

توسعه مدل هیبریدی موجکی در برآورد خشکسالی های منطقه ای حوضه آبریز سیمینه رود

عرفان رستم زاده^۱، علیرضا پرویشی^{۲*}

۱- کارشناس ارشد مهندسی مدیریت منابع آب، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران.

۲- استادیار گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران.

a.parvishi@gmail.com

تاریخ پذیرش: ۱۴۰۱/۰۲/۲۷

تاریخ دریافت: ۱۴۰۱/۰۱/۲۸

چکیده

در مطالعه حاضر خشکسالی حوضه آبریز سیمینه رود به وسیله مدل های هوشمند ماشین بردار پشتیبان (SVM)، شبکه عصبی مصنوعی (ANN) و تئوری موجک (W) مورد بررسی قرار گرفت. از داده های شش ایستگاه باران سنجی در منطقه استفاده و شاخص خشکسالی در چهار مقیاس زمانی محاسبه گردید. همچنین خود همبستگی مرتبه اول به عنوان تاخیر بهینه انتخاب شد. سپس ساختار مناسب شبکه عصبی مصنوعی با استفاده از روش آزمون و خطا تعیین و ضرایب سه گانه مدل SVM نیز مشخص و مدل سازی انجام شد. نتایج ارزیابی مدل های منفرد نشان داد که تفاوت معنی داری بین دو روش در پیش بینی خشکسالی ها وجود ندارد. در ادامه مدل های هیبریدی WANN و WSVM تهیه شدند. نتایج نشان داد کاربست تئوری موجک عملکرد مدل های منفرد را بسیار بهبود داده و مقدار شاخص های RMSE و MAE به ترتیب ۱۹ و ۲۱ درصد کاهش و ضریب همبستگی ۳۰ درصد افزایش داشته و مدل W(L2)SVM برای پیش بینی خشکسالی های حوضه آبریز سیمینه رود پیشنهاد گردید.

کلمات کلیدی: سطح تجزیه، شاخص بارش استاندارد شده اصلاح شده، مدل های هیبریدی، مدل های منفرد.

مقدمه

نیازهای فعالیتهای مشخص شده انسانی ناکافی باشد (۶). خشکسالی در هر منطقه ای می تواند رخ بدهد، و نوع اقلیم منطقه تاثیری بر عدم وقوع آن ندارد، حتی مناطق مرطوب نیز همواره در معرض این پدیده طبیعی قرار دارند. با توجه به اینکه پدیده خشکسالی در هر منطقه ای خصوصیات و ویژگی های خاص خود را دارد، درک این پدیده و توسعه ابزار و مدل هایی برای پایش خشکسالی از لحاظ کمی و کیفی دارای اهمیت ویژه ای می باشد. این پدیده

خشکسالی ها به تناوب به وقوع پیوسته و از اثرات آن ها، افزایش نیاز آبی گیاهان، کاهش حجم منابع آب های زیرزمینی، تاثیرات منفی و مخرب بر روی جامعه بشری، محیط زیست، اقتصاد و حیات گیاهی و جانوری است (۱۵). تاثیرات خشکسالی عموماً ممکن است به صورت تجمعی در یک دوره زمانی طولانی، منطقه مورد تاثیر را تحت شعاع خود قرار داده و در محدوده وسیعی گسترش یابد (۹). خشکسالی زمانی اتفاق می افتد که بارش برای تامین

خسارات زیادی به انسان‌ها و اکوسیستم‌های طبیعی وارد می‌آورد. خشکسالی با دیگر حوادث طبیعی از قبیل سیل، طوفان و زلزله تفاوت‌هایی دارد و بیان و توصیف کمی هر یک از این پدیده‌ها نیز متفاوت می‌باشد (۵). با توجه به پیچیدگی‌های ذکر شده برای پدیده خشکسالی، تاکنون روش‌های متعددی برای پیش‌بینی خشکسالی‌ها توسعه یافته که از نقاط قوت و ضعف متفاوتی نیز برخوردار هستند. چرا که عوامل مؤثر در فرآیند خشکسالی هواشناسی بسیار متنوع بوده و اعمال کلیه آن‌ها در مدل‌های طراحی شده بسیار مشکل می‌باشد. علاوه بر این، نبود قطعیت‌ها و غیرخطی بودن روابط بین متغیرها، مسأله را پیچیده نموده است. بنابراین، در سال‌های اخیر، رویکرد به مدل‌های هوشمند نظیر شبکه‌های عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) به عنوان ابزاری توانمند در پیش‌بینی خشکسالی‌ها و ترکیب آن‌ها با تئوری موجک، افزایش یافته است. لذا در پیش‌بینی پارامترهای هیدرولوژیک نظیر خشکسالی هواشناسی بایستی داده‌های مؤثر در اختیار مدل قرار گیرند اما، سری‌های زمانی ثبت شده هیدرولوژیک، با مشکلاتی همچون خاصیت تناوبی و وجود نویز سفید در داده‌ها مواجه هستند. عوامل مذکور موجب کاهش دقت شده و برآوردها را به حالت ناریب تبدیل می‌نمایند. برای حل این مشکلات می‌توان از روش‌هایی همچون تلفیق مدل‌های هوشمند و توابع موجک استفاده نمود. مدل‌های هیبریدی با تلفیق روش‌های هوشمند و توابع موجک می‌توانند پارامترهای هیدرولوژیک را با دقت قابل توجهی برآورد نمایند. لذا در این تحقیق سعی گردیده است تا میزان بهبود عملکرد روش‌های ANN و SVM را با استفاده از توابع موجک مورد بررسی و ارزیابی قرار داده و مناسب‌ترین ترکیب هیبریدی برپایه مدل‌های هوشمند مد نظر معرفی گردد. خشکسالی یکی از

