی از جمله پارامتر σ در الگوریتم

تقدیر و تشکر

این مقاله حاصل پایان‌نامه با عنوان مدل‌سازی مکانی - زمانی پدیده خشک‌سالی با بهره‌گیری از هوش محاسباتی در مقطع (دکتر) در سال ۱۳۹۶ است که با حمایت دانشگاه آزاد اسلامی واحد علوم و تحقیقات (تهران) اجرا شده است.

GRNN و تعیین تعداد بهینه نوروهای لایه پنهان شبکه عصبی MLP به کمک الگوریتم‌های ژنتیک و الگوریتم PSO پرداخته شود.

مراجع

1. Alizadeh MR, Nikoo MR. 2018. A fusion-based methodology for meteorological drought estimation using remote sensing data. *Remote sensing of environment*, 211: 229-247. doi:https://doi.org/10.1016/j.rse.2018.04.001.
2. Cancelliere A, Di Mauro G, Bonaccorso B, Rossi G. 2007. Drought forecasting using the standardized precipitation index. *Water resources management*, 21(5): 801-819. doi:https://doi.org/10.1007/s11269-006-9062-y.
3. Cigizoglu HK. 2005. Generalized regression neural network in monthly flow forecasting. *Civil Engineering and Environmental Systems*, 22(2): 71-81. doi:https://doi.org/10.1080/10286600500126256.
4. Cortes C, Vapnik V. 1995. Support-vector networks. *Machine learning*, 20(3): 273-297. doi:https://doi.org/10.1007/BF00994018.
5. Danandeh Mehr, A., Nourani, V., Karimi Khosrowshahi, V., & Ghorbani, M. A. (2019). A hybrid support vector regression-firefly model for monthly rainfall forecasting. *International Journal of Environmental Science & Technology (IJEST)*, 16(1). doi:https://doi.org/10.1007/s13762-018-1674-2.
6. Ebrahimikhusfi Z, Khosroshahi M, Naeimi M, Zandifar S. 2019. Evaluating and monitoring of moisture variations in Meyghan wetland using the remote sensing technique and the relation to the meteorological drought indices. *Journal of RS and GIS for Natural Resources*, 10(2): 1-14. doi:http://girs.iaubushehr.ac.ir/article_666807.html. (IN Persian).
7. Gardner MW, Dorling S. 1998. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15): 2627-2636. doi:https://doi.org/10.1016/S1352-2310(97)00447-0.
8. Ghasemi A, Fallah A, Shataee Joibari S. 2016. Evaluation of four algorithms for estimation of canopy cover of mangrove forests by using aerial imagery. *Journal of RS and GIS for Natural Resources*, 7(2): 1-16. http://girs.iaubushehr.ac.ir/article_524151.html. (IN Persian).
9. Gholamnia M, Khandan R, Bonafoni S, Sadeghi A. 2019. Spatiotemporal analysis of MODIS NDVI in the semi-arid region of Kurdistan (Iran). *Remote Sensing*, 11(14): 1723. doi:https://doi.org/10.3390/rs11141723.
10. Hamzeh S, Farahani Z, Mahdavi S, CHATRABGOUN O, Gholamnia M. 2017. Spatio-temporal monitoring of agricultural drought using remotely sensed data (Case study of Markazi province of Iran). https://jsaeh.khu.ac.ir/article-1-2749-en.html&sw=Hamzeh. (IN Persian).
11. Khosravi I, Jouybari-Moghaddam Y, Sarajian MR. 2017. The comparison of NN, SVR, LSSVR and ANFIS at modeling meteorological and remotely sensed drought indices over the eastern district of Isfahan, Iran. *Natural Hazards*, 87(3): 1507-1522. doi:https://doi.org/10.1007/s11069-017-2827-1.
12. Li G, Liu Z, Li J, Fang Y, Liu T, Mei Y, Wang Z. 2018. Application of general regression neural network to model a novel integrated fluidized bed gasifier. *International Journal of Hydrogen Energy*, 43(11): 5512-5521. doi:https://doi.org/10.1016/j.ijhydene.2018.01.130.
13. Mahmoudzadeh H, Azizmoradi M. 2019. Deforestation modeling using artificial neural network and GIS (Case study: forests of Khorramabad environs). *Journal of RS and GIS for Natural Resources*, 10(4): 74-90. http://girs.iaubushehr.ac.ir/article_670420.html. (IN Persian).
14. McKee TB, Doesken NJ, Kleist J. 1993. The relationship of drought frequency and duration to time scales. In: *Proceedings of the 8th Conference on Applied Climatology*, vol 22. Boston, pp 179-183.
15. Mishra A, Desai V. 2005. Drought forecasting using stochastic models. *Stochastic environmental research and risk assessment*, 19(5): 326-339. doi:https://doi.org/10.1007/s00477-005-0238-4.
16. Mishra AK, Singh VP. 2011. Drought modeling—A review. *Journal of Hydrology*, 403(1-2): 157-175. doi:https://doi.org/10.1016/j.jhydrol.2011.03.049.
17. Noriega L. 2005. Multilayer perceptron tutorial. School of Computing Staffordshire University.

