



سجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی (سال سیزدهم / شماره چهارم) زمستان ۱۴۰۱

نمایه شده در سایت: پایگاه استنادی علوم جهان اسلام، جهاد دانشگاهی، مگ ایران، نورمگز، سیویلیکا، گوگل اسکولار
آدرس وب سایت: <http://girs.iaubushehr.ac.ir>



پیش بینی و مدل سازی خشک سالی به روش هیبریدی موجک و الگوریتم های شبکه عصبی

مقاله پژوهشی

جهانبخش محمدی، علیرضا وفایی نژاد، سعید بهزادی، حسین آقامحمدی زنجیر آباد، امیر هومن حمصی

دریافت: ۲۶ آبان ۱۴۰۰ / بازنگری: ۵ دی ۱۴۰۰ / پذیرش: ۱۳ دی ۱۴۰۰

دسترسی اینترنتی: ۱۶ دی ۱۴۰۰ / دسترسی چاپی: ۱۱ دی ۱۴۰۱

چکیده

می دهد. از این رو مدل سازی و پیش بینی خشک سالی از موضوعات مهم و جدی در جوامع علمی است. در گذشته از مدل های ریاضی و آماری مانند روش رگرسیون ساده، خودرگرسیون گیری (AR)، میانگین متحرک (MA) و نیز ARIMA جهت مدل سازی خشک سالی استفاده می شد. در سال های اخیر استفاده از روش های یادگیری ماشین و هوش محاسباتی جهت مدل سازی و پیش بینی خشک سالی بسیار مورد توجه دانشمندان بوده است. از جمله از الگوریتم های هوش محاسباتی که توسط دانشمندان جهت مدل سازی خشک سالی قبلاً مورد توجه قرار گرفته است می توان به شبکه عصبی پرسپترون چندلایه، شبکه عصبی RBF، ماشین بردار پشتیبان، روش های فازی و فازی عصبی اشاره کرد. در این تحقیق هدف مدل سازی و پیش بینی خشک سالی با بهره گیری از سه الگوریتم شبکه عصبی شامل پرسپترون چندلایه، شبکه عصبی RBF و شبکه عصبی رگرسیون تعمیم یافته است. شاخص خشک سالی استفاده شده در این تحقیق شاخص استاندارد شده بارش (SPI) است. در این تحقیق از تکنیک موجک در تلفیق با الگوریتم های شبکه عصبی مصنوعی جهت مدل سازی و پیش بینی خشک سالی در ۱۰ ایستگاه سینوپتیک در کشور ایران (آبادان، بابلسر، بندرعباس، کرمان، مشهد، رشت، سقز، تهران، تبریز و زاهدان) در اقلیم های مختلف و

پیشینه و هدف بحران خشک سالی یک دوره خشک آب و هوایی است که در هر نقطه از جهان و با هر اقلیمی ممکن رخ دهد. این بحران اگرچه به آرامی شروع می شود اما می تواند برای مدتی طولانی تأثیر جدی بر سلامت، محصولات کشاورزی، اقتصاد، انرژی و محیط زیست بگذارد. خشک سالی معیشت و سلامت انسان ها را به شدت تهدید می کند و خطر ابتلا به انواع بیماری ها را افزایش می دهد. **جهانبخش محمدی^۱، علیرضا وفایی نژاد^۲ (✉)، سعید بهزادی^۳، حسین آقامحمدی زنجیر آباد^۴، امیر هومن حمصی^۵**

۱. دانشجوی گروه تخصصی سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، 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 گروه مهندسی منابع طبیعی، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات تهران، دانشگاه آزاد اسلامی، تهران، ایران
- پست الکترونیکی مسئول مکاتبات: a_vafaei@sbu.ac.ir

<https://doi.org/10.30495/GIRS.2022.687669>

<https://dori.net/dor/20.1001.1.26767082.1401.13.4.5.9>

با توزیع مکانی مناسب در کل کشور ایران استفاده شده است.

مواد و روش‌ها در این تحقیق در ابتدا با استفاده از داده‌های بارش ماهانه بین سال‌های ۱۹۶۱ تا ۲۰۱۷ شاخص خشک‌سالی SPI در مقیاس‌های زمانی ۳، ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه از طریق برنامه‌نویسی در محیط نرم‌افزار MATLAB پیاده‌سازی شد. نتایج این مرحله با استفاده از نرم‌افزارهای علمی موجود MDM و Drinc صحت‌سنجی شد. در ادامه با استفاده از زنجیره مارکوف به طراحی مدل‌های پیش‌بینی پرداخته شد. در این تحقیق در مجموع از شش مدل هوش محاسباتی شامل سه مدل منفرد شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی تابع پایه شعاعی (RBF) و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و سه مدل ترکیبی (هیبریدی) موجک با این سه مدل به صورت (WMLP-WRBF-WGRNN) جهت مدل‌سازی و پیش‌بینی شاخص SPI در ۱۰ ایستگاه این تحقیق استفاده شده است. در پیاده‌سازی تمامی این شش مدل از محیط برنامه‌نویسی نرم‌افزار MATLAB استفاده شده است. در این تحقیق ابتدا از چهار نوع موجک گسسته شامل دابیشز (Daubechies)، سیملت (Symlets)، کویفلت (Coiflets) و دوضلعی (Biorthogonal) استفاده شد، به دلیل عملکرد بهتر موجک دابیشز، از این نوع موجک در تحقیق به‌عنوان گزینه نهایی استفاده شد. در موجک دابیشز استفاده شده در بین مرتبه‌های ۱ تا ۴۵، مرتبه ۳ بهترین عملکرد را در بین مقیاس‌های زمانی مختلف SPI از خود نشان داد، به همین دلیل از موجک دابیشز مرتبه ۳ در تمامی مدل‌های ترکیبی این تحقیق استفاده شد. بعد از آموزش همه شش الگوریتم استفاده شده نتایج با معیارهای ارزیابی ضریب تعیین (R^2) و جذر میانگین مربعات خطا (RMSE) جهت اندازه‌گیری اختلاف بین مقادیر واقعی و برآورد شده استفاده شده است.

نتایج و بحث نتایج این تحقیق نشان داد که روش‌های هوش محاسباتی دقت بالایی در مدل‌سازی و پیش‌بینی شاخص خشک‌سالی SPI دارند. در مرحله اول نتایج نشان داد که مدل‌های منفرد MLP، RBF و GRNN در صورتی که به‌طور صحیح آموزش داده شوند نتایجی نزدیک به هم در مدل‌سازی و پیش‌بینی شاخص خشک‌سالی SPI دارند. در مرحله بعد مشاهده شد که تکنیک موجک باعث بهبود نتایج مدل‌سازی خواهد شد. در استفاده از تکنیک موجک در تلفیق با سه مدل منفرد MLP، RBF و GRNN انتخاب نوع موجک نیز در مدل‌سازی بهتر مؤثر است، به‌نحوی که در این تحقیق ابتدا از چهار نوع موجک گسسته دابیشز، سیملت، کویفلت و دوضلعی در تلفیق با

سه مدل منفرد این تحقیق استفاده شد که نتایج این چهار نوع موجک نشان از برتری نسبی موجک دابیشز نسبت به سه موجک دیگر بود. در استفاده از موجک دابیشز نیز از آنجایی این موجک ۴۵ مرتبه دارد و انتخاب مرتبه نیز در مدل‌سازی مؤثر بود با آزمایش ۴۵ مرتبه موجک مشاهده شد که موجک مرتبه ۳ در حالت کلی دارای دقت بالاتری در تمامی مقیاس‌های زمانی شاخص SPI (۳، ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه) و نیز در هر سه الگوریتم MLP، RBF و GRNN دارد. از این رو در این تحقیق از موجک مرتبه سوم دابیشز در هر سه الگوریتم این تحقیق و نیز در همه مقیاس‌های زمانی استفاده شد. نتایج تحقیق نشان داد که تلفیق تکنیک موجک با هر سه مدل MLP، RBF و GRNN باعث بهبود نتایج خواهد شد. نمودارهای تحقیق نشان داد که برای مقیاس زمانی سه‌ماهه مقادیر به‌دست‌آمده از پیش‌بینی مدل منفرد در مدل‌سازی MLP و RBF تا حدودی دارای اختلاف‌فاز یک‌ماهه نسبت به مدل هیبریدی هست، درحالی‌که در مدل GRNN این اختلاف پیش‌بینی کم هست. نتایج مدل‌سازی برای هر دو حالت مدل‌سازی منفرد و هیبریدی بیانگر عدم وجود اختلاف‌فاز بین دو روش مدل‌سازی منفرد و هیبریدی در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ است. برای مقیاس زمانی ۱۲ و ۲۴ ماهه، مدل منفرد GRNN دارای نوسانات و خطای بیشتری در مدل‌سازی و پیش‌بینی ماهانه SPI بوده است درحالی‌که مدل هیبریدی در این دو مقیاس زمانی به‌مراتب رفتار بهتری در مدل‌سازی و پیش‌بینی ماهانه داشته است. نمودارهای پراکنش داده‌های مربوط به SPI مشاهداتی ایستگاه آبادان نشان داد که نتایج مدل‌سازی برای حالت منفرد و هیبریدی در مقیاس‌های زمانی ۳ و ۶ ماهه دقت کمتری نسبت به دیگر مقیاس‌های زمانی دارد و جدایی خط برازش و همچنین میزان عدم قطعیت آن بیشتر است. هرچند در همه مدل‌های شبکه عصبی و در تمامی مقیاس‌های زمانی روش هیبریدی دقت بیشتری از خود نشان داده است. نتایج عددی تحقیق نشان‌دهنده این است که در تمامی SPI ها و ایستگاه‌های مورد مطالعه، مقادیر تفاضلی R^2 مثبت است که بیانگر مقادیر بیشتر R^2 مدل هیبریدی نسبت به مدل‌سازی‌های شبکه عصبی منفرد است که به نحوی نشان‌دهنده بهبود مدل‌سازی هیبریدی نسبت به مدل‌های منفرد است. همچنین مقادیر تفاضلی RMSE نیز در کلیه مدل‌های مورد بررسی و ایستگاه‌های مورد مطالعه منفی است که نشان‌دهنده کمتر بودن مقدار RMSE در پیش‌بینی مدل‌های هیبریدی نسبت به مدل‌های منفرد شبکه عصبی است. در گراف‌های تحقیق دیده می‌شود که مقدار

بهتر شاخص خشک‌سالی SPI لازم است نوع و مرتبه موجک بهینه انتخاب شود. از نتایج این تحقیق می‌توان نتیجه‌گیری کرد که تکنیک موجک تأثیر بیشتری در مقیاس‌های زمانی پایین‌تر یعنی ۳ و ۶ ماهه نسبت به مقیاس‌های بالاتر یعنی ۲۴ و ۴۸ ماهه دارد.

واژه‌های کلیدی: خشک‌سالی، شبکه عصبی، شاخص استاندارد شده بارش (SPI)، شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی تابع پایه شعاعی (RBF)، شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)

اختلاف‌ها در RMSE و R^2 بیانگر میزان اختلاف بیشتر در مقیاس‌های زمانی ۳ و ۶ نسبت به مقیاس‌های زمانی ۱۲، ۱۸، ۲۴ و ۴۸ است که به نحوی به ماهیت داده‌های این مقیاس‌های زمانی برمی‌گردد. به ترتیب بیشترین بهبود در مقدار R^2 و RMSE از مقیاس پایین ۳ ماهه به سمت مقیاس‌های زمانی بالاتر ۴۸ ماهه است.