مخرب‌ترین بلایای طبیعی در جوامع بشری محسوب می‌شود که می‌تواند تأثیرات جبران ناپذیر کشاورزی، زیست محیطی، اجتماعی و اقتصادی به همراه داشته باشد. بنابراین آگاهی از وقوع خشکسالی می‌تواند در کاهش خسارات مؤثر باشد. در ادامه به تعدادی از مطالعات در این زمینه اشاره می‌شود: رستمی و همکاران، کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی را به عنوان روش‌هایی مؤثر در پیش‌بینی شدت خشکسالی حوزه مَند استان فارس مورد بررسی قرار دادند. نتایج نشان داد که دقت روش شبکه‌های عصبی مصنوعی از روش سیستم استنتاج عصبی - فازی تطبیقی بیشتر می‌باشد؛ همچنین یافته‌های حاصل از این بررسی نشان می‌دهد که هرچه پراکندگی داده‌های ورودی مدل بیشتر باشد مدل استنتاج عصبی - فازی تطبیقی دارای توانایی بیشتری در شبیه‌سازی این نوع از داده‌ها می‌باشد (۱). صمدیان فرد و اسدی، برای پیش‌بینی نمایه خشکسالی بارش استاندارد شده (SPI) در ایستگاه سینوپتیک تبریز در بازه زمانی سال‌های ۱۳۵۸ تا ۱۳۹۱، از روش‌های ماشین بردار پشتیبان و رگرسیون خطی چندگانه استفاده نمودند. نتایج نشان داد هر دو روش مورد مطالعه شامل ماشین بردار پشتیبان و خطی چندگانه پیش‌بینی‌های مناسبی از نمایه‌های خشکسالی داشته‌اند و می‌توانند برای مدیریت عواقب ناشی از پدیده مذکور، با اطمینان قابل قبولی مورد استفاده قرار گیرند (۳). عباسی و همکاران وضعیت خشکسالی حوضه آبریز دریاچه ارومیه را با استفاده از شاخص بارش و تبخیر و تعرق استاندارد شده (SPEI) و مدل ماشین بردار پشتیبان (SVM) با سه تابع هسته‌ای خطی، چند جمله‌ای و پایه شعاعی و شبکه بیزین (BN) مورد بررسی قرار دادند. نتایج نشان داد که در هر دو روش، مدل با پنج تأخیر زمانی عملکرد بهتری داشته و تابع هسته‌ای خطی در روش

SVM نسبت به دو تابع دیگر دقت بیشتری داشته است. همچنین، دقت پیش‌بینی این مدل‌ها با افزایش مقیاس محاسبه SPEI رابطه مستقیم دارد، به نحوی که ضریب همبستگی در روش شبکه بیزین در مرحله آزمون از ۰/۱۷۴ به ۰/۹۸۵، در مقیاس ۴۸ ماهه و در روش SVM با تابع هسته‌ای خطی نیز از ۰/۱۴۹ به ۰/۹۸۳ رسیده است (۴). در مطالعات متعددی همچون پارمار و همکاران (۱۰)، سان و همکاران (۱۲)، یاسین و همکاران (۱۶)، مهدی‌زاده و همکاران (۸) کارایی تلفیق مدل‌های هوشمند و توابع موجک در پیش‌بینی پارامترهای هیدرولوژیک گزارش گردیده است.

مواد و روش‌ها

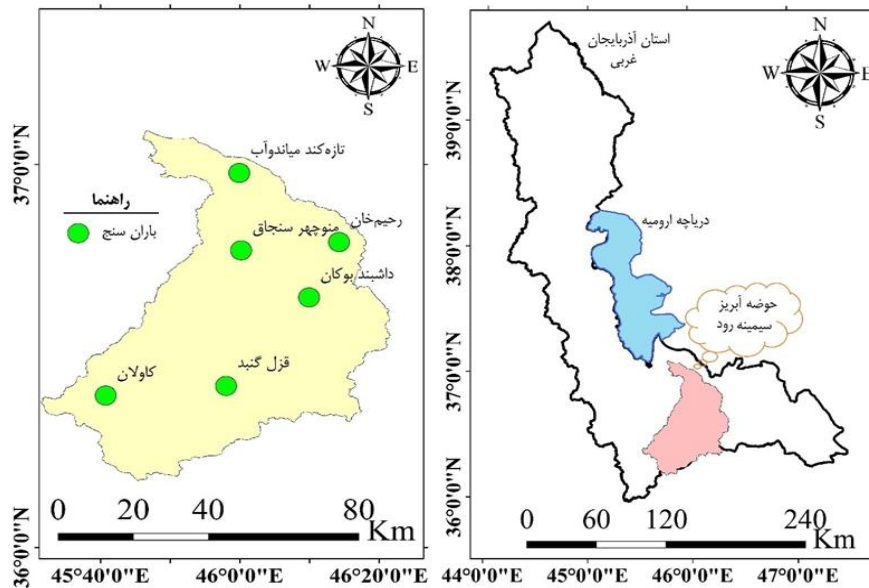
در این مطالعه شاخص SPI اصلاح شده با استفاده از داده‌های ایستگاه‌های باران سنجی موجود در حوضه آبریز درجه دو سیمینه رود واقع در حوضه آبریز درجه یک دریاچه ارومیه و استان آذربایجان غربی مورد بررسی قرار می‌گیرد. حوضه آبریز دریاچه ارومیه واقع در شمال غرب ایران با مساحت ۵۱۸۷۶ کیلومتر مربع یکی از شش حوضه آبریز اصلی کشور است. دریاچه ارومیه به عنوان بزرگترین دریاچه