18. Pachauri RK, Allen MR, Barros VR, Broome J, Cramer W, Christ R, Church JA, Clarke L, Dahe Q, Dasgupta P. 2014. Climate change 2014: synthesis report. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change. Ipcc.
19. Rahmati O, Falah F, Dayal KS, Deo RC, Mohammadi F, Biggs T, Moghaddam DD, Naghibi SA, Bui DT. 2020. Machine learning approaches for spatial modeling of agricultural droughts in the south-east region of Queensland Australia. *Science of the Total Environment*, 699: 134230. doi:https://doi.org/10.1016/j.scitotenv.2019.134230.
20. Specht DF. 1991. A general regression neural network. *IEEE transactions on neural networks*, 2(6): 568-576. doi:https://doi.org/10.1109/72.97934.
21. Trenberth KE, Dai A, Van Der Schrier G, Jones PD, Barichivich J, Briffa KR, Sheffield J. 2014. Global warming and changes in drought. *Nature Climate Change*, 4(1): 17-22. doi:https://doi.org/10.1038/nclimate2067.
22. Vapnik VN. 1999. An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5): 988-999. doi:https://doi.org/10.1109/72.788640.
23. Wilhite DA. 2000. Drought as a natural hazard: concepts and definitions.
24. Wu B, Ma Z, Yan N. 2020. Agricultural drought mitigating indices derived from the changes in drought characteristics. *Remote Sensing of Environment*, 244: 111813. doi:https://doi.org/10.1016/j.rse.2020.111813.
25. Yu P-S, Chen S-T, Chang I-F. 2006. Support vector regression for real-time flood stage forecasting. *Journal of hydrology*, 328(3-4): 704-716. doi:https://doi.org/10.1016/j.jhydrol.2006.01.021.



The effect of kernel optimization in modeling drought phenomenon using computational intelligence (Case study: Sanandaj)

Jahanbakhsh Mohammadi¹, Alireza Vafaeinezhad², Saeed Behzadi³, Hossein Aghamohammadi⁴, Amirhooman Hemmasi⁵

Received: 2021-11-04 / Accepted: 2022-01-25 / Published: 2023-03-21

Abstract

Drought is one of the most important natural disasters with devastating and harmful effects in various economic, social, and environmental fields. Due to the repetitive behavior of this phenomenon, if the appropriate solutions are not implemented, its destructive effects can remain in the region for years after its occurrence. Most natural disasters, such as floods, earthquakes, hurricanes, and landslides in the short term, can cause severe financial and human

damage to society, but droughts are slow-moving and creepy in nature, and their devastating effects appear gradually and over a longer period of time. Therefore, by modeling drought, it is possible to provide plans for drought preparation and reduce the damage caused by it. In this study, computational intelligence algorithms of Multi-Layer Perceptron neural network, Generalized Regression Neural Network, Support Vector Regression with support kernel, and Support Vector regression with the proposed kernel (Support Vector) Regression New kernel has been used to model the drought using the Standardized Precipitation Index. The modeling results, in most cases, showed better performance of the proposed SVR_N model than other models. The values of RMSE and R² were 0.093 and 0.991, respectively, and the GRNN, MLP, and SVR models performed better in modeling after SVR_N, respectively. Modeling of drought phenomenon in modeling is supported by vector regression method.

Jahanbakhsh Mohammadi¹, Alireza Vafaeinezhad²(✉), Saeed Behzadi³, Hossein Aghamohammadi⁴, Amirhooman Hemmasi⁵

1. PhD Student, Department of Remote Sensing and GIS, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Associate Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

3. Assistant Professor, Faculty of Civil Engineering Shahid Rajaee Teacher Training University, Tehran, Iran

4. Assistant Professor, Department of Remote Sensing and GIS, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran

5. Professor, Natural Resources Engineering, Faculty of Natural Resources and Environment, Tehran science and Research Branch, Islamic Azad University, Tehran, Iran.

DOI: 10.30495/girs.2023.688408

e-mail: a_vafaei@sbu.ac.ir

Extended Abstract

Background and Objective

Drought or water deficiency is one of the inherent characteristics of any climate, and unlike aridity, which is a permanent condition of an environment, drought is a temporary disorder; the severity and duration of drought vary from region to region. There are different definitions of drought, but in general, drought decreases precipitation below the average value of an area in the long term. Because the effects of drought are so wide and affect all aspects of human life from the human

environment to the people's economic and living conditions, drought modeling and forecasting is very effective in controlling and managing water resources to deal with the effects of drought. Previously, mathematical models such as simple regression, moving average, and ARIMA were used to model the drought. In recent years, the use of computational intelligence methods to model and predict drought has been of great interest to scientists. Computational intelligence methods include tools such as artificial neural networks, fuzzy logic, support vector regression, and fuzzy-neural models. One of the most widely used indicators by scientists in drought studies is the Standardized Precipitation Index (SPI). The purpose of this research is drought modeling in Sanandaj synoptic station. The city of Sanandaj, as the capital of Kurdistan province, is a mountainous region and has a semi-arid climate based on the Demarten climate index and a cold semi-arid climate based on the Ambrose climate index. In Sanandaj, the average annual rainfall is 458 mm.