نتیجه‌گیری از یافته‌های این تحقیق می‌توان نتیجه گرفت که الگوریتم‌های شبکه عصبی مصنوعی روش‌های کارآمدی در مدل‌سازی و پیش‌بینی شاخص خشک‌سالی SPI می‌باشند. همچنین استفاده از موجک در هر سه مدل شبکه عصبی مصنوعی باعث بهبود نتایج خواهد شد. همچنین می‌توان نتیجه گرفت که برای مدل‌سازی

مقدمه

بحران خشک‌سالی یک دوره خشک آب و هوایی است که در هر نقطه از جهان و با هر اقلیمی ممکن است رخ دهد. این بحران اگرچه به آرامی شروع می‌شود اما می‌تواند برای مدتی طولانی تأثیر جدی بر سلامت، محصولات کشاورزی، اقتصاد، انرژی و محیط‌زیست بگذارد. خشک‌سالی معیشت و سلامت انسان‌ها را به شدت تهدید می‌کند و خطر ابتلا به انواع بیماری‌ها را افزایش می‌دهد. خشک‌سالی همچنین باعث مهاجرت اجباری انسان‌ها و به دنبال آن وقوع بحران‌های فراوان در مناطق مهاجرپذیر خواهد شد. هر ساله خشک‌سالی زیان‌های هنگفتی در زمینه زیر بنایی و اقتصادی بر کشورها تحمیل می‌کند. از این رو پایش و مدل‌سازی خشک‌سالی جهت مدیریت این بحران بسیار مهم و حائز اهمیت است (۲۵) و (۲۸). جهت مطالعه خشک‌سالی شاخص‌های مختلفی توسط محققین مورد بررسی قرار گرفته است که هر کدام از این شاخص‌ها جهت مطالعه نوع خاصی از خشک‌سالی است و به شرایط منطقه مورد مطالعه و داده‌های در دسترس بستگی دارد (۲۴). پرکاربردترین شاخص خشک‌سالی مربوط به شاخص‌های استخراج شده از بارش است. شاخص SPI به‌عنوان پرکاربردترین شاخص خشک‌سالی در مطالعات مختلفی مورد بررسی قرار گرفته است (۱، ۲۴ و ۲۵). این شاخص در مقیاس‌های زمانی مختلف محاسبه می‌گردد. رفتار این شاخص در مقیاس‌های زمانی مختلف متفاوت است و بستگی به مقیاس زمانی پیش‌بینی آن با دشواری‌های مختلفی همراه است. مطالعات مختلفی جهت پیش‌بینی و مدل‌سازی خشک‌سالی صورت گرفته است که هدف از این مطالعات برآورد، مدل‌سازی و پیش‌بینی خشک‌سالی در بازه‌های زمانی بدون داده و یا پیش‌بینی برای آینده است. به دلیل رفتار نامشخص بارندگی و غیرخطی بودن آن، استفاده از روش‌های غیرخطی و هوش محاسباتی در مدل‌سازی خشک‌سالی در ده اخیر رشد قابل توجهی داشته است. از جمله این تحقیقات می‌توان به مطالعه ده ژو و همکاران (۲۹) جهت پیش‌بینی

خشک‌سالی در استان هنان در کشور چین اشاره کرد. در این تحقیق از مدل ARIMA و مدل ترکیبی ARIMA-SVR برای پیش‌بینی شاخص خشک‌سالی در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه SPI استفاده شده است. نتایج این تحقیق نشان داد که مدل ترکیبی ARIMA-SVR دارای دقت بالاتری در تمامی مقیاس‌های زمانی نسبت به مدل منفرد ARIMA است و نیز نتایج پیش‌بینی شده ۱ تا ۲ ماه آینده تطابق نسبتاً خوبی با داده‌های واقعی دارد. اوکایا و کورناز (۲۲) به پیش‌بینی خشک‌سالی برای ایستگاه هواشناسی واقع در منطقه مرمره کشور ترکیه پرداختند. در این تحقیق از مدل‌های خودرگرسیون غیرخطی و مدل رگرسیون غیرخطی با ورودی خارجی از نوع شبکه عصبی و نیز مدل ترکیبی با موجک استفاده شد. نتایج این تحقیق حاکی از دقت بالاتر مدل ترکیبی با موجک نسبت به بقیه مدل‌ها بود. عزیمی و اژدری مقدم (۲) به پیش‌بینی کوتاه‌مدت بارندگی با استفاده از مدل شبکه عصبی مصنوعی و مدل طبقه‌بندی فرآیند گوسی با استفاده از شاخص خشک‌سالی SPI در ۳۶۲ ایستگاه سینوپتیک کشور ایران پرداختند. نتایج پیش‌بینی در این تحقیق نشان داد که شاخص «خشک‌سالی ملایم» تندتر از شاخص «خشک‌سالی نزدیک به نرمال» است. در نهایت مناطق جنوبی و شرقی و بخش‌های خاصی از شمال شرق کشور در بازه زمانی ۱۳۸۴ تا ۱۳۹۴ در کلاس‌های هفتم و هشتم قرار گرفتند که نشان‌دهنده خشک‌سالی شدید است. تجزیه و تحلیل دوره ۱۹۹۴-۲۰۱۴ نشان داد که دشت‌های استان سیستان و بلوچستان در منطقه جنوب شرق کشور به میزان قابل توجهی تحت تأثیر خشک‌سالی‌ها قرار گرفته‌اند. به استثنای بخش‌های مرکزی خراسان، مناطق کلی شرق، جنوب شرق و جنوب کشور را می‌توان در درازمدت به‌عنوان کلاس خشک‌سالی مطلق در نظر گرفت. تایلان و همکاران (۲۷) برای مدل‌سازی شاخص خشک‌سالی SPI در چاناک قلعه ترکیه از روش‌های هوش محاسباتی استفاده کردند. در این تحقیق ابتدا شاخص SPI در مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه با استفاده از سه مدل SVM، ANFIS و شبکه عصبی مصنوعی مدل‌سازی شد. در ادامه با استفاده از تکنیک موجک

نویز، استخراج رفتار کلی و مطالعه هم‌زمان محتویات فرکانس- زمان سری زمانی مورد استفاده قرار می‌گیرد (۵ و ۲۶). تمامی تحقیق‌های صورت‌گرفته، بر کارایی روش‌های هوش محاسباتی از جمله انواع شبکه‌های عصبی مصنوعی و نیز تبدیل موجک جهت مدل‌سازی و پیش‌بینی پدیده‌های مختلف از جمله خشک‌سالی دارد. لازم به ذکر است در خصوص مدل‌سازی و پیش‌بینی خشک‌سالی با استفاده از شاخص SPI، با روش‌های MLP، GRNN و RBF در ترکیب با تکنیک موجک مطالعات مشخصی انجام‌نشده است. در این پژوهش از تلفیق سه روش هوش محاسباتی مبتنی بر شبکه عصبی که شامل شبکه عصبی پرسپترون چندلایه، شبکه عصبی تابع پایه شعاعی و شبکه عصبی رگرسیون تعمیم‌یافته با آنالیز موجک جهت مدل‌سازی رفتار SPI استفاده شده است. در بخش‌های بعدی ابتدا به بررسی منطقه مورد مطالعه و ایستگاه‌های سینوپتیک مورد استفاده پرداخته می‌شود. سپس توضیحی در خصوص شاخص SPI و نحوه استخراج آن از داده‌های بارندگی پرداخته می‌شود. در ادامه به بررسی مبانی ریاضی روش موجک و روش‌های مبتنی بر شبکه عصبی جهت مدل‌سازی شاخص SPI پرداخته می‌شود.

منطقه مورد مطالعه و داده‌های مورد استفاده

ایران از نظر اقلیمی عمدتاً کشوری خشک و نیمه‌خشک است که عمده اقلیم ایران متأثر از رشته‌کوه البرز، زاگرس و همچنین دشت‌های کویر در مرکز ایران هست (۲۱ و ۲۵). در این تحقیق از داده‌های بارش ۱۰ ایستگاه سینوپتیک آبادان، بابلسر، بندرعباس، کرمان، مشهد، رشت، سقز، تهران، تبریز و زاهدان جهت استخراج شاخص SPI مورد استفاده قرار گرفته است. دلیل استفاده از این ۱۰ ایستگاه داشتن ۵۶ سال داده بارش ماهانه در زمان انجام تحقیق و نیز توزیع مکانی مناسب این ۱۰ ایستگاه در کل کشور ایران و قرار گرفتن این ۱۰ ایستگاه در مناطقی با اقلیم‌های گوناگون است. در شکل ۱ موقعیت ایستگاه‌ها به همراه نقشه ایران نمایش داده شده است.

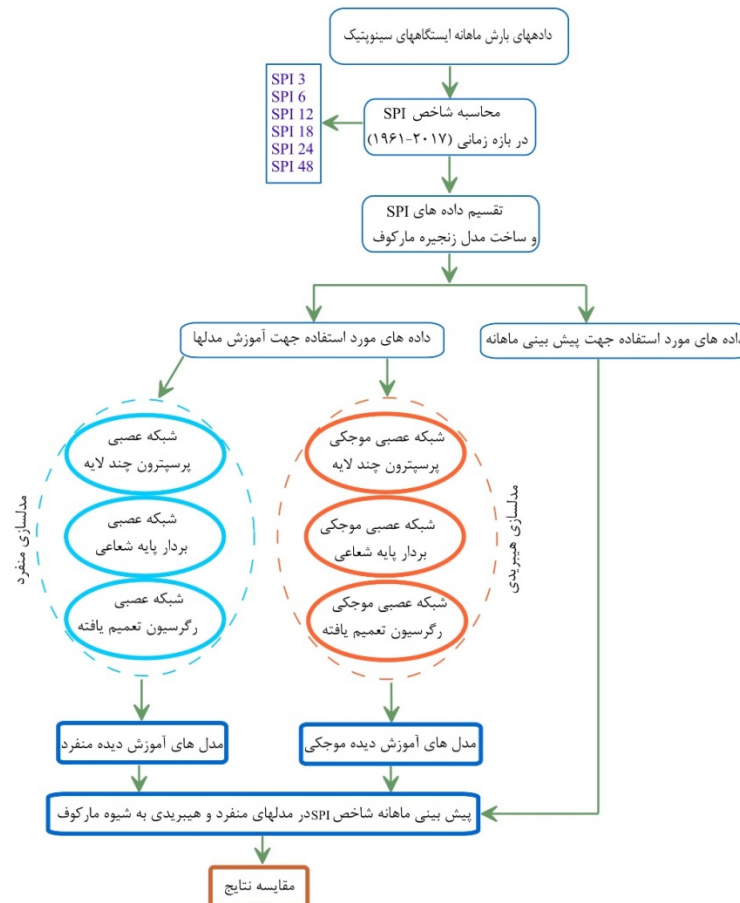
سیگنال‌های SPI تجزیه و دوباره از سه الگوریتم تحقیق جهت مدل‌سازی دوباره شاخص SPI استفاده شد. نتایج این تحقیق نشان داد که مدل‌های ترکیبی توسعه‌یافته با استفاده از تکنیک پیش‌پردازش (موجک) بهتر عمل می‌کنند. در بین این مدل‌ها مشاهده شد که مدل W-ANFIS (ترکیب موجک با ANFIS) بهترین نتایج را برای دوره ۶ ماهه ارائه می‌دهد. کماسی و شرقی (۱۳) به پیش‌بینی خشک‌سالی با استفاده از موجک - ماشین بردار پشتیبان و شاخص استاندارد بارش در دریاچه ارومیه-ایران پرداختند. در این تحقیق سری زمانی SPI حوضه آبخیز دریاچه ارومیه با تبدیل موجک به سری‌های زمانی مکرر متعدد تجزیه شد. سپس این سری‌های زمانی به‌عنوان داده‌های ورودی به مدل ماشین بردار پشتیبان (SVM) برای پیش‌بینی خشک‌سالی اعمال شدند. نتایج این تحقیق نشان داد که مدل ترکیبی پیشنهادی (موجک با ماشین بردار پشتیبان) نسبتاً مناسب‌تر از مدل‌های خود رگرسیون کلاسیک مانند ANN است. فرومندی و همکاران (۵) به چرایی افت سطح آب دریاچه ارومیه با استفاده از تکنیک‌های سنجش‌ازدور، شبکه‌های عصبی مصنوعی، تبدیل موجک و آزمون‌های روند من-کندال پرداختند. نتایج این تحقیق نشان داد که افزایش روزافزون کشاورزی در شرایطی که بارندگی افزایش نیافته، باعث کاهش رواناب ورودی به دریاچه شده و دبی کمتر باقی‌مانده برای تثبیت سطح آب کافی نیست. سری زمانی دما نیز روند مثبت قابل‌توجهی را تجربه کرده است که تغییر سطح آب را تشدید کرده است. نتایج این تحقیق حاکی از بهبود نتایج به دلیل استفاده از تبدیل موجک بود. محمود زاده و عزیز مرادی (۱۸) 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. تکنیک موجک به‌عنوان یکی از روش‌های قوی چند ریزه‌سازی با فیلتر کردن و تجزیه سری زمانی به دو بخش فرکانس بالا و پایین جهت حذف

روش تحقیق

در این تحقیق از تلفیق روش موجک و سه الگوریتم شبکه عصبی پرسپترون چندلایه، شبکه عصبی تابع پایه شعاعی و شبکه عصبی رگرسیون تعمیم یافته که مبتنی بر شبکه عصبی می باشند جهت مدل سازی سری زمانی SPI استفاده شده است. همان طور که در فلوجارت شکل ۲ دیده می شود ابتدا شاخص SPI از داده های بارندگی ایستگاه های هواشناسی استخراج می گردد و در مرحله بعد مقادیر سری زمانی SPI به دسته آموزشی و ارزیابی تقسیم بندی می گردند. از مقادیر سری زمانی آموزشی SPI جهت برآورد پارامترهای مدل های مورد استفاده قرار می گیرد و با استفاده از مقادیر ارزیابی در زمان های مورد نظر مقادیر SPI به شیوه زنجیره مارکوف و ماهانه پیش بینی می گردند.