داخلی ایران و از مهم‌ترین و با ارزش‌ترین اکوسیستم‌های آبی ایران و جهان به شمار می‌آید. دریاچه ارومیه در مجموع توسط ۶۰ رودخانه سیراب می‌شود که ۲۱ رودخانه دائمی یا فصلی هستند و ۳۹ تای آن‌ها دوره‌ای می‌باشند. رودخانه سیمینه‌رود در استان آذربایجان غربی و شهرستان بوکان ایران قرار دارد. سیمینه‌رود از کوهستان‌های منطقه سقز و بانه و کردستان عراق سرچشمه گرفته و پس از عبور از وسط شهر بوکان و اطراف شهر میاندوآب به دریاچه ارومیه می‌ریزد. همچنین رودخانه‌ی سیمینه‌رود از جنوب میاندوآب گذشته، زمین‌های فراوانی را در محدوده‌ی شهرستان میاندوآب آبیاری می‌کند. در این مطالعه از اطلاعات ایستگاه‌های باران‌سنجی وزارت نیرو در محدوده حوضه آبریز سیمینه‌رود استفاده شد. در کل حوضه ۱۰ ایستگاه باران سنجی وجود داشت که شش ایستگاه داشبند بوکان، تازه‌کند میاندوآب، قزل‌گنبد، کاولان، منوچهر و رحیم‌خان به دلیل دارا بودن آمار طولانی مدت برای انجام مطالعه انتخاب شدند. مشخصات ایستگاه‌های مورد بررسی در جدول ۱ و موقعیت مکانی آن‌ها در شکل ۱ ارائه شده است.

جدول ۱- مشخصات ایستگاه‌های منتخب در حوضه آبریز سیمینه‌رود در دوره آماری ۱۳۶۰ تا

۱۳۹۵

ایستگاه	میانگین (mm)	انحراف معیار (mm)	ضریب تغییرات (درصد)
داشبند بودکان	۳۸۵/۳	۱۴۴/۲	۳۷/۴
تازه کند میاندوآب	۲۴۱/۷	۷۵/۷	۳۱/۳
کاولان	۴۲۵/۲	۱۷۳/۲	۴۰/۷
قزل گنبد	۳۷۱/۶	۱۲۸/۷	۳۴/۶
منوچهر	۲۷۶/۱	۷۸/۴	۲۸/۴
رحیم خان	۲۵۰/۲	۷۴/۷	۲۹/۹



شکل ۱- موقعیت حوزه آبریز سیمینه رود و ایستگاه‌های منتخب

نزدیکترین نقاط آموزشی موجود در حاشیه ابر صفحه، بردارهای پشتیبان اطلاق گردیده و از آن‌ها برای مشخص کردن مرز بین طبقات استفاده

توابع موجک:

مطالعات فوریه در قرن ۱۷ میلادی پایه و اساس اولیه تحلیل سیگنال‌ها را مطرح و زمینه را برای ابداع تئوری موجک فراهم نمود. سال‌های متمادی پژوهش‌گران برای تحلیل داده‌های نامنظم و متناوب از تحلیل فوریه استفاده کرده و در بسیاری از موارد نتایج با خطای قابل توجهی همراه بود. برای رفع نقیصه‌های این روش، نظریه موجک معرفی گردید (۲). نظریه موجک با کاربرد تئوری‌های مهندسی و ریاضیاتی به سرعت توسعه یافته و سادگی کاربرد آن در زمینه‌های مختلف امکان استفاده و تحلیل داده‌ها را با دقت قابل قبولی ارائه نمود. موج کوچک یا موجک باید دارای تعداد نوسان‌های محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی از دامنه خود و میانگین صفر باشد. این خصوصیات تحت عنوان شرط پذیرفتگی شناخته می‌شود. یکی از مشخصات کاربردی تابع موجک، الگوریتم فیلترسازی آن است که با عبور دادن داده‌ها از فیلتر مربوطه، آن‌ها

شبکه عصبی مصنوعی ANN:

امروزه علاوه بر مدل‌های متداول کلاسیک، روش‌های غیر کلاسیک که از ویژگی‌هایی همچون هوشمندی برخوردارند و به شبکه‌های عصبی مصنوعی ANN موسومند که برای پیش‌بینی ابداع شده‌اند. شبکه‌های عصبی مصنوعی همانند مغز انسان توانایی لازم را در یادگیری داشته و با پردازش روی داده‌های تجربی، قوانین پیچیده و غیرخطی نهفته در ورای داده‌ها را کشف نموده و قادر به بکار بردن و استفاده از تجارب بدست آمده در مسائل نو و مشابه و پیش‌بینی مقادیر آتی می‌باشند.

ماشین بردار پشتیبان:

ماشین بردار پشتیبان یک طبقه‌بندی کننده دو دویی غیر آماری است که در سال‌های اخیر بسیار مورد توجه قرار گرفته و به اختصار آن را با نام SVM معرفی می‌نمایند (۷). ماشین بردار پشتیبان الگوریتمی است که مدل‌های خطی منحصر به فرد را یافته و با استفاده از آن‌ها حداکثر حاشیه ابر صفحه را حاصل می‌کند. حداکثر شدن حاشیه ابر صفحه، حداکثر شدن تفکیک بین طبقات را حاصل نموده و موجبات بهبود دقت در فرآیند مدل‌سازی را فراهم می‌نماید. به

$$R = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \right)^{0.5} \quad (4)$$

مدلی به عنوان مناسب‌ترین گزینه انتخاب می‌گردد که بیشترین مقدار R و کمترین مقدار RMSE و MAE را به خود اختصاص دهد.