Materials and Methods

In this study SPI index in Sanandaj synoptic station was modeled based on four computational intelligence methods, including multilayer perceptron neural network (MLP), generalized regression neural network (GRNN), support vector regression (SVR), and support vector regression with the new kernel (SVR-N) which was used at time scales of 6, 12, 18, 24 and 48 months. Selecting the optimal values of the model parameters will lead to better modeling results. One of the important parameters in support vector regression (SVR) is the selection of the optimal kernel for modeling. Any function that is based on the Mercer theory can be used as a kernel in SVR. In this study, two Gaussian kernels and a new (proposed) kernel were used in drought modeling with SVR modeling. In this study, the first SPI drought index in 6, 12, 18, 24, and 48 months' time scales in the period between 1981 to 2017 AD was calculated from the precipitation data of the synoptic station. Subsequently, all four computational intelligence models MLP, GRNN, SVR, and SVR-N were implemented in MATLAB software development environment. The SPI time series was randomly divided into two categories: training data for computational intelligence models and test data for computational intelligence models. 80% of the data were selected as training data and the remaining 20% as test data. Training data were used to train all four MLP, GRNN, SVR and SVR-N models, and test data were used to compare the modeling results of the four models.

Results and Discussion

The results of this study showed that all four models have a high ability to model the SPI drought index. Since increasing the time scale from 6 months to 48 months, the SPI time series has a smoother behavior, so all model's results showed more accuracy in modeling with increasing time scale. By comparing the outputs of

the four models with the actual SPI data in 20% of the test data, the SVR-N model had better results in modeling in almost all time scales. Also, the SVR model with Gaussian kernel (which is used in most studies) showed a weaker estimate than other models, but with the change of kernel in the SVR, the modeling results for different SPIs were much better. The results showed that the lower values of RMSE and higher values of R^2 in the proposed model than other models in different SPI cases. The difference between the RMSE and R^2 values of the proposed model and the SVR model with the Gaussian kernel is also evident, indicating that the kernel change is effective on modeling. However, the GRNN model also had appropriate RMSE and R^2 values in different cases compared to other models. The GRNN model for 6-month SPI has the best RMSE and values compared to other models; it should be noted that the difference between GRNN and the proposed model is very small. The highest accuracy in modeling among the models used in the 48-month time scale and related to the SVR-N model, which had RMSE and R^2 values of 0.093 and 0.991, respectively. The lowest accuracy in the 6-month time scale was related to the MLP model, in which the values of RMSE and were 0.633 and 0.602, respectively. At the 12-month time scale, the amount of RMSE and at the same time has a significant change compared to the 6-month time scale in all models. This is due to the softer nature of the 12-month SPI time series chart, which is shown in the images in this study as a 6 to 48 month time series chart. In general, the SVR-N model had the best performance in modeling the SPI drought index at different time scales, and then the GRNN model had better performance. The MLP model became the third model in modeling the SPI drought index in terms of accuracy, and finally, the SVR model with the Gaussian kernel was included. The results of this study showed the high power of computational intelligence tools in modeling drought.

Conclusion

It can be concluded that changing the parameters of computational intelligence models will change the modeling behavior of these tools. In the SVR model, optimal kernel selection had a significant effect on modeling results. It is suggested that in similar researches, the task of finding the optimal parameters of the models should be entrusted to innovative and meta-heuristic algorithms, and the results should be compared with trial-and-error methods. On the other hand, since phenomena such as precipitation and drought indices such as SPI have a complex frequency behavior, it is recommended that before the SPI index enters the models, this index must first pass through the wavelet filter. This breaks down the SPI time series into frequency components, thereby increasing the number of inputs. Increasing the number of inputs with different frequencies causes the frequencies that have a more negligible effect on the results to have lower coefficients in the models, and this will improve the

results. In general, it can be concluded that by improving computational intelligence models, including filtering inputs and selecting the optimal value of model parameters, better results in modeling and drought forecasting are achieved.

Keywords: Computational Intelligence, Neural Network, Kernel, Support Vector Regression

Please cite this article as: Tahermanesh S, Asghari Beirami B, Mokhtarzade M. Analyzing the Efficiency of the Deep Neural Network in Detecting Urban Changes Using Bi-temporal Landsat-8 Images. Journal of RS and GIS for Natural Resources, 14(2): 74-91.