شکل ۱. موقعیت ایستگاه های سینوپتیک مورد مطالعه در این تحقیق
Fig. 1. The synoptic stations position in the study area



شکل ۲. فلوجارت روند انجام مراحل پژوهش


Fig. 2. The research process Flowchart

شاخص بارش استاندارد شده

مکی و همکاران (۱۹) شاخص بارش استاندارد شده را برای اولین بار در مقیاس‌های زمانی مختلف جهت مدل‌سازی احتمالاتی بارش ارائه دادند. این شاخص به‌عنوان یکی از شاخص‌های اصلی در مدل‌سازی خشک‌سالی مورد توجه محققین مختلفی قرار گرفته است (۱، ۲، ۳، ۱۱، ۱۵، ۲۴، ۲۸ و ۲۹). جهت محاسبه شاخص SPI در این تحقیق از محیط برنامه‌نویسی نرم‌افزار MATLAB استفاده شد و نتایج این پیاده‌سازی با نرم‌افزارهای علمی موجود مانند MDM Drinc و (<https://agrimetsoft.com/mdm.aspx>) و (<https://drought-software.com/download>) صحت‌سنجی شد. در این مطالعه مقدار شاخص SPI بر اساس روابط بیان‌شده در (۱۹) برای سری زمانی بارش ۱۰ ایستگاه نام‌برده شده در بخش‌های قبل محاسبه و به‌عنوان ورودی مدل‌های مورد مطالعه در این پژوهش در نظر گرفته شده است.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک ابزار محاسباتی است که در حوزه هوش محاسباتی قرار می‌گیرد. این ابزارها منشأ الهامشان دستگاه‌های بیولوژیکی و دستگاه‌های طبیعی هستند. در واقع دانشمندان با مطالعه و توصیف ریاضی این دستگاه‌های طبیعی دست به توسعه بلوک‌های محاسباتی مانند شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک، منطق فازی نائل شده‌اند که این بلوک‌های محاسباتی را تحت عنوان هوش محاسباتی می‌شناسیم. خاصیت مهم و برجسته همه این بلوک‌های محاسباتی الهام گرفتن از طبیعت است. پیاده‌سازی چنین الگویی در طراحی شبکه‌های عصبی مصنوعی به مفهوم به‌کارگیری تعداد نورون‌های مصنوعی به میزان حداقل خود جهت تبادل اطلاعات لازم است؛ که در این صورت به یک ساختار بهینه دست‌یافته‌ایم. ابتدا باید شبکه‌های عصبی مصنوعی را آموزش داد و سپس بر اساس آموزش‌دیده شده پیش‌بینی و مدل‌سازی صورت می‌گیرد (۴ و ۲۵). در شکل زیر ساختار یک نورون مصنوعی آمده است.



شکل ۳. نمایش ساختار نورون مصنوعی به همراه داده‌های ورودی و خروجی و تابع انتقال‌دهنده آن

Fig. 3. Artificial neurons with input and output data and its transmitter function

شبکه عصبی رگرسیونی تعمیم‌یافته

شبکه عصبی مصنوعی که مدل GRNN حالت خاصی از آن است، یک تکنیک مدل‌سازی غیرخطی است که برای مدل‌سازی در طیف وسیعی از پدیده‌ها مناسب است. شبکه‌های عصبی مصنوعی قادر به شناسایی یک رابطه غیرخطی پیچیده بین مجموعه داده‌های ورودی و خروجی هستند.

واحدهای اصلی عملکرد آن‌ها از نورون‌ها تشکیل شده است (۴). شبکه عصبی GRNN نخستین بار در سال ۱۹۹۱ توسط اسپکت معرفی شد. معماری این شبکه در شکل ۴ آمده است که شامل چهار لایه ورودی، الگو، جمع و لایه خروجی است (۱۹).

است. برای یک بردار ورودی X ، خروجی GRNN مطابق رابطه ۳ محاسبه می‌شود.

$$Y(X) = \frac{S}{D} = \frac{\sum_{i=1}^n Y_i \exp\left(-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right)} \quad [3]$$

در شبکه عصبی GRNN پارامتر σ تنها پارامتر قابل تنظیم است که مقدار آن در این پژوهش از طریق سعی و خطا محاسبه شد.

شبکه عصبی پرسپترون چندلایه

متداول‌ترین مدل شبکه‌های عصبی مصنوعی مورد استفاده برای مدل‌سازی و پیش‌بینی شبکه عصبی پرسپترون چندلایه است که از سه لایه تشکیل شده است: لایه اول ورودی، آخرین لایه خروجی و لایه پنهان میانی. در شبکه‌های پیش‌خور (شکل ۵)، هر پارامتر ورودی (a_i) در وزن مربوطه (w_{ij}) ضرب شده و با یک بایاس به فرم رابطه ۴ جمع می‌شود (۱۷).

$$X = \left(\sum_{i=1}^n w_{ij} a_i \right) + b_j \quad [4]$$

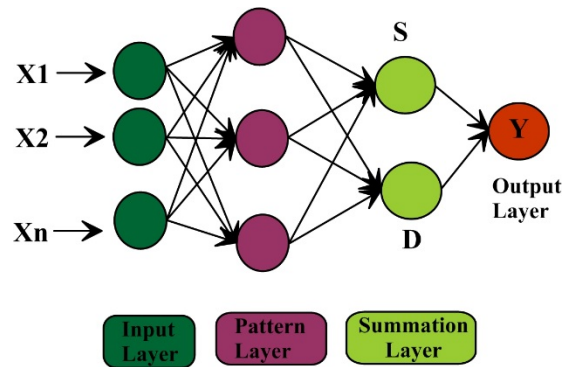
رابطه ۴ پس از عبور از تابع انتقال (فعال‌سازی) خروجی شبکه عصبی پرسپترون چندلایه را مطابق رابطه ۵ تولید می‌کند.

$$F(X) = F\left[\left(\sum_{i=1}^n w_{ij} a_i\right) + b_j\right] \quad [5]$$

توابع tansig و logsig از مشهورترین توابع انتقال در لایه پنهان می‌باشند (۳۰). تابع انتقال logsig به صورت رابطه ۶ و تابع انتقال tansig به صورت رابطه ۷ بیان می‌شود.

$$F(X) = \frac{1}{1 + e^{-X}} \quad [6]$$

$$F(X) = \frac{e^X - e^{-X}}{e^X + e^{-X}} \quad [7]$$



شکل ۴. نمایش ساختار شبکه عصبی رگرسیون تعمیم‌یافته
Fig. 4. Generalized regression neural network structure


GRNN حالتی از شبکه عصبی پایه شعاعی (RBF) است که به روش آموزش تکراری مانند ANN نیاز ندارد (۸). در عوض، GRNN قادر به تقریب هر رابطه بین بردارهای ورودی و خروجی است و تابع را مستقیماً از مجموعه داده آموزشی تخمین می‌زند (۱۱). GRNN به عنوان ابزار قدرتمندی جهت تحلیل رگرسیون غیرخطی مورد استفاده قرار می‌گیرد. در شبکه عصبی GRNN استفاده شده در این تحقیق لایه ورودی، اطلاعات را جمع‌آوری کرده و به لایه الگو ارسال می‌کند. لایه الگو برای انجام خوشه‌بندی در فرآیند آموزش استفاده می‌شود. سپس خروجی لایه الگو از لایه جمع‌بندی عبور می‌کند. این لایه فقط از دو نورون تشکیل شده است که نورون اول و دوم را به ترتیب S جمع و D جمع گویند. نورون S جمع مجموع خروجی‌های وزنی لایه الگو را محاسبه می‌کند در حالی که نورون D جمع خروجی‌های وزن نشده نورون‌های الگو را محاسبه می‌کند. این دو نورون در لایه جمع از رابطه‌های ۱ و ۲ محاسبه می‌شوند (۶ و ۱۲).

$$S = \sum_{i=1}^n Y_i \exp\left(-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right) \quad [1]$$


$$D = \sum_{i=1}^n \exp\left(-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right) \quad [2]$$

در روابط فوق Y_i وزنی است که نورون i ام در لایه الگو را به لایه جمع متصل می‌کند که در آن σ پارامتر هموارسازی

در این تحقیق از یک شبکه پرسپترون با یک لایه پنهان با ۳ نورون و تابع انتقال tansig و لایه خروجی با یک نورون و تابع انتقال خطی استفاده شده است. کلیه مراحل ورودی داده، ساخت شبکه عصبی MLP، آموزش شبکه عصبی و محاسبه نتایج در محیط نرم افزار MATLAB پیاده سازی شده است. معماری شبکه MLP استفاده شده در این تحقیق در شکل ۶ آمده است.



شکل ۵. نمایش ساختار شبکه عصبی پرسپترون چندلایه
Fig. 5. Multilayer perceptron neural network structure



شکل ۶. ساختار شبکه عصبی پرسپترون چندلایه استفاده شده در این تحقیق
Fig. 6. The structure of the multilayer perceptron neural network used in this research

شبکه عصبی تابع پایه شعاعی

شبکه عصبی تابع پایه شعاعی به عنوان یک شبکه سه لایه که شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی بیان می شود (شکل ۷). توابع RBF به عنوان توابع پایه و اساس شبکه های عصبی تابع پایه شعاعی به شمار می رود که گروهی از شبکه های عصبی به نام شبکه های عصبی آماری را تشکیل می دهد (۹). لایه ورودی شامل داده های ورودی است و لایه پنهان نیز داده ها را با استفاده از یک تابع غیرخطی از فضای ورودی به فضای پنهان می برد. لایه خروجی که یک لایه خطی است، پاسخ شبکه را ارائه می دهد (۱۶). در ساختار شبکه عصبی تابع پایه شعاعی داده ورودی X یک بردار n بعدی است که به هر نورون لایه پنهان منتقل می شود. تابع فعال سازی نورون های لایه پنهان در فضای ورودی متقارن است و خروجی هر نورون لایه پنهان تنها به فاصله شعاعی بین بردار ورودی X و مرکز نورون لایه پنهان بستگی دارد. خروجی هر نورون لایه پنهان از رابطه ۸ محاسبه می شود.

$$h_j(x) = \phi(\|x - c_j\|) \quad j = 1, 2, \dots, J \quad [8]$$

که $\| \cdot \|$ نرم اقلیدسی، c_j مرکز هر نورون در لایه پنهان و $\phi_j(x)$ تابع فعال ساز است که یک تابع غیرخطی است و شامل انواع مختلفی از توابع مانند توابع گاوسی، چهارگانه، اسپیلاین و نمایی است. تابع گاوسی از جمله مرسوم ترین توابع فعال ساز است که در لایه پنهان استفاده می شود. تابع فعال سازی گاوسی را می توان به صورت رابطه ۹ نوشت (۱۶).


$$\phi_j(x) = \exp\left[-\frac{(\|x - c_j\|^2)}{2\rho^2}\right] \quad [9]$$

در رابطه ۹ بردار x داده های آموزشی و ρ عرض تابع گاوسی است. هر نورون لایه پنهان با یک مرکز و یک عرض تنظیم می شود. معمولاً وزن های متصل کننده واحدهای مخفی و خروجی با استفاده از روش حداقل میانگین مربع تخمین زده

که در رابطه ۱۰ مقدار تابع $\phi_j(x)$ پاسخ زامین نوروں لایه پنهان، وزن اتصال بین زامین نوروں لایه پنهان و k امین نوروں لایه خروجی و نیز w_0 ترم بایاس است. تنظیم عرض تابع فعال‌ساز گاوسی (ρ) لایه پنهان پارامتر مهمی است که بسیار در نتایج مدل‌سازی شبکه عصبی RBF تأثیرگذار است که در این تحقیق به صورت تجربی محاسبه گردیده است.

می‌شود. در نهایت k امین خروجی شبکه از رابطه ۱۰ محاسبه می‌شود (۱۶).

$$\hat{y}_k = w_0 + \sum_{j=1}^M w_{jk} \phi_j(x) \quad [10]$$



شکل ۷. نمایش ساختار شبکه عصبی تابع پایه شعاعی

Fig. 7. Radial base function neural network structure

در رابطه ۱۲ علامت * نماد مزدوج مختلط a, b, t به ترتیب پارامترهای مقیاس، انتقال و زمان هستند (۷، ۱۰ و ۲۰). محاسبه ضرایب CWT باعث افزایش زمان محاسبات و تولید حجم زیاد ضرایب می‌شود. با توجه به گسسته بودن داده‌های ورودی، در این تحقیق از روش تبدیل موجک گسسته (DWT) جهت تجزیه سری‌های زمانی SPI استفاده شده است. DWT به صورت رابطه ۱۳ تعریف می‌شود.