نتایج و بحث:

نتایج پیش‌بینی خشکسالی با استفاده از روش‌های هوشمند منفرد:

پس از تعیین ورودی مدل‌های هوشمند بایستی سهم داده‌های آموزش و صحت‌سنجی را تعیین نمود. بدین منظور داده‌های ۲۵ سال یعنی از سال ۱۳۶۰ تا ۱۳۸۵ برای مرحله آموزش مدل‌ها و داده‌های ۱۰ سال نهایی برای آزمون تقسیم‌بندی شد. برای پیش‌بینی خشکسالی و ساخت مدل در حوضه آبریز سیمینه‌رود، باید شبکه عصبی را آموزش داد و چون قوانین خاصی برای آموزش و طراحی شبکه‌های عصبی موجود نیست، بنابراین چندین ساختار مورد آزمایش قرار می‌گیرد. لازم است به مسأله مهمی اشاره شود و آن رویکردی است که برای جلوگیری از بیش‌آموزی انتخاب می‌شود. با انتخاب داده‌های جداگانه به منظور انجام واسنجی (همزمان با عمل آموزش و یا یادگیری در شبکه هوش مصنوعی) می‌توان با اطمینان بیشتری نسبت به عدم بیش‌آموزی بودن مدل‌های ایجاد شده گام برداشت. در این راستا، از شبکه پرسپترون چندلایه (MLP) با الگوریتم پس انتشار خطا و تکنیک یادگیری مارکوارت- لونیبرگ استفاده شد و تعداد نورون در هر لایه با آزمون و خطا مشخص گردید. با توجه به این موضوع که نرم‌افزار MATLAB مقادیری را به عنوان پیش فرض برای تعداد نورون‌ها در نظر می‌گیرد، با انجام تکرارهای متعدد، اثر تغییر این پارامترها بر روی عملکرد شبکه‌ها، بررسی و در نهایت تعداد بهینه لایه‌های

را به دو دسته تقریب و جزئیات تقسیم می‌نماید. تقریب نماینده اجزا با فرکانس پایین یا مقیاس بالا و جزئیات شامل اجزایی با مقیاس کوچک یا فرکانس بالا بوده و فرآیند تجزیه امواج می‌تواند تا چندین مرحله ادامه یابد (۱۳). یکی از مراحل مهم در کاربرد توابع موجک انتخاب سطح تجزیه مناسب برای تحلیل سیگنال مورد نظر می‌باشد. بدین منظور در مطالعه حاضر از رابطه پیشنهادی وانگ و دینگ (۱۴) به شرح زیر استفاده شد:

$$L = \text{Int}[\text{Log}(N)] \quad (1)$$

در رابطه فوق، L تعداد سطح تجزیه، N طول سری داده‌های اولیه و INT عملگر صحیح می‌باشد.

شاخص خشکسالی SPI:

خشکسالی هواشناسی پیش از سایر انواع خشکسالی‌ها ظاهر شده و وقوع آن شرط لازم برای خشکسالی‌های دیگر است. در خشکسالی هواشناسی درجه خشکی غالباً بر اساس مقایسه میزان بارش با متوسط دراز مدت یا میزان نرمال آن تعیین می‌شود. اصولاً SPI برای تشخیص کمبود میزان بارندگی در مقیاس‌های زمانی چندگانه طراحی شده است. این مقیاس‌های زمانی منعکس کننده اثرات ویژه خشکسالی روی قابلیت دسترسی به منابع آبی مختلف می‌باشند.

ارزیابی مدل‌ها:

در این تحقیق، برای ارزیابی مدل‌های مورد نظر از معیارهای جذر میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE) و ضریب همبستگی (R) استفاده می‌شود:

$$RMSE = \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \right]^{0.5} \quad (2)$$

$$MAE = \frac{\sum_{i=1}^n |O_i - P_i|}{n} \quad (3)$$

نتایج حاصل از اجرای مدل منفرد شبکه عصبی مصنوعی در جدول ۲ ارائه شده است. باتوجه به این جدول مشاهده می‌شود که در برآورد خشکسالی‌ها در مقیاس ۳ ماه کمترین دقت و بیشترین خطا رخ داده است. با افزایش مقیاس زمانی نیز عملکرد مدل ANN بهبود می‌یابد.

پنهان و نورون‌ها که نتایج مناسب‌تری داشته، برای آموزش شبکه به مدل معرفی شدند. در نهایت مشخص گردید که وجود یک لایه پنهان با شش نورون می‌تواند بهترین عملکرد را در پیش‌بینی خشکسالی‌های حوضه آبریز سیمینه‌رود داشته باشد.