تبدیل موجک

تبدیل موجک (ویولت) یک تابع ریاضی است که توانایی بالایی در استخراج ویژگی سری‌های زمانی دارد. این ابزار می‌تواند سری‌های زمانی را به مؤلفه‌های فرکانسی آن‌ها تجزیه کند تا بر ضعف روش‌های داده محور در مواجهه با سری‌های زمانی غیرایستا غلبه کند تبدیل موجک به دو صورت تبدیل موجک پیوسته و تبدیل موجک گسسته انجام می‌شود (۷ و ۱۰). ضرایب تبدیل موجک پیوسته (CWT) از رابطه ۱۱ محاسبه می‌شود. در این رابطه موجک مادر از رابطه ۱۲ محاسبه می‌گردد.

$$W_f(j, k) = \int_{-\infty}^{+\infty} f(t) \psi_{j,k}^*(t) dt \quad [13]$$

$$\psi_{j,k}(t) = a_0^{-j/2} \psi(a_0^{-j} t - b_0 k) \quad [14]$$

که در روابط فوق a_0 و b_0 ثابت، j سطح تجزیه و k فاکتور زمان انتقال است (۳۰). تبدیل موجک از خانواده بزرگی تشکیل شده است که در حالت کلی به دودسته پیوسته و گسسته تقسیم‌بندی می‌شود. در این تحقیق ابتدا از چهار نوع

$$W_f(a, b) = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}^*(t) dt \quad [11]$$

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R, a \neq 0 \quad [12]$$

مدل‌های هیبریدی این تحقیق استفاده شد، در ادامه مقادیر RMSE و R^2 برای موجک‌های مادر دابیشز از مرتبه ۱ تا ۴۵ مورد بررسی قرار گرفت که نتایج بیانگر بهینه بودن مقدار موجک مادر دابیشز مرتبه سوم نسبت به دیگر مرتبه‌ها در کلیه مدل‌سازی‌ها بود و در این پژوهش از موجک مادر دابیشز مرتبه سوم استفاده گردید. با توجه به تعداد زیاد نمودار خروجی، در این تحقیق صرفاً نمودارهای سری زمانی و پراکنش داده‌های مربوط به پیش‌بینی ماهانه ایستگاه آبادان نمایش داده شده است. شکل ۸، ۹ و ۱۰ به ترتیب نتایج مربوط به پیش‌بینی ماهانه مقادیر SPI مربوط به ایستگاه آبادان را برای مدل‌سازی به روش MLP، GRNN و RBF را به صورت منفرد و همچنین به صورت هیبریدی و تلفیق با موجک نشان می‌دهد. این نمودارها شامل سری زمانی پیش‌بینی ماهانه SPI در مقیاس‌های زمانی ۳، ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه است. همان‌طور که در این اشکال دیده می‌شود سری زمانی داده‌های SPI مشاهداتی (محاسبه شده از داده‌های بارش ایستگاه سینوپتیک) با ستاره سیاه‌رنگ، مقادیر پیش‌بینی ماهانه به روش ترکیبی موجک و روش‌های شبکه عصبی با خط قرمز رنگ همچنین مقادیر مدل‌سازی شده به روش الگوریتم‌های شبکه عصبی منفرد با خط آبی‌رنگ نمایش داده شده است. همان‌طور که در اشکال ۸ تا ۱۰ دیده می‌شود برای مقیاس زمانی سه‌ماهه مقادیر به دست آمده از پیش‌بینی مدل منفرد در مدل‌سازی MLP و RBF تا حدودی دارای اختلاف فاز یک‌ماهه نسبت به مدل هیبریدی هست، در حالی که در مدل GRNN این اختلاف پیش‌بینی کم هست. نتایج مدل‌سازی برای هر دو حالت مدل‌سازی منفرد و هیبریدی بیانگر عدم وجود اختلاف فاز بین دو روش مدل‌سازی منفرد و هیبریدی در مقیاس‌های زمانی ۶، ۱۲، ۱۸، ۲۴ و ۴۸ است. برای مقیاس زمانی ۱۲ و ۲۴ ماهه، مدل منفرد GRNN دارای نوسانات و خطای بیشتری در مدل‌سازی و پیش‌بینی ماهانه SPI بوده است در حالی که مدل هیبریدی در این دو مقیاس زمانی به مراتب رفتار بهتری در مدل‌سازی و پیش‌بینی ماهانه داشته است. در حالت کلی

موجک گسسته شامل دابیشز (Daubechies)، سیملت (Symlets)، کویفلت (Coiflets) و دوضلعی (Biorthogonal) استفاده شد، به دلیل عملکرد بهتر موجک دابیشز، از این نوع موجک در تحقیق به عنوان گزینه نهایی استفاده شد. در موجک دابیشز استفاده شده در بین مرتبه‌های ۱ تا ۴۵، مرتبه ۳ بهترین عملکرد را در بین مقیاس‌های زمانی مختلف SPI از خود نشان داد، به همین دلیل از موجک دابیشز مرتبه ۳ در تمامی مدل‌های ترکیبی این تحقیق استفاده شد.

زنجیره مارکوف

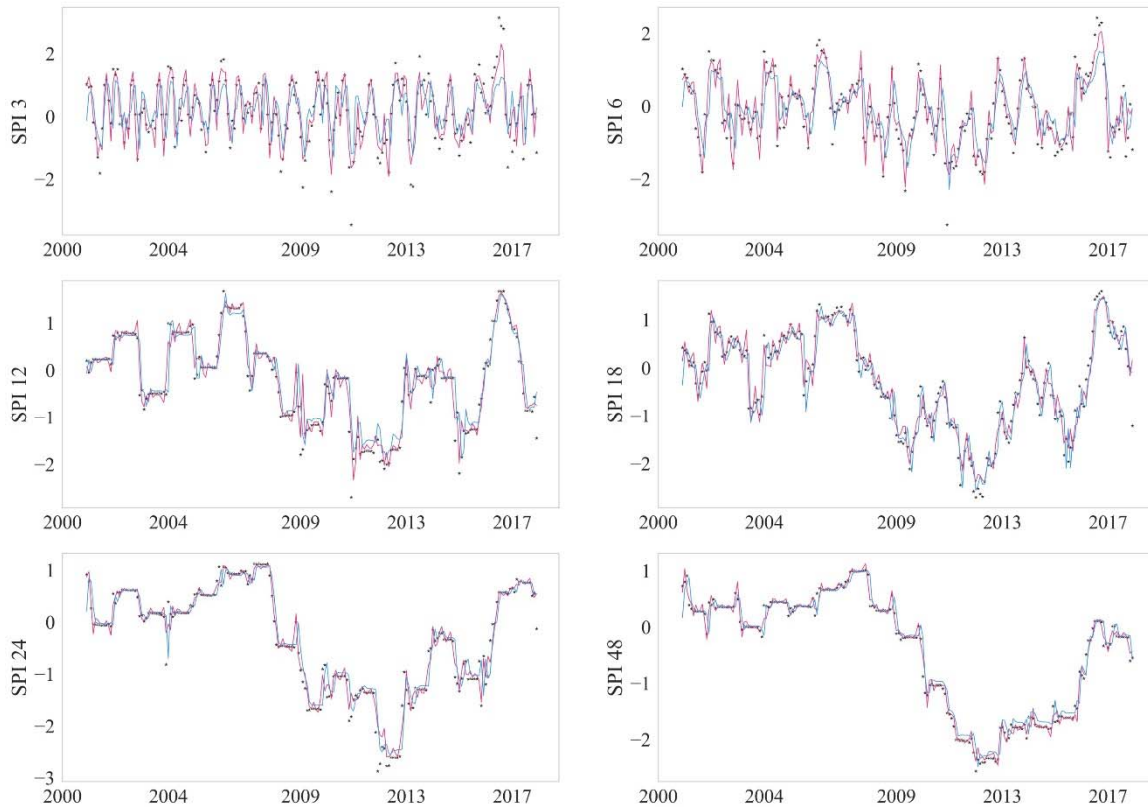
مدل زنجیره مارکوف رویکردی ریاضی جهت ساخت مدل‌های سری‌های زمانی پدیده‌های تصادفی است (۲۳). وابستگی این زنجیره به زمان یا از طریق ضرایب همبستگی و یا با استفاده از ماتریس‌های احتمالاتی انتقال بیان می‌شود (۱۴). مدل زنجیره مارکوف مرتبه اول اصلی‌ترین شکل مدل زنجیره مارکوف هست که در واقع با داشتن چند مرحله و گام عقب‌تر یک پدیده می‌توان یک مرحله جلوتر را پیش‌بینی کرد که در این پژوهش همانند برخی پژوهش‌های انجام شده جهت پیش‌بینی خشک‌سالی (۱۴ و ۲۳) از سه مرحله متوالی SPI جهت پیش‌بینی یک مرحله جلوتر استفاده شده است.

نتایج

همان‌طور که در بخش روش تحقیق بیان شد ابتدا مقادیر سری زمانی SPI برای ایستگاه‌های منطقه مورد مطالعه استخراج گردید و سپس داده‌های SPI به دو بخش آموزشی مدل (جهت استخراج پارامترهای مدل‌سازی) و بخش پیش‌بینی ماهانه تقسیم‌بندی گردید. جهت انتخاب موجک مادر بهینه برای تمامی مدل‌های هیبریدی مورد مطالعه در این پژوهش و ایستگاه‌های مورد نظر، مقادیر RMSE و R^2 ابتدا برای چهار نوع موجک دابیشز، سیملت، کویفلت و دوضلعی محاسبه شد. نتایج استفاده از این چهار نوع موجک حاکی از عملکرد بهتر موجک دابیشز بود به همین دلیل از موجک دابیشز در تمامی

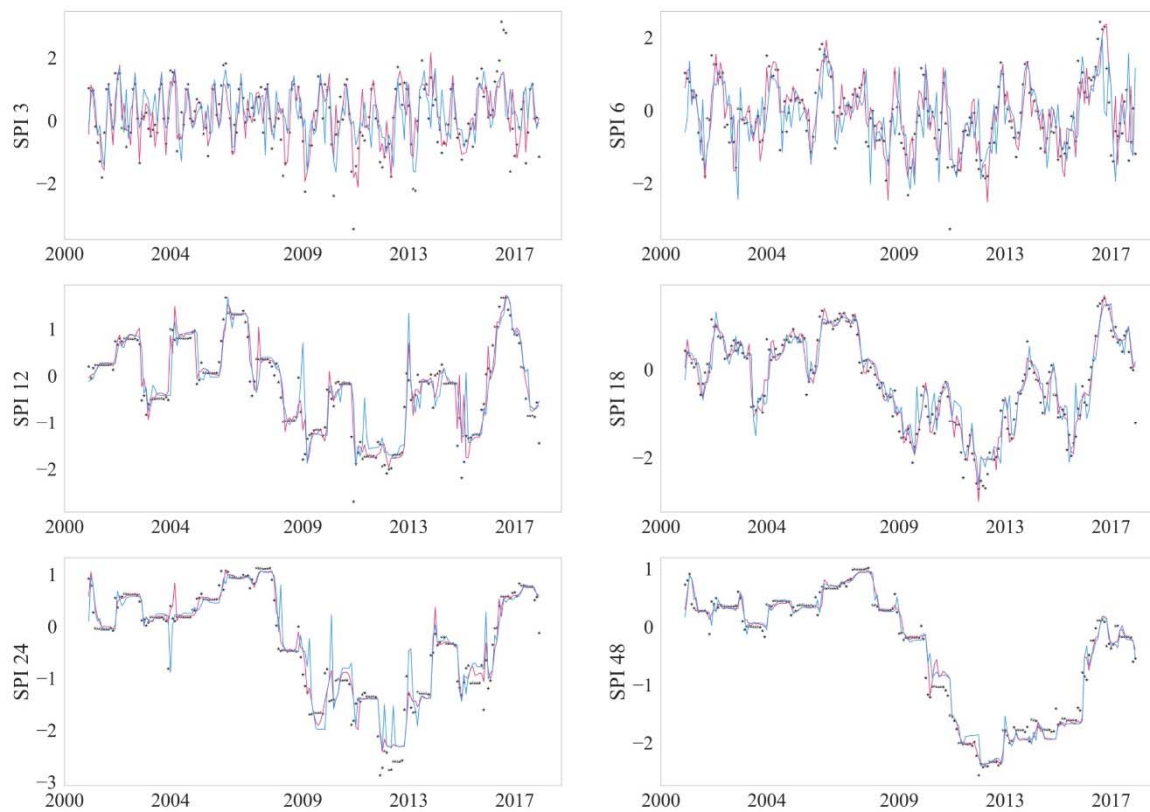
سبز بیانگر محور ۴۵ درجه جهت مقایسه بصری نتایج مدل‌ها نسبت به حالت ایدئال است. همان‌طور که در شکل‌های ۱۱ تا ۱۳ دیده می‌شود نتایج مدل‌سازی برای حالت منفرد و هیبریدی در مقیاس‌های زمانی ۳ و ۶ ماهه دقت کمتری نسبت به دیگر مقیاس‌های زمانی دارد و جدایی خط برازش و همچنین میزان عدم قطعیت آن (پهنای خط برازش بیانگر میزان عدم قطعیت است) نسبت به خط ۴۵ درجه (حالت ایدئال) بیشتر است. هرچند در همه مدل‌های شبکه عصبی و در تمامی مقیاس‌های زمانی روش هیبریدی دقت بیشتری از خود نشان داده است.