جدول ۲- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از ANN

مرحله آموزش				مرحله آزمون				آماره	ایستگاه
SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3	SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3		
۰/۲۷۶	۰/۳۵۸	۰/۵۰۱	۰/۷۶۱	۰/۲۵۸	۰/۳۳۷	۰/۴۹۳	۰/۷۲۷	RMSE	داشیند بوکان
۰/۱۸۵	۰/۲۶۲	۰/۳۵۶	۰/۵۸۱	۰/۱۷۷	۰/۲۵۸	۰/۳۴۷	۰/۵۸۱	MAE	
۰/۱۸۷۵	۰/۸۳۲	۰/۷۸	۰/۵۹۱	۰/۹۶۸	۰/۹۴۴	۰/۸۸۲	۰/۶۷۶	R	
۰/۴۳۴	۰/۵۳۳	۰/۶۷	۰/۸۷	۰/۳۲۲	۰/۴۳۳	۰/۵۶۵	۰/۷۱۴	RMSE	تازه کند میاندوآب
۰/۲۵۷	۰/۳۵۹	۰/۴۶۲	۰/۶۵۸	۰/۲۲۶	۰/۳۲۸	۰/۴۱۲	۰/۵۶	MAE	
۰/۱۸۶۶	۰/۸۲۹	۰/۷۸۳	۰/۶۸۸	۰/۹۵	۰/۹۰۶	۰/۸۳۵	۰/۶۶۹	R	
۰/۳۴۷	۰/۴۰۴	۰/۶۴۴	۰/۹۱۴	۰/۲۱۳	۰/۴۲۷	۰/۳۳۹	۰/۶۳۱	RMSE	کاولان
۰/۲۰۳	۰/۲۹۵	۰/۴۵۲	۰/۷۱۱	۰/۱۳۴	۰/۳۱۱	۰/۲۳۲	۰/۴۹۳	MAE	
۰/۹۲۱	۰/۸۹۲	۰/۷۶۹	۰/۵۴۱	۰/۹۷۱	۰/۸۸۶	۰/۹۲۸	۰/۷۳۱	R	
۰/۳۲۷	۰/۴۱	۰/۵۷	۰/۸۶۸	۰/۲۷۱	۰/۳۴۸	۰/۴۷۶	۰/۷۰۷	RMSE	قرز گنبد
۰/۲۱۶	۰/۳۱۱	۰/۳۸۵	۰/۶۷۵	۰/۱۸۱	۰/۲۶۱	۰/۳۳۱	۰/۵۲۴	MAE	
۰/۸۸۳	۰/۸۴۷	۰/۷۶۹	۰/۵۲۹	۰/۹۶۶	۰/۹۴۲	۰/۸۸۸	۰/۶۸۶	R	
۰/۴۰۲	۰/۵۱۵	۰/۶۷۴	۰/۹۶۸	۰/۲۹۵	۰/۳۹۱	۰/۵۰۷	۰/۷	RMSE	منوچهر
۰/۲۴۱	۰/۳۸۴	۰/۴۵۱	۰/۷۱۱	۰/۲۰۱	۰/۲۹۸	۰/۳۸۴	۰/۵۴۶	MAE	
۰/۸۹۵	۰/۸۴۶	۰/۷۷۵	۰/۵۹۱	۰/۹۵۹	۰/۹۲۵	۰/۸۶۶	۰/۶۷۳	R	
۰/۳۸۵	۰/۴۶۵	۰/۶۲۳	۰/۷۷۳	۰/۳۲۱	۰/۴۲۱	۰/۵۴۷	۰/۷۰۶	RMSE	رحیم خان
۰/۲۳۹	۰/۳۱۸	۰/۴۰۹	۰/۵۷۱	۰/۲۱۴	۰/۳۲۱	۰/۴۰۱	۰/۵۶۱	MAE	
۰/۸۸۸	۰/۸۴۳	۰/۷۶۴	۰/۶۶۶	۰/۹۵	۰/۹۱۱	۰/۸۴۶	۰/۶۸۳	R	

ε و C تعیین گردد. همچنین در این پژوهش برای مدل‌سازی خشکسالی، هسته RBF برای مدل SVM انتخاب شد. در تابع RBF نیز، مشخصه γ بایستی تعیین گردد. بنابراین در حالت کلی برای پیش‌بینی خشکسالی در مقیاس‌های زمانی مختلف توسط مدل SVM، لازم است که مقادیر بهینه سه مشخصه مذکور به دست آید که بدین منظور دو

در مطالعه حاضر برای مدل‌سازی خشکسالی با استفاده از روش SVM داده‌ها به مانند روش ANN به صورت ۷۰ درصد برای آموزش و ۳۰ درصد برای تست به مدل معرفی گردید. بدین ترتیب با توجه به اینکه ورودی‌های هر دو مدل یکسان می‌باشد امکان مقایسه هر دو روش فراهم می‌گردد. در مرحله بعد بایستی مقادیر بهینه مشخصه‌های مدل SVM شامل

در این جدول مقادیر بهینه ضرایب سه گانه مدل SVM نیز ارائه شده است. با توجه به این جدول مشاهده می‌شود که بیشترین دقت دربرآورد خشکسالی‌ها به مقیاس زمانی ۱۲ ماهه اختصاص دارد. این نتایج مشابه با عملکرد مدل ANN می‌باشد.


مشخصه ε و C توسط الگوریتم بهینه‌سازی جستجوی شبکه و متغیر γ (گاما) نیز به صورت سعی و خطا محاسبه شد. نتایج حاصل از پیش‌بینی خشکسالی‌های حوضه آبریز سیمینه‌رود با استفاده از روش SVM در جدول ۳ ارائه شده است. همچنین

جدول ۳- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از SVM

ایستگاه	آماره	مرحله آموزش									مرحله آزمون			ضرایب SVM		
		SPIIm-3	SPIIm-6	SPIIm-9	SPIIm-12	SPIIm-3	SPIIm-6	SPIIm-9	SPIIm-12	SPIIm-12	C	ε	گاما			
داشبند بوکان	RMSE	۰/۷۲۵	۰/۴۷۶	۰/۳۳۸	۰/۲۶۲	۰/۷۴۴	۰/۵۱۹	۰/۳۵۷	۰/۲۷۷	۱۰	۰/۱	۰/۹				
	MAE	۰/۵۷۹	۰/۳۳۷	۰/۲۵۹	۰/۱۷۹	۰/۵۶۵	۰/۳۷۱	۰/۲۶۱	۰/۱۸۵	۱۰	۰/۱	۰/۸				
	R	۰/۶۷۸	۰/۸۹۱	۰/۹۴۴	۰/۹۶۷	۰/۶۱۳	۰/۷۶۷	۰/۸۳۴	۰/۸۷۶	۹	۰/۱	۰/۹				
تازه کند میاندوآب	RMSE	۰/۷۰۳	۰/۵۶۴	۰/۴۳۲	۰/۳۲۲	۰/۸۷۲	۰/۶۷۲	۰/۵۳۸	۰/۴۴۱	۱۰	۰/۱	۰/۵				
	MAE	۰/۵۵۰	۰/۴۱۶	۰/۳۲۸	۰/۲۲۵	۰/۶۶۶	۰/۴۶۹	۰/۳۶۳	۰/۲۶۹	۱۰	۰/۱	۰/۸				
	R	۰/۶۸۲	۰/۸۳۶	۰/۹۰۷	۰/۹۵۱	۰/۶۸۱	۰/۷۸۰	۰/۸۲۸	۰/۸۶۱	۸	۰/۱	۰/۸				
کاولان	RMSE	۰/۶۳۳	۰/۴۲۵	۰/۳۳۷	۰/۲۱۸	۰/۹۰۶	۰/۶۶۲	۰/۴۰۰	۰/۳۴۴	۱۰	۰/۱	۰/۹				
	MAE	۰/۴۹۵	۰/۳۱۳	۰/۲۳۱	۰/۱۳۸	۰/۷۰۲	۰/۴۵۰	۰/۲۹۱	۰/۲۰۷	۸	۰/۱	۰/۴				
	R	۰/۷۳۰	۰/۸۸۸	۰/۹۳۰	۰/۹۷۰	۰/۵۵۴	۰/۷۶۷	۰/۸۹۳	۰/۹۲۲	۱۰	۰/۱	۰/۹				
قرز گنبد	RMSE	۰/۷۰۹	۰/۴۷۸	۰/۳۴۸	۰/۲۷۱	۰/۸۶۶	۰/۵۷۸	۰/۴۰۸	۰/۳۲۸	۱۰	۰/۱	۰/۶				
	MAE	۰/۵۵۷	۰/۳۳۴	۰/۲۶۰	۰/۱۸۳	۰/۶۷۵	۰/۳۹۴	۰/۳۰۸	۰/۲۱۵	۹	۰/۱	۰/۴				
	R	۰/۶۸۵	۰/۸۸۸	۰/۹۴۲	۰/۹۶۷	۰/۵۳۶	۰/۷۶۴	۰/۸۴۸	۰/۸۸۳	۱۰	۰/۱	۰/۷				
منوچهر	RMSE	۰/۷۰۷	۰/۵۰۹	۰/۳۹۳	۰/۲۹۶	۰/۹۸۰	۰/۶۷۰	۰/۵۱۳	۰/۳۹۹	۱۰	۰/۱	۰/۹				
	MAE	۰/۵۵۸	۰/۳۹۰	۰/۳۰۱	۰/۲۰۳	۰/۷۲۲	۰/۴۴۹	۰/۳۸۳	۰/۲۴۰	۱۰	۰/۱	۰/۹				
	R	۰/۶۶۶	۰/۸۶۶	۰/۹۲۵	۰/۹۵۹	۰/۵۷۹	۰/۷۷۷	۰/۸۴۶	۰/۸۹۶	۱۰	۰/۱	۰/۹				
رحیم خان	RMSE	۰/۷۱۱	۰/۵۴۴	۰/۴۲۲	۰/۳۲۲	۰/۷۸۹	۰/۶۲۵	۰/۴۶۲	۰/۳۸۳	۱۰	۰/۱	۰/۸				
	MAE	۰/۵۶۶	۰/۴۰۳	۰/۳۲۲	۰/۲۱۶	۰/۵۷۵	۰/۴۱۲	۰/۳۱۷	۰/۲۳۹	۱۰	۰/۱	۰/۸				
	R	۰/۶۷۶	۰/۸۴۸	۰/۹۱۲	۰/۹۵۰	۰/۶۴۹	۰/۷۶۱	۰/۸۴۴	۰/۸۹۰	۱۰	۰/۱	۰/۸				

بیشترین مقدار RMSE را در برآورد خشکسالی‌ها داشته‌اند و کمترین مقدار نیز به ایستگاه داشبند بوکان اختصاص دارد. می‌توان چنین استنباط کرد که در مقیاس ۳ ماهه عملکرد مدل SVM اندکی بهتر از مدل ANN بود.