می‌توان رفتار هموارتری از مدل‌های هیبریدی در بیش بینی نسبت به مدل‌های منفرد شبکه‌های عصبی در رفتار سری زمانی مشاهده کرد. شکل‌های ۱۱، ۱۲ و ۱۳ نشان‌دهنده پراکنش داده‌های مربوط به SPI مشاهداتی ایستگاه آبادان مربوط به مدل‌های شبکه عصبی منفرد و هیبریدی (محور افقی SPI مشاهداتی) و مقادیر پیش‌بینی شده داده‌های SPI با استفاده از مدل منفرد و مدل هیبریدی (محور قائم). نقاط قرمز و خط برازش داده‌شده قرمز رنگ مربوط به مدل هیبریدی نقاط آبی و خط برازش داده‌شده آبی رنگ مربوط به مدل منفرد است. خط



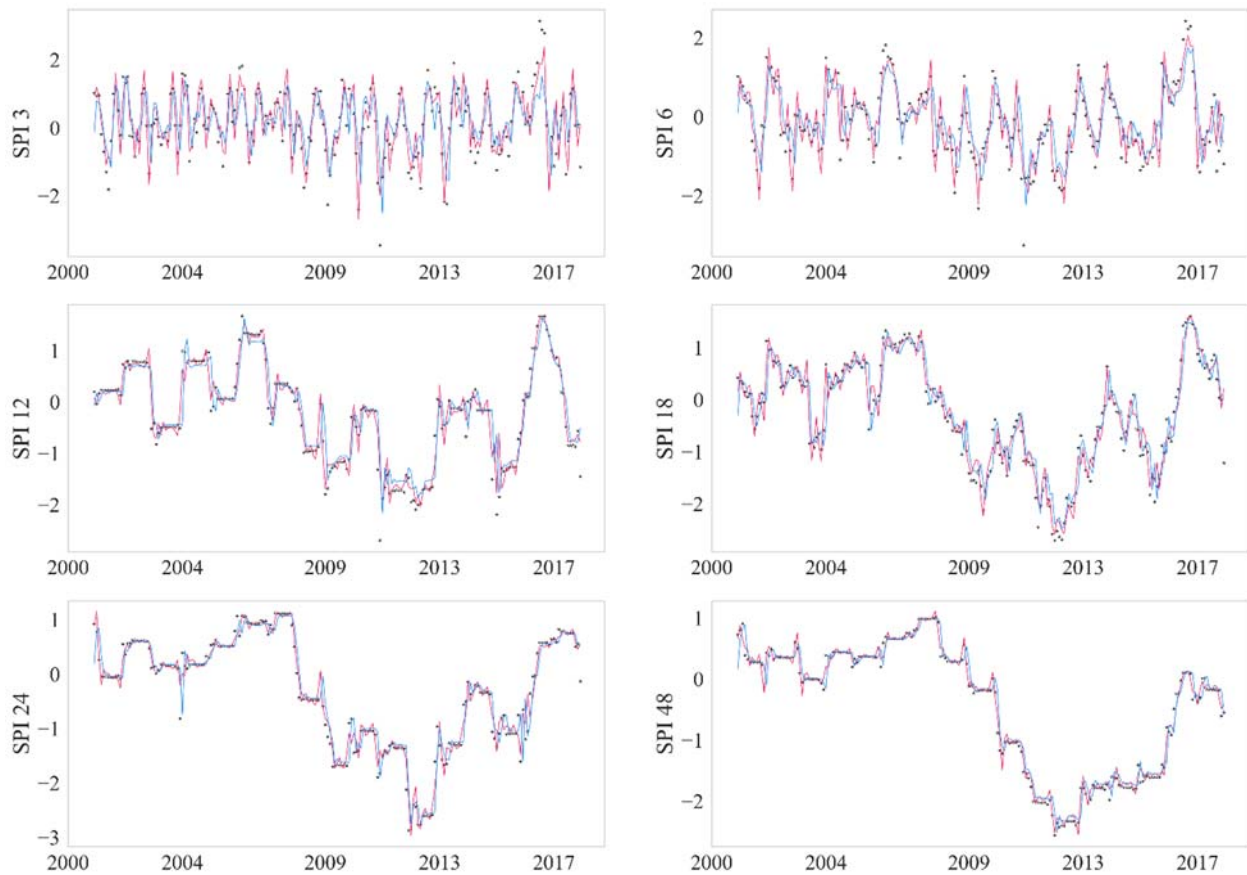
شکل ۸. نمایش سری زمانی SPI ایستگاه آبادان مربوط به داده‌های مشاهداتی (ستاره سیاه‌رنگ) - مدل‌سازی با مدل ترکیبی موجک و مدل هوش محاسباتی (نمودار قرمز رنگ) - مدل‌سازی با الگوریتم هوش محاسباتی MLP (نمودار آبی رنگ)

Fig. 8. SPI time series of Abadan station. Observational data (black star), combined of wavelet and MLP (red diagram), MLP (blue diagram)



شکل ۹. نمایش سری زمانی SPI ایستگاه آبادان مربوط به داده‌های مشاهداتی (ستاره سیاه‌رنگ) - مدل‌سازی با مدل ترکیبی موجک و مدل‌های هوش محاسباتی (نمودار قرمز رنگ) - مدل‌سازی با الگوریتم‌های هوش محاسباتی GRNN (نمودار آبی رنگ)


Fig. 9. SPI time series of Abadan station. Observational data (black star), combined of wavelet and GRNN (red diagram), GRNN (blue diagram)



شکل ۱۰. نمایش سری زمانی SPI ایستگاه آبادان مربوط به داده‌های مشاهداتی (ستاره سیاه‌رنگ) - مدل‌سازی با مدل ترکیبی موجک و

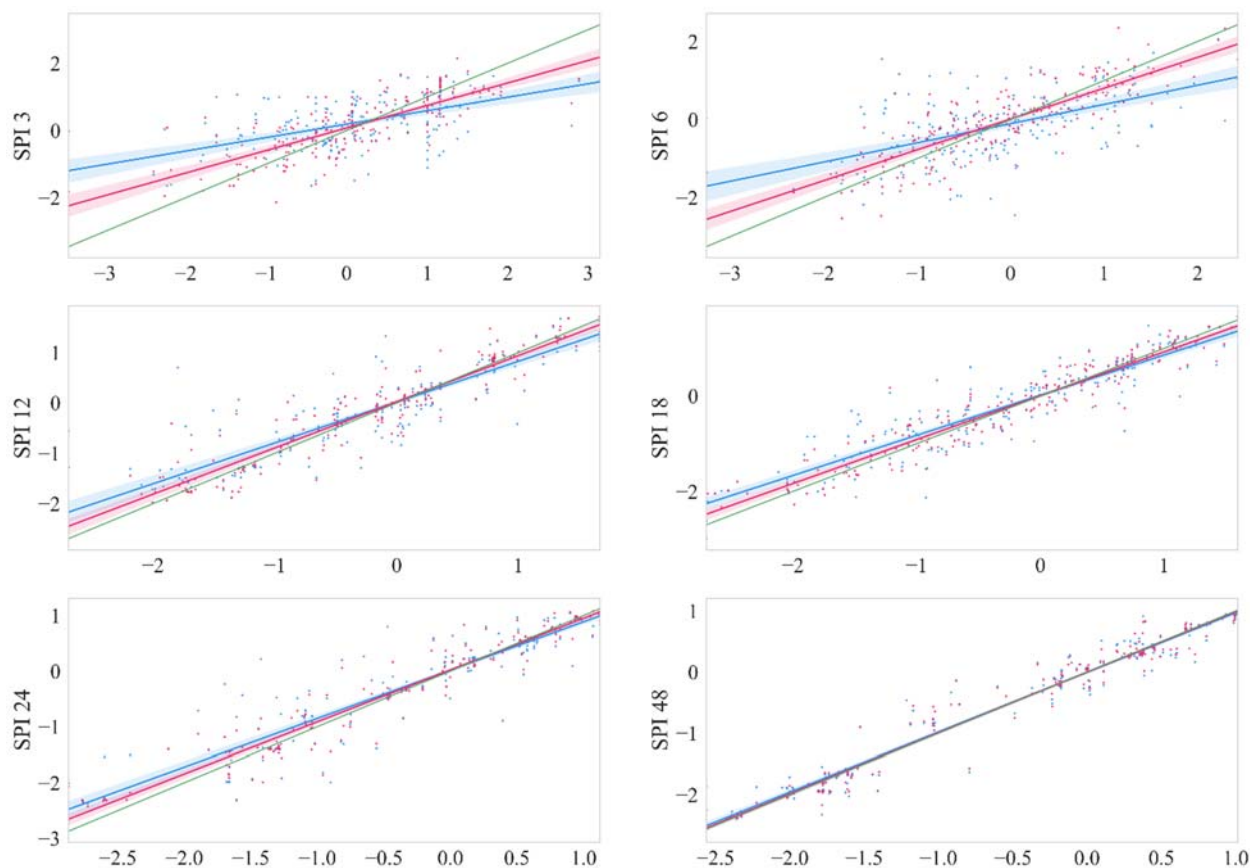
مدل‌های هوش محاسباتی (نمودار قرمز رنگ) - مدل‌سازی با الگوریتم‌های هوش محاسباتی RBF (نمودار آبی رنگ)

Fig. 10. SPI time series of Abadan station. Observational data (black star), combined of wavelet and RBF (red diagram), RBF (blue diagram)




شکل ۱۱. نمودار پراکنش داده‌های SPI مشاهداتی ایستگاه آبادان مربوط به مدل منفرد و هیبریدی (محور افقی SPI مشاهداتی) و مقادیر پیش‌بینی شده داده‌های SPI با استفاده از مدل منفرد و مدل هیبریدی (محور قائم). نقاط قرمز و خط برازش داده‌شده قرمز رنگ مربوط به مدل هیبریدی و نقاط آبی و خط برازش داده‌شده آبی رنگ مربوط به مدل منفرد است. خط سبز بیانگر محور ۴۵ درجه جهت مقایسه بصری نتایج مدل‌ها نسبت به حالت ایدئال است.

Fig. 11. Observation of SPI data in Abadan station. Scatter plot of single and hybrid MLP model. Horizontal axis is observed SPI and the vertical axes is predicted values of SPI by using single model (blue point and regression line), hybrid model (red point and regression line). The 45° ideal line regression is drawn in green.



شکل ۱۲. نمودار پراکنش داده‌های SPI مشاهده‌ای ایستگاه آبادان مربوط به مدل منفرد و هیبریدی (محور افقی SPI مشاهده‌ای) و مقادیر پیش‌بینی شده داده‌های SPI با استفاده از مدل منفرد و مدل هیبریدی (محور قائم). نقاط قرمز و خط برازش داده شده قرمز رنگ مربوط به مدل هیبریدی و نقاط آبی و خط برازش داده شده آبی رنگ مربوط به مدل منفرد است. خط سبز بیانگر محور ۴۵ درجه جهت مقایسه بصری نتایج مدل‌ها نسبت به حالت ایدئال است.

Fig. 12. Observation of SPI data in Abadan station. Scatter plot of single and hybrid GRNN model. Horizontal axis is observed SPI and the vertical axes is predicted values of SPI by using single model (blue point and regression line), hybrid model (red point and regression line). The 45° ideal line regression is drawn in green.



شکل ۱۳. نمودار پراکنش داده‌های SPI مشاهداتی ایستگاه آبادان مربوط به مدل منفرد و هیبریدی (محور افقی SPI مشاهداتی) و مقادیر پیش‌بینی شده داده‌های SPI با استفاده از مدل منفرد و مدل هیبریدی (محور قائم). نقاط قرمز و خط برازش داده شده قرمز رنگ مربوط به مدل هیبریدی و نقاط آبی و خط برازش داده شده آبی رنگ مربوط به مدل منفرد است. خط سبز بیانگر محور ۴۵ درجه جهت مقایسه بصری نتایج مدل‌ها نسبت به حالت ایدئال است.

Fig. 13. Observation of SPI data in Abadan station. Scatter plot of single and hybrid RBF model. Horizontal axis is observed SPI and the vertical axes is predicted values of SPI by using single model (blue point and regression line), hybrid model (red point and regression line). The 45° ideal line regression is drawn in green.

است. همچنین مقادیر تفاضلی RMSE نیز در کلیه مدل‌های مورد بررسی و ایستگاه‌های مورد مطالعه منفی است که نشان‌دهنده کمتر بودن مقدار RMSE در پیش‌بینی مدل‌های هیبریدی نسبت به مدل‌های منفرد شبکه عصبی است. در رنگ‌بندی جداول هر مقدار سلولی رنگ سبز پررنگ‌تر باشد یعنی مدل‌سازی هیبریدی نسبت به منفرد اختلاف بیشتری دارد و بهبود مدل‌سازی در این موارد بیشتر بوده است. همان‌طور که در این جداول دیده می‌شود اختلاف بین مدل هیبریدی و مدل منفرد در همه ایستگاه‌ها برای مقیاس‌های پایین‌تر بیشتر است و

جدول‌های آورده شده در شکل‌های ۱۴ تا ۱۶ به تفاضل RMSE و R^2 مدل‌های هیبرید با مدل‌سازی شبکه عصبی منفرد جهت پیش‌بینی مقدار SPI ماهانه مربوط به ۱۰ ایستگاه مورد مطالعه در مقیاس‌های زمانی مورد بررسی است. مقادیر عددی به دست آمده در این جداول نشان‌دهنده این است که در تمامی SPI‌ها و ایستگاه‌های مورد مطالعه، مقادیر تفاضلی R^2 مثبت است که بیانگر مقادیر بیشتر R^2 مدل هیبریدی نسبت به مدل‌سازی‌های شبکه عصبی منفرد است که به نحوی نشان‌دهنده بهبود مدل‌سازی هیبریدی نسبت به مدل‌های منفرد

بیشترین اختلاف بین مدل‌سازی هیبریدی و منفرد مربوط به مقیاس زمانی ۳ ماهه و مقیاس زمانی ۳ ماهه و مربوط به مدل RBF است که مقدار آن برابر ۰/۳۹۵۵- بوده است که در آن میزان اختلاف R^2 برابر با ۰/۴۱۰۱ بوده است.

بیشترین اختلاف بین مدل‌سازی هیبریدی و منفرد مربوط به مقیاس زمانی ۳ ماهه است. بیشترین اختلاف مربوط به R^2 بین مدل‌سازی هیبریدی و منفرد مربوط به ایستگاه کرمان و مقیاس زمانی ۳ ماهه و مربوط به مدل RBF است که مقدار آن برابر ۰/۴۵۲۲ بوده است که در آن میزان اختلاف RMSE برابر با

| الف | | | | | | ب | | | | | | |
|--------|--------|--------|--------|--------|--------|-------------|---------|---------|---------|---------|---------|---------|
| SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 | Station | SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 |
| 0.4012 | 0.3420 | 0.0905 | 0.1099 | 0.0926 | 0.0389 | BandarAbbas | -0.2512 | -0.2306 | -0.0763 | -0.1123 | -0.1006 | -0.0587 |
| 0.3912 | 0.3117 | 0.0723 | 0.0659 | 0.0454 | 0.0174 | Abadan | -0.3249 | -0.2784 | -0.1079 | -0.1169 | -0.1019 | -0.0680 |
| 0.4160 | 0.2007 | 0.0862 | 0.0722 | 0.0485 | 0.0352 | Babolsar | -0.3916 | -0.2523 | -0.1560 | -0.1508 | -0.1113 | -0.0960 |
| 0.4507 | 0.2802 | 0.1552 | 0.1244 | 0.0739 | 0.0390 | Kerman | -0.3058 | -0.1795 | -0.1453 | -0.1192 | -0.0678 | -0.0366 |
| 0.3556 | 0.2485 | 0.1235 | 0.0575 | 0.1128 | 0.0607 | Mashhad | -0.2458 | -0.2033 | -0.1334 | -0.0749 | -0.1391 | -0.0705 |
| 0.3661 | 0.2450 | 0.1314 | 0.1008 | 0.0745 | 0.0465 | Rasht | -0.3132 | -0.2422 | -0.1898 | -0.1519 | -0.1168 | -0.0935 |
| 0.3521 | 0.2831 | 0.1300 | 0.0717 | 0.0508 | 0.0575 | Saghez | -0.2867 | -0.2382 | -0.1270 | -0.0947 | -0.0808 | -0.0790 |
| 0.3881 | 0.2291 | 0.1426 | 0.1072 | 0.0713 | 0.0427 | Tabriz | -0.3053 | -0.1959 | -0.1287 | -0.0943 | -0.0742 | -0.0485 |
| 0.2817 | 0.2158 | 0.0763 | 0.0410 | 0.0251 | 0.0268 | Tehran | -0.2201 | -0.2146 | -0.1346 | -0.1081 | -0.0821 | -0.1033 |
| 0.4207 | 0.3095 | 0.0780 | 0.0594 | 0.1096 | 0.0235 | Zahedan | -0.3453 | -0.3001 | -0.1382 | -0.1328 | -0.1962 | -0.0821 |

شکل ۱۴. مقایسه نتایج مدل‌سازی مدل MLP با W_MLP در SPI های مختلف. الف) مقادیر تفاضل R^2 (ب) مقادیر تفاضل RMSE
 Fig. 14. The comparison of MLP, W_MLP for different SPI time scales. A) R^2 difference, B) RMSE difference.

| الف | | | | | | ب | | | | | | |
|--------|--------|--------|--------|--------|--------|-------------|---------|---------|---------|---------|---------|---------|
| SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 | Station | SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 |
| 0.3214 | 0.2237 | 0.0508 | 0.1308 | 0.1032 | 0.0081 | BandarAbbas | -0.1743 | -0.1221 | -0.0350 | -0.1019 | -0.0781 | -0.0083 |
| 0.3380 | 0.3858 | 0.1142 | 0.0784 | 0.0764 | 0.0108 | Abadan | -0.2350 | -0.2648 | -0.1333 | -0.1164 | -0.1224 | -0.0289 |
| 0.3265 | 0.1938 | 0.0866 | 0.0480 | 0.1401 | 0.0346 | Babolsar | -0.2255 | -0.1863 | -0.1258 | -0.0797 | -0.2001 | -0.0586 |
| 0.2986 | 0.2279 | 0.1246 | 0.0921 | 0.0389 | 0.0993 | Kerman | -0.1579 | -0.1277 | -0.0947 | -0.0674 | -0.0290 | -0.0619 |
| 0.3341 | 0.2084 | 0.1190 | 0.0679 | 0.0529 | 0.0396 | Mashhad | -0.1907 | -0.1450 | -0.1053 | -0.0773 | -0.0594 | -0.0342 |
| 0.3229 | 0.2346 | 0.1236 | 0.1024 | 0.0807 | 0.0278 | Rasht | -0.2125 | -0.1831 | -0.1405 | -0.1306 | -0.1034 | -0.0415 |
| 0.3434 | 0.2548 | 0.0664 | 0.0603 | 0.0299 | 0.0550 | Saghez | -0.2094 | -0.1655 | -0.0491 | -0.0576 | -0.0355 | -0.0345 |
| 0.3248 | 0.1543 | 0.1317 | 0.0753 | 0.0522 | 0.0192 | Tabriz | -0.2079 | -0.1055 | -0.0959 | -0.0553 | -0.0438 | -0.0171 |
| 0.2869 | 0.2177 | 0.0677 | 0.0430 | 0.0201 | 0.0060 | Tehran | -0.1793 | -0.1754 | -0.1039 | -0.0931 | -0.0513 | -0.0160 |
| 0.2707 | 0.2103 | 0.0643 | 0.0013 | 0.0670 | 0.0359 | Zahedan | -0.1833 | -0.1758 | -0.0797 | -0.0016 | -0.0828 | -0.0438 |

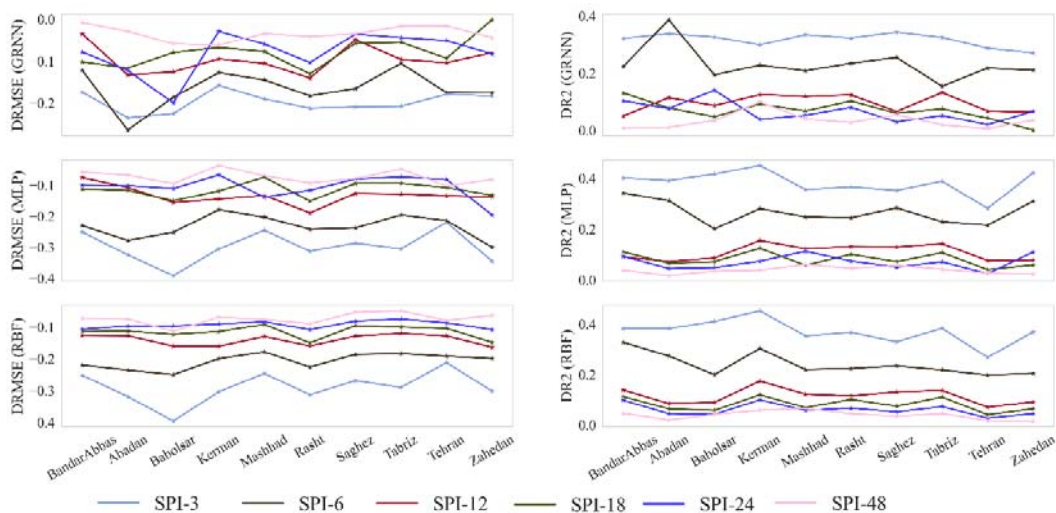
شکل ۱۵. مقایسه نتایج مدل‌سازی مدل GRNN با W_GRNN در SPI های مختلف. الف) مقادیر تفاضل R^2 (ب) مقادیر تفاضل RMSE
 Fig. 15. The comparison of GRNN, W_GRNN for different SPI time scales. A) R^2 difference, B) RMSE difference.

| الف | | | | | | | ب | | | | | | |
|--------|--------|--------|--------|--------|--------|-------------|---------|---------|---------|---------|---------|---------|--|
| SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 | Station | SPI_3 | SPI_6 | SPI_12 | SPI_18 | SPI_24 | SPI_48 | |
| 0.3811 | 0.3274 | 0.1378 | 0.1118 | 0.0976 | 0.0456 | BandarAbbas | -0.2520 | -0.2200 | -0.1274 | -0.1145 | -0.1076 | -0.0724 | |
| 0.3816 | 0.2730 | 0.0842 | 0.0635 | 0.0438 | 0.0188 | Abadan | -0.3186 | -0.2356 | -0.1280 | -0.1137 | -0.0978 | -0.0751 | |
| 0.4101 | 0.1991 | 0.0888 | 0.0568 | 0.0409 | 0.0410 | Babolsar | -0.3955 | -0.2498 | -0.1603 | -0.1236 | -0.0972 | -0.1137 | |
| 0.4522 | 0.3029 | 0.1734 | 0.1193 | 0.0991 | 0.0577 | Kerman | -0.3037 | -0.1999 | -0.1609 | -0.1150 | -0.0910 | -0.0695 | |
| 0.3523 | 0.2193 | 0.1215 | 0.0681 | 0.0570 | 0.0646 | Mashhad | -0.2462 | -0.1785 | -0.1303 | -0.0924 | -0.0838 | -0.0766 | |
| 0.3663 | 0.2235 | 0.1147 | 0.1006 | 0.0662 | 0.0438 | Rasht | -0.3131 | -0.2261 | -0.1599 | -0.1502 | -0.1090 | -0.0902 | |
| 0.3294 | 0.2341 | 0.1302 | 0.0738 | 0.0511 | 0.0336 | Saghez | -0.2686 | -0.1864 | -0.1289 | -0.0963 | -0.0816 | -0.0540 | |
| 0.3824 | 0.2175 | 0.1364 | 0.1102 | 0.0721 | 0.0441 | Tabriz | -0.2899 | -0.1838 | -0.1208 | -0.1007 | -0.0755 | -0.0498 | |
| 0.2677 | 0.1975 | 0.0700 | 0.0397 | 0.0262 | 0.0168 | Tehran | -0.2123 | -0.1921 | -0.1286 | -0.1050 | -0.0871 | -0.0798 | |
| 0.3681 | 0.2041 | 0.0910 | 0.0635 | 0.0441 | 0.0149 | Zahedan | -0.3015 | -0.1993 | -0.1637 | -0.1484 | -0.1092 | -0.0642 | |

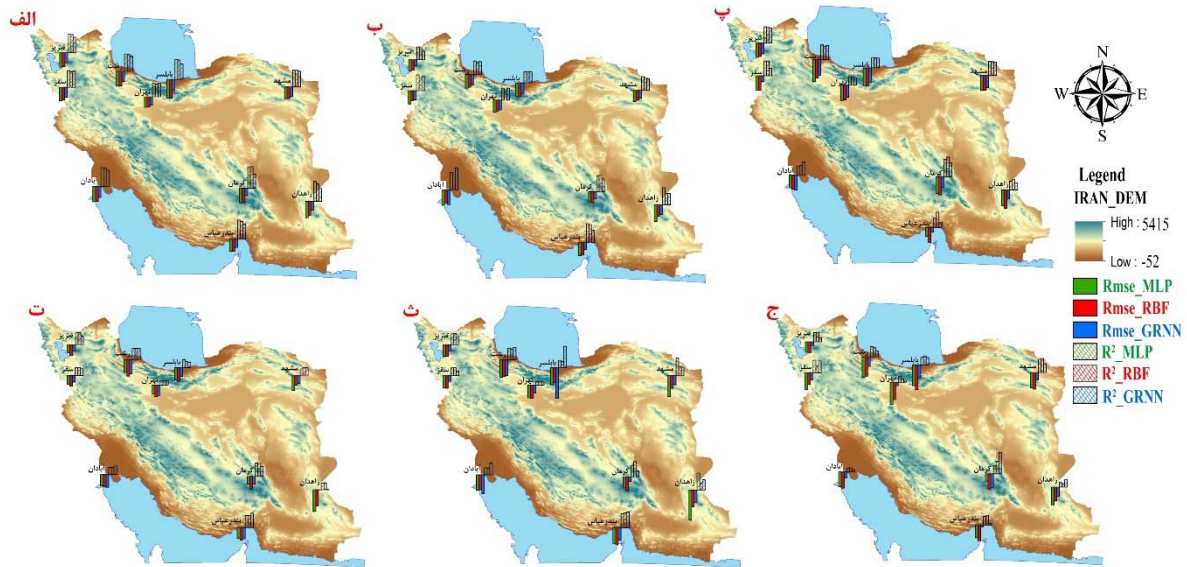
شکل ۱۶. مقایسه نتایج مدل سازی مدل RBF با W_RBF در SPI های مختلف. الف) مقادیر تفاضل R^2 (ب) مقادیر تفاضل RMSE
 Fig. 16. The comparison of RBF, W_RBF for different SPI time scales. A) R^2 difference, B) RMSE difference.