در شکل ۲ نمودار راداری آمار RMSE مدل‌های SVM و ANN برای مرحله آزمون در پیش‌بینی خشکسالی‌ها با مقیاس زمانی ۳ ماهه برای مقایسه عملکرد هر دو مدل ارائه شده است. همانطور که مشاهده می‌شود، عملکرد مدل‌ها بسیار نزدیک به یکدیگر می‌باشد. هر دو مدل در ایستگاه منوچهر



شکل ۲- نمودار راداری شاخص RMSE برای مدل‌های SVM و ANN در مرحله آزمون برای مقیاس زمانی سه ماهه

توسط توابع موجک مورد استفاده، به عنوان ورودی ایجاد گردیدند. یکی از مهم‌ترین مراحل در استفاده از توابع موجک تعیین سطح تجزیه سیگنال‌های مورد بررسی می‌باشد، همان‌طور که در رابطه ۱، در بخش مواد و روش‌ها اشاره گردید، تعیین می‌شود. در رابطه مذکور، L ، سطح تجزیه پیشنهادی و N ، تعداد داده‌های مورد بررسی می‌باشد. در این مطالعه تعداد داده‌های مورد استفاده در تحلیل پیش‌بینی خشکسالی‌های حوضه آبریز سیمینه‌رود در مقیاس زمانی چهار گانه برابر با ۴۰۸ عدد می‌باشد. با قرار دادن این مقدار در رابطه فوق سطح حداکثر تجزیه، دو سطح به دست می‌آید. نتایج حاصل از اجرای مدل‌های تلفیقی WANN در جداول ۴ و ۵ به ترتیب برای سطح تجزیه یک، $L1$ و دو، $L2$ ارائه شده است. همچنین به منظور درک بهتر تاثیر استفاده از تئوری موجک در بهبود عملکرد مدل منفرد ANN شکل ۳ ارائه شده است. با توجه به این شکل در مقیاس زمانی ۳ ماهه مقدار شاخص RMSE بین ۰/۸ تا ۱/۰ در ایستگاه‌های مختلف در حال تغییر می‌باشد. اما با توسعه مدل‌های هیبریدی WANN در دو سطح

در مقیاس زمانی ۶ ماهه به مانند مقیاس ۳ ماهه، عملکرد هر دو مدل مورد استفاده بسیار نزدیک به یکدیگر بود. خطا در برآوردهای خشکسالی ۶ ماهه کمتر از مقیاس ۳ ماهه می‌باشد. همچنین در این مقیاس بیشترین مقدار RMSE در ایستگاه تازه کند میان‌دوآب مشاهده گردید. برای مقیاس‌های زمانی ۹ و ۱۲ ماهه مشاهده شد که عملاً هیچ تفاوت معنی‌داری بین مدل‌های SVM و ANN در برآورد خشکسالی‌های ۹ ماهه و ۱۲ ماهه حوضه آبریز سیمینه‌رود وجود ندارد. همچنین با افزایش مقیاس زمانی مقدار RMSE نیز کاهش می‌یابد.

نتایج پیش‌بینی خشکسالی با استفاده از روش‌های هیبریدی موجک:

در این پژوهش برای بررسی اثر تجزیه سیگنال‌های پدیده‌های هیدرولوژیک در عملکرد مدل‌های هوشمند از تئوری موجک استفاده شد. بدین منظور ابتدا داده‌های خشکسالی در مقیاس‌های زمانی مختلف حوضه آبریز سیمینه‌رود با استفاده از تابع موجک دابچیز ۴ (db4) تجزیه شد. سپس مدل‌های تلفیقی WANN و WSVM با داده‌های تجزیه شده

تجزیه L1 و L2 مقدار RMSE به ۰/۶ تا ۰/۸ کاهش می‌یابد. همچنین عملکرد مدل ANN در سطح تجزیه L1 در اکثر ایستگاه‌های مورد مطالعه بهتر از سطح تجزیه L2 می‌باشد. در مقیاس زمانی ۶ ماهه نیز وضعیت مشابه با مقیاس زمانی ۳ ماهه بوده و مدل‌های هیبریدی از خطای کمتری در هر دو سطح تجزیه نسبت به مدل منفرد برخوردار بودند. همچنین در این مقیاس در سطح

تجزیه L2 ، در همه ایستگاه‌ها عملکرد مدل WANN بهتر از سطح تجزیه L1 به دست آمد. برای مقیاس‌های زمانی ۹ و ۱۲ ماهه عملکرد مدل WANN نسبت به مدل ANN بسیار بهبود یافته و مقدار شاخص RMSE به مقدار قابل توجهی کاهش یافته است. همچنین در هر دو مقیاس مدل WANN با سطح تجزیه L2 به بهترین عملکرد خود دست می‌یابد.

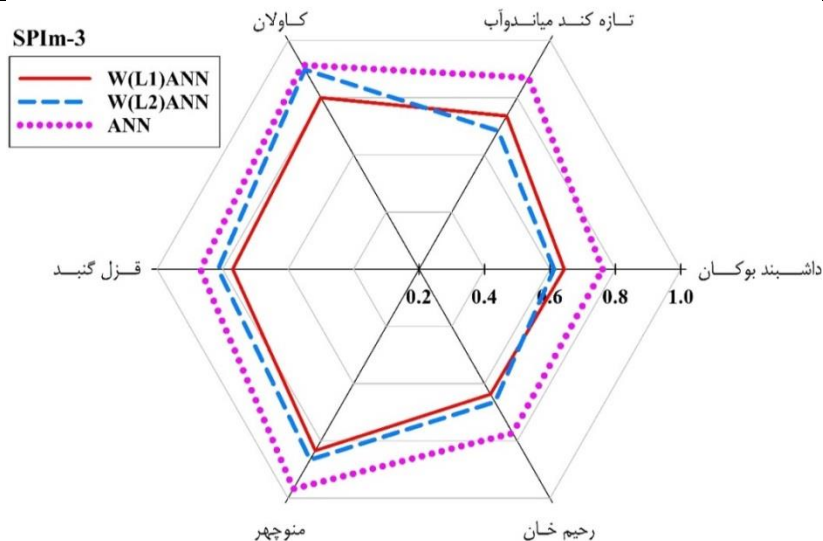
جدول ۴- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از مدل WANN در سطح یک تجزیه