شده در تحقیق را بر روی موقعیت مکانی این ایستگاهها نشان می دهد. همانطور که در این نقشه دیده می شود در مدل های RBF و MLP با افزایش مقیاس زمانی شاخص SPI از ۳ ماهه به سمت ۴۸ ماهه میزان تفاضل RMSE و R^2 (قدر مطلق مقادیر) تقریباً روندی نزولی دارد و این به این معنی است که اثر ترکیب موجک با دو الگوریتم RBF و MLP در مقیاس های زمانی پایین تر، بیشتر است. در مدل GRNN الگویی متمایز تر از دیگر مدلها را به طور مثال در ایستگاه زاهدان SPI ۱۸ ماهه (مقداری بسیاری کم) و در بابلسر در SPI ۲۴ ماهه (مقدار تفاضل بیشتری) شاهد هستیم.

نمودارهای مربوط به شکل ۱۷ بیانگر میزان اختلاف بین مدل های هیبریدی و منفرد برای تمامی ایستگاهها به صورت گراف های رنگی است. همانطور که در این گرافها دیده می شود مقدار اختلافها در RMSE و R^2 بیانگر میزان اختلاف بیشتر در مقیاس های زمانی ۳ و ۶ نسبت به مقیاس های زمانی ۱۲، ۱۸، ۲۴ و ۴۸ است که به نحوی به ماهیت داده های این مقیاس های زمانی برمی گردد. همانطور که در این شکل دیده می شود به ترتیب بیشترین بهبود در مقدار R^2 و RMSE از مقیاس پایین ۳ ماهه به سمت مقیاس های زمانی بالاتر ۴۸ ماهه است. شکل ۱۸ مقادیر تفاضل RMSE و R^2 مدل های استفاده



شکل ۱۷. نمودار مقادیر تفاضل RMSE و تفاضل R^2 برای ده ایستگاه مورد مطالعه در SPI های ۳ تا ۴۸ ماهه
 Fig. 17. The RMSE and R^2 differences graph for all 10 stations and for each SPI time scales.



شکل ۱۸. نمایش مقادیر تفاضل RMSE و تفاضل R^2 ده ایستگاه مورد مطالعه در SPI های ۳ تا ۴۸ ماهه بر روی نقشه ارتفاعی ایران.

(الف) SPI3، (ب) SPI6، (پ) SPI12، (ت) SPI18، (ث) SPI24، (ج) SPI48.

Fig. 18. The RMSE and R^2 differences graph for all 10 stations and for each SPI time scales on the Iran elevation map. A) SPI3, B) SPI6, C) SPI12, D) SPI18, E) SPI24, F) SPI48.

بحث و نتیجه گیری

یک ماه آینده مورد استفاده قرار گرفت. در این پژوهش از سه مدل شبکه عصبی MLP، RBF و GRNN به صورت منفرد و نیز ترکیب این سه مدل با موجک استفاده شد. در تمامی مقیاس‌های زمانی مورد بررسی مدل‌های هیبریدی دقت بالاتری نسبت به مدل‌های منفرد از خود نشان دادند. این موضوع با نتیجه حاصل از پژوهش خان و همکاران (۱۰) که به پیش‌بینی خشک‌سالی با استفاده از دو مدل MLP و ARIMA به صورت منفرد و در ترکیب با موجک در منطقه حوضه رودخانه لانگات مالزی استفاده کردند و نشان دادند که در تمامی مقیاس‌های زمانی مدل ترکیبی دارای دقت بالاتری نسبت به مدل‌های منفرد است، مطابقت دارد. دقت بالاتر مدل‌های هیبریدی نسبت به مدل‌های منفرد با کار کماسی و شرقی (۱۳) نیز مطابقت دارد. اختلاف بین مدل‌های هیبریدی و منفرد در مقیاس زمانی سه و شش‌ماهه بیشتر از دیگر مقیاس‌های دیگر زمانی بود. این موضوع نیز با نتایج تحقیق تایلان و همکاران (۲۷) مطابقت دارد. میانگین تمامی تفاضل بین RMSE مدل‌های هیبریدی نسبت به منفرد در هر ده ایستگاه مورد مطالعه و در همه

خشک‌سالی یکی از پرهزینه‌ترین بحران‌های مرتبط با آب‌وهوا است. خشک‌سالی اثرات بسیار سنگینی بر زندگی جوامع بشری دارد. در دوران خشک‌سالی علاوه بر از دست رفتن منابع آب شرب، محصولات کشاورزی، دامداری، اقتصاد، محیط‌زیست و حتی سلامت انسان‌ها نیز دچار اختلال جدی خواهند شد. از این رو مدل‌سازی، پیش‌بینی و پایش خشک‌سالی بسیار در مدیریت این بحران کمک خواهد کرد. در این تحقیق با بهره‌گیری از سه الگوریتم شبکه عصبی و استفاده از تکنیک موجک در تلفیق با آن‌ها به مدل‌سازی و پیش‌بینی خشک‌سالی پرداخته شده است. در این پژوهش در ابتدا مقدار شاخص SPI در مقیاس‌های زمانی ۳، ۶، ۱۲، ۱۸، ۲۴ و ۴۸ در ۱۰ ایستگاه سینوپتیک در بازه زمانی ۱۹۶۱ تا ۲۰۱۷ محاسبه گردید. در ادامه با تقسیم داده‌های SPI به دو بخش داده‌های مورد استفاده جهت آموزش مدل‌های مورد مطالعه در این پژوهش و همچنین بخش داده‌های مورد استفاده جهت پیش‌بینی ماهانه تقسیم گردید. از زنجیره مارکوف با سه گام عقب‌تر جهت پیش‌بینی

و پیش‌بینی پدیده خشک‌سالی دارند که با ترکیب این الگوریتم‌ها با موجک توانایی آن‌ها در مدل‌سازی و پیش‌بینی خشک‌سالی به میزان قابل توجهی افزایش می‌یابد. علاوه بر این می‌توان نتیجه گرفت که در مقیاس‌های زمانی پایین‌تر شاخص خشک‌سالی SPI، مانند مقیاس‌های ۳ و ۶ ماهه که سری زمانی پیچیده‌تری نسبت به مقیاس‌های زمانی بالاتر دارند، میزان بهبود دقت مدل‌های هیبریدی نسبت به مدل‌های منفرد بیشتر است که نشان‌دهنده اهمیت بالای استفاده از موجک در تلفیق با الگوریتم‌های هوش محاسباتی مانند شبکه‌های عصبی MLP، GRNN و RBF دارد. در پژوهش‌های بعدی می‌توان با استفاده از تصاویر ماهواره‌ای به مدل‌سازی و پیش‌بینی خشک‌سالی در مقیاسه با روش‌های هوش محاسباتی پرداخت. علاوه بر سه الگوریتم استفاده شده در این تحقیق (MLP، RBF و GRNN) در کارهای آتی می‌توان به تلفیق الگوریتم‌های دیگری از خانواده هوش محاسباتی از جمله ماشین بردار پشتیبان، رگرسیون فرآیند گوسی، درخت تصمیم‌گیری، فازی-عصبی با موجک پرداخت. پیشنهاد می‌شود در کارهای آتی از تعدادی بیشتری ایستگاه سینوپتیک جهت ساخت سامانه پیش‌بینی خشک‌سالی در کشور ایران استفاده کرد. از آنجایی که همه مدل‌های هوش محاسباتی دارای پارامترهایی هستند که یافتن مقدار بهینه آنها تاثیر بالایی در نتایج مدل‌سازی دارد، پیشنهاد می‌شود در پژوهش‌های بعدی به یافتن مقادیر بهینه این پارامترها با استفاده از الگوریتم‌های بهینه‌سازی پرداخت. از جمله الگوریتم‌های بهینه‌سازی می‌توان به الگوریتم ژنتیک، کلونی مورچگان، کلونی زنبور عسل، PSO و بقیه روش‌های ابتکاری و فراابتکاری اشاره کرد.

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

مقیاس‌های زمانی نشان داد که به میزان بهبود ناشی از استفاده از موجک در تلفیق با شبکه‌های عصبی به ترتیب در مدل MLP با تفاضل RMSE برابر با ۰/۱۶۰۴- و تفاضل R2 برابر ۰/۱۵۸۰، مدل RBF با تفاضل RMSE برابر با ۰/۱۵۳۸- و تفاضل R2 برابر ۰/۱۵۰۴ و GRNN با تفاضل RMSE برابر با ۰/۱۰۸۷- و تفاضل R2 برابر ۰/۱۳۵۴ بوده است. به عبارت دیگر در حالت کلی روش تلفیق موجک با مدل MLP نسبت به دیگر مدل‌ها سبب بهبود بیشتری در مدل‌سازی نسبت به حالت منفرد و پیش‌بینی ماهانه مقدار SPI بوده است. یعنی می‌توان نتیجه گرفت که مدل RBF و GRNN در حالت منفرد دارای دقت بالاتری در مدل‌سازی و پیش‌بینی نسبت به مدل منفرد MLP می‌باشند که این نتیجه‌گیری با نتیجه حاصل از پژوهش حسینی مقعری و عراقی‌نژاد (۹) که به پیش‌بینی ماهانه خشک‌سالی با استفاده از سه مدل منفرد RBF، GRNN و MLP در حوزه گرگان‌رود پرداخته است، مطابقت دارد. در این تحقیق در مجموع از ۶ روش جهت مدل‌سازی و پیش‌بینی خشک‌سالی در ۱۰ ایستگاه در اقلیم‌های مختلف استفاده شد که در تحقیقات قبلی به این صورت به آن پرداخته نشده است. به عنوان نمونه، اوکایا و کورناز (۲۲) به پیش‌بینی خشک‌سالی برای ایستگاه هواشناسی واقع در منطقه مرمره کشور ترکیه پرداختند. در این تحقیق از مدل‌های خودرگرسیو غیرخطی و مدل رگرسیون غیرخطی با ورودی خارجی از نوع شبکه عصبی و نیز مدل ترکیبی با موجک استفاده شد. اما در این تحقیق از ایستگاه‌های مختلف و نیز انواع شبکه عصبی در ترکیب با موجک استفاده نشده است. در تحقیقی مشابه با این تحقیق عزیمی و اژدری مقدم (۶) به پیش‌بینی کوتاه‌مدت بارندگی با استفاده از مدل شبکه عصبی مصنوعی و مدل طبقه‌بندی فرآیند گوسی پرداختند، در این تحقیق اگرچه از ۳۶۲ ایستگاه سینوپتیک کشور ایران استفاده شد اما از تکنیک موجک جهت دستیابی به نتایج بهتر استفاده نشده است. نتیجه‌گیری کلی که می‌توان از پژوهش حاضر داشت این است که الگوریتم‌های هوش محاسباتی قابلیت بالایی در مدل‌سازی

است. دانشگاه آزاد اسلامی واحد علوم و تحقیقات (تهران) اجرا شده

References

1. Abeyasingha N, Rajapaksha U. 2020. SPI-based spatiotemporal drought over Sri Lanka. *Advances in Meteorology*, 2020. <https://doi.org/10.1155/2020/9753279>.
2. Azimi S, Moghaddam MA. 2020. Modeling short term rainfall forecast using neural networks, and Gaussian process classification based on the SPI drought index. *Water Resources Management*: 1-37. <https://doi.org/10.1007/s11269-020-02507-6>.
3. Bhunia P, Das P, Maiti R. 2020. Meteorological drought study through SPI in three drought prone districts of West Bengal, India. *Earth Systems and Environment*, 4(1): 43-55. <https://doi.org/10.1007/s41748-019-00137-6>.
4. Diop L, Bodian A, Djaman K, Yaseen ZM, Deo RC, El-Shafie A, Brown LC. 2018. The influence of climatic inputs on stream-flow pattern forecasting: case study of Upper Senegal River. *Environmental earth sciences*, 77(5): 1-13. <https://doi.org/10.1007/s12665-018-7376-8>.
5. Foroumandi E, Nourani V, Sharghi E. 2021. Climate change or regional human impacts? Remote sensing tools, artificial neural networks, and wavelet approaches aim to solve the problem. *Hydrology Research*, 52(1): 176-195. <https://doi.org/10.2166/nh.2020.112>.
6. Ghritlahre HK, Prasad RK. 2018. Exergetic performance prediction of solar air heater using MLP, GRNN and RBF models of artificial neural network technique. *Journal of environmental management*, 223: 566-575. <https://doi.org/10.1016/j.jenvman.2018.06.033>.
7. Hadi SJ, Tombul M. 2018. Streamflow forecasting using four wavelet transformation combinations approaches with data-driven models: a comparative study. *Water Resources Management*, 32(14): 4661-4679. <https://doi.org/10.1007/s11269-018-2077-3>
8. Hannan SA, Manza R, Ramteke R. 2010. Generalized regression neural network and radial basis function for heart disease diagnosis. *International Journal of Computer Applications*, 7(13): 7-13. <https://doi.org/10.5120/1325-1799>.
9. Hosseini-Moghari SM, Araghinejad S. 2015. Monthly and seasonal drought forecasting using statistical neural networks. *Environmental Earth Sciences*, 74(1): 397-412. <https://doi.org/10.1007/s12665-015-4047-x>.
10. Khan MMH, Muhammad NS, El-Shafie A. 2020. Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting. *Journal of Hydrology*, 590: 125380. <https://doi.org/10.1016/j.jhydrol.2020.125380>.
11. KISI Ö. 2006. Generalized regression neural networks for evapotranspiration modelling. *Hydrological Sciences Journal*, 51(6): 1092-1105. <https://doi.org/10.1623/hysj.51.6.1092>.
12. Kisi O, Tombul M, Kermani MZ. 2015. Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoretical and applied climatology*, 121(1): 377-387. <https://doi.org/10.1007/s00704-014-1232-x>.
13. Komasi M, Sharghi S. 2020. Drought Forecasting Using Wavelet-Support Vector Machine and Standardized Precipitation Index (Case Study: Urmia Lake-Iran). *Journal of Environmental Science and Technology*, 22(7): 83-101. <https://doi.org/10.22034/jest.2020.9578>. (In Persian).
14. Lazri M, Ameer S, Brucker JM, Lahdir M, Sehad M. 2015. Analysis of drought areas in northern Algeria using Markov chains. *Journal of Earth System Science*, 124(1): 61-70. <https://doi.org/10.1007/s12040-014-0500-6>.
15. Li L, She D, Zheng H, Lin P, Yang Z-L. 2020. Elucidating diverse drought characteristics from two meteorological drought indices (SPI and SPEI) in China. *Journal of Hydrometeorology*, 21(7): 1513-1530. <https://doi.org/10.1175/JHM-D-19-0290.1>.
16. Lin G-F, Chen L-H. 2004. A non-linear rainfall-runoff model using radial basis function network. *Journal of Hydrology*, 289(1-4): 1-8. <https://doi.org/10.1016/j.jhydrol.2003.10.015>.
17. Lippmann R. 1994. Book Review: "Neural Networks, A Comprehensive Foundation", by Simon Haykin. *International Journal of Neural Systems*, 5(04): 363-364. <https://doi.org/10.1142/S0129065794000372>.
18. 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).
19. 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.
20. Mehdizadeh S, Ahmadi F, Mehr AD, Safari MJS. 2020. Drought modeling using classic time series and hybrid wavelet-gene expression programming models. *Journal of Hydrology*, 587: 125017. <https://doi.org/10.1016/j.jhydrol.2020.125017>.
21. Mirdashtvan M, Saravi MM. 2020. Influence of non-stationarity and auto-correlation of climatic records on spatio-temporal trend and seasonality analysis in a region with prevailing arid and semi-

- arid climate, Iran. *Journal of Arid Land*, 12(6): 964-983. <https://doi.org/10.1007/s40333-020-0100-z>.
22. Ozan Evkaya O, Sevinç Kurnaz F. 2021. Forecasting drought using neural network approaches with transformed time series data. *Journal of Applied Statistics*, 48(13-15): 2591-2606. <https://doi.org/10.1080/02664763.2020.1867829>.
23. Paulo AA, Pereira LS. 2007. Prediction of SPI drought class transitions using Markov chains. *Water resources management*, 21(10): 1813-1827. <https://doi.org/10.1007/s11269-006-9129-9>.
24. Pei Z, Fang S, Wang L, Yang W. 2020. Comparative analysis of drought indicated by the SPI and SPEI at various timescales in Inner Mongolia, China. *Water*, 12(7): 1925. doi: <https://doi.org/10.3390/w12071925>.
25. Razinei T. 2017. Köppen-Geiger climate classification of Iran and investigation of its changes during 20th century. *Journal of the Earth and Space Physics*, 43(2): 419-439. <https://doi.org/10.22059/jesphys.2017.58916>. (In Persian).
26. Rhif M, Ben Abbes A, Martinez B, Farah IR. 2021. An improved trend vegetation analysis for non-stationary NDVI time series based on wavelet transform. *Environmental Science and Pollution Research*, 28(34): 46603-46613. <https://doi.org/10.1007/s11356-020-10867-0>.
27. Taylan ED, Terzi Ö, Baykal T. 2021. Hybrid wavelet-artificial intelligence models in meteorological drought estimation. *Journal of Earth System Science*, 130(1): 1-13. doi:<https://doi.org/10.1007/s12040-020-01488-9>.
28. Won J, Choi J, Lee O, Kim S. 2020. Copula-based Joint Drought Index using SPI and EDDI and its application to climate change. *Science of the Total Environment*, 744: 140701. <https://doi.org/10.1016/j.scitotenv.2020.140701>.
29. Xu D, Zhang Q, Ding Y, Huang H. 2020. Application of a Hybrid ARIMA-SVR Model Based on the SPI for the Forecast of Drought—A Case Study in Henan Province, China. *Journal of Applied Meteorology and Climatology*, 59(7): 1239-1259. <https://doi.org/10.1175/JAMC-D-19-0270.1>.
30. Zadeh MR, Amin S, Khalili D, Singh VP. 2010. Daily outflow prediction by multilayer perceptron with logistic sigmoid and tangent sigmoid activation functions. *Water resources management*, 24(11): 2673-2688. <https://doi.org/10.1007/s11269-009-9573-4>.



Drought prediction and modeling by hybrid wavelet method and neural network algorithms

Jahanbakhsh Mohammadi, Alireza Vafaeinejad, Saeed Behzadi, Hossein Aghamohammadi Zanjirabad, Amirhooman Hemmasi

Received: 17 November 2021 / Received in revised form 26 December 2021 / Accepted: 3 January 2022
Available online 6 January 2022 / Available print 1 January 2023

Abstract

Background and Objective A drought crisis is a dry period of climate that can occur anywhere globally and with any climate. Although this crisis starts slowly, it can have a serious impact on health, agricultural products, the economy, energy, and the environment for a long time to come. Drought severely threatens human livelihood and health and increases the risk of various diseases. Therefore, modeling and predicting drought is one of the most important and serious issues in the scientific community. In the past, mathematical and statistical models such as simple regression, Auto-regression (AR), moving average (MA), and ARIMA were used to model the drought. In recent years, machine learning methods and computational intelligence to model and predict drought have been of great interest

to scientists. Computational intelligence algorithms that have been previously considered by scientists to model drought include multilayer perceptron neural network, RBF neural network, support vector machine, fuzzy, and ANFIS methods. In this research, the purpose of modeling and predicting drought is by using three neural network algorithms, including multilayer perceptron, RBF neural network, and generalized regression neural. The drought index used in this research is the standardized precipitation index (SPI). In this research, the wavelet technique in combination with artificial neural network algorithms for modeling and predicting drought in 10 synoptic stations in Iran (Abadan, Babolsar, Bandar Abbas, Kerman, Mashhad, Rasht, Saqez, Tehran, Tabriz, and Zahedan) have been used in different climates and with suitable spatial distribution throughout Iran.

J. Mohammadi¹, **A. R Vafaeinejad**(✉)², **S. Behzadi**³, **H. A. Zanjirabad**⁴, **A. H. Hemmasi**⁵

Materials and Methods This study, initially using monthly precipitation data between 1961 and 2017, SPI drought index in time scales of 3, 6, 12, 18, 24, and 48 months through programming in soft environment MATLAB software implemented. The results of this step were validated using the available scientific software MDM and Drinc. Then, prediction models were designed using the Markov chain. In this study, a total of six computational intelligence models, including three single models of multilayer perceptron neural network (MLP), radial basis function neural network (RBF), and generalized regression neural network (GRNN), and three hybrids wavelet models with these three models (WMLP-WRBF-WGRNN) have been used to model and predict the SPI index in

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 Rajaei 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, Department of Natural Resources Engineering, Faculty of Natural Resources and Environment, Tehran science and Research Branch, Islamic Azad University, Tehran, Iran

e-mail: a_vafaei@sbu.ac.ir

<https://doi.org/10.30495/GIRS.2022.687669>

<https://dorl.net/dor/20.1001.1.26767082.1401.13.4.5.9>

10 stations of this research. In implementing all these six models, the MATLAB software programming environment has been used. In this study, four types of discrete wavelets were used, including Daubechies, Symlets, Coiflets, and Biorthogonal. Due to the better performance of the Dobbies wavelet, this type of wavelet was used as a final option in the research. In the Daubechies wavelet used between levels 1 to 45, level 3 showed the best performance among different SPI time scales; therefore, the Daubechies level 3 wavelet was used in all hybrid models of this study. After training all six algorithms used, the evaluation criteria of coefficient of determination (R^2) and root mean square error (RMSE) was used to measure the difference between actual and estimated values.

Results and Discussion The results of this study showed that computational intelligence methods have high accuracy in modeling and predicting the SPI drought index. In the first stage, the results showed that the individual MLP, RBF, and GRNN models, if properly trained, have close results in modeling and predicting the SPI drought index. In the next step, it was observed that the wavelet technique would improve the modeling results. In using the wavelet technique in combination with three single models MLP, RBF, and GRNN, the choice of wavelet type is also more effective in modeling, so in this research, the first of the four types of discrete wavelets Daubechies, Symlet, Qoiflet, and Biorthogonal in combination with Three single models of this research were used and the results of these four types of wavelets showed the relative superiority of the Daubechies wavelet over the other three wavelets. In using the Daubechies wavelet, since this wavelet has 45 times and the choice of order was also effective in modeling, it was observed by testing the wavelet 45 times that the 3rd wavelet, in general, has higher accuracy in all time scales of SPI index, 3, 6, 12, 18, 24 and 48 months and also in all three algorithms MLP, RBF, and GRNN. Therefore, in this research, the third-order Daubechies wavelet was used in all three algorithms of this research, as well as in all time scales. The results showed that combining the wavelet technique with all three models MLP, RBF, and GRNN will improve the results. The research graphs showed that for the quarterly time scale, the values obtained from the single model prediction in MLP and RBF modeling have a somewhat one-month phase difference compared to the hybrid model, while in the GRNN model, this prediction difference is negligible. The modeling results for both single and hybrid

modeling modes indicate that there is no phase difference between the single and hybrid modeling methods in time scales of 6, 12, 18, 24, and 48. For the 12- and 24-month time scales, the single GRNN model had more fluctuations and errors in SPI monthly modeling and forecasting, while the hybrid model in these two-time scales had much better behavior in monthly modeling and forecasting. Distribution diagrams of data related to observational SPI of Abadan station showed that the modeling results for single and hybrid modes in 3 and 6-month time scales are less accurate than other time scales and fit line separation, and its uncertainty is higher than others. However, in all neural network models and in all time scales, the hybrid method has shown more accuracy. The numerical results of the study indicate that in all SPIs and stations under study, the differential values of R^2 are positive, which indicates higher values of R^2 in the hybrid model than in single neural network modeling, which indicates an improvement in hybrid modeling compared to individual models. Also, the differential values of RMSE are negative in all studied models and stations, which indicates that the amount of RMSE in predicting hybrid models is lower than individual neural network models. In the research graphs, it can be seen that the amount of differences in RMSE and R^2 indicates a greater difference in time scales 3 and 6 than the time scales 12, 18, 24, and 48, which somehow goes back to the nature of the data of these time scales. The most significant improvement in R^2 and RMSE is from the 3-month low to the 48-month high, respectively.

Conclusion From the findings of this study, it can be concluded that artificial neural network algorithms are efficient methods for modeling and predicting the SPI drought index. The use of wavelets in all three models of artificial neural networks will also improve the results. It can also be concluded that for better modeling of the SPI drought index, it is necessary to select the optimal wavelet type and order. From the results of this study, it can be concluded that the wavelet technique has a greater impact on the lower time scales, i.e., 3 and 6 months, than the higher scales, i.e., 24 and 48 months.

Keywords: Drought, Neural network, Standardized precipitation index (SPI), Multilayer Perceptron neural network (MLP), Radial base function (RBF), Generalized Regression Neural Network (GRNN)