ایستگاه	آماره	مرحله آموزش				مرحله آزمون			
		SPIIm-3	SPIIm-6	SPIIm-9	SPIIm-12	SPIIm-3	SPIIm-6	SPIIm-9	SPIIm-12
داشبند بوکان	RMSE	۰/۵۹۳	۰/۲۸۱	۰/۳۸۶	۰/۲۱۳	۰/۶۴۴	۰/۴۵۳	۰/۲۸۴	۰/۲۴۴
	MAE	۰/۴۵۴	۰/۲۱۷	۰/۲۷۱	۰/۱۴۴	۰/۵۰۶	۰/۳۱۴	۰/۲۰۵	۰/۱۵۶
	R	۰/۸۰۳	۰/۹۶۱	۰/۹۳۰	۰/۹۷۸	۰/۷۳۲	۰/۸۲۶	۰/۸۹۵	۰/۹۰۳
تازه کند میان‌دوآب	RMSE	۰/۵۷۵	۰/۳۶۰	۰/۴۵۴	۰/۲۶۱	۰/۷۳۶	۰/۶۲۲	۰/۴۲۵	۰/۳۵۹
	MAE	۰/۴۳۷	۰/۲۶۲	۰/۳۱۸	۰/۱۹۱	۰/۵۷۴	۰/۴۳۵	۰/۳۱۳	۰/۲۵۰
	R	۰/۸۰۶	۰/۹۳۶	۰/۸۹۹	۰/۹۶۷	۰/۷۸۷	۰/۸۲۶	۰/۸۹۶	۰/۹۱۰
کاولان	RMSE	۰/۵۴۳	۰/۲۵۵	۰/۳۶۱	۰/۱۷۹	۰/۸۰۰	۰/۵۶۰	۰/۳۲۸	۰/۳۰۳
	MAE	۰/۴۲۸	۰/۱۸۱	۰/۲۷۳	۰/۱۲۱	۰/۵۷۱	۰/۳۷۲	۰/۲۴۳	۰/۱۸۳
	R	۰/۸۱۴	۰/۹۶۰	۰/۹۲۰	۰/۹۷۹	۰/۶۸۲	۰/۸۲۴	۰/۹۲۸	۰/۹۴۰
قرز گنبد	RMSE	۰/۵۷۸	۰/۳۸۲	۰/۲۸۲	۰/۲۱۹	۰/۷۶۹	۰/۴۵۱	۰/۳۳۵	۰/۳۱۸
	MAE	۰/۴۳۲	۰/۲۷۸	۰/۲۱۱	۰/۱۵۱	۰/۵۴۸	۰/۳۲۱	۰/۲۵۲	۰/۲۰۳
	R	۰/۸۰۴	۰/۹۳۰	۰/۹۶۲	۰/۹۷۸	۰/۶۶۱	۰/۸۶۳	۰/۸۹۹	۰/۸۹۵
منوچهر	RMSE	۰/۵۸۰	۰/۳۹۱	۰/۳۱۴	۰/۲۳۲	۰/۸۳۴	۰/۵۷۳	۰/۴۰۱	۰/۳۴۶
	MAE	۰/۴۳۸	۰/۳۰۰	۰/۲۳۱	۰/۱۶۴	۰/۶۱۲	۰/۴۱۶	۰/۳۱۶	۰/۲۲۶
	R	۰/۷۸۹	۰/۹۲۳	۰/۹۵۳	۰/۹۷۶	۰/۷۲۳	۰/۸۴۹	۰/۹۱۲	۰/۹۲۲
رحیم خان	RMSE	۰/۵۷۷	۰/۴۵۶	۰/۳۴۵	۰/۲۵۹	۰/۶۳۷	۰/۵۴۴	۰/۳۶۹	۰/۳۳۱
	MAE	۰/۴۴۵	۰/۳۳۵	۰/۲۵۹	۰/۱۸۸	۰/۴۹۴	۰/۳۶۱	۰/۲۵۳	۰/۲۱۴
	R	۰/۸۰۱	۰/۸۹۶	۰/۹۴۲	۰/۹۶۷	۰/۷۸۷	۰/۸۲۷	۰/۹۰۴	۰/۹۱۹

جدول ۵- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از مدل WANN در سطح دو تجزیه

ایستگاه	آماره	مرحله آموزش	مرحله آزمون
---------	-------	-------------	-------------

SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3	SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3		
۰/۲۴۴	۰/۲۸۴	۰/۴۵۳	۰/۶۶۴	۰/۲۱۳	۰/۳۸۶	۰/۲۸۱	۰/۵۹۳	RMSE	داشبند بوکان
۰/۱۵۶	۰/۲۰۵	۰/۳۱۴	۰/۵۰۶	۰/۱۴۴	۰/۲۷۱	۰/۲۱۷	۰/۴۵۴	MAE	
۰/۹۰۳	۰/۸۹۵	۰/۸۲۶	۰/۷۳۲	۰/۹۷۸	۰/۹۳۰	۰/۹۶۱	۰/۸۰۳	R	
۰/۳۵۹	۰/۴۲۵	۰/۶۲۲	۰/۷۳۶	۰/۲۶۱	۰/۴۵۴	۰/۳۶۰	۰/۵۷۵	RMSE	تازه کند میاندوآب
۰/۲۵۰	۰/۳۱۳	۰/۴۳۵	۰/۵۷۴	۰/۱۹۱	۰/۳۱۸	۰/۲۶۲	۰/۴۳۷	MAE	
۰/۹۱۰	۰/۸۹۶	۰/۸۲۶	۰/۷۸۷	۰/۹۶۷	۰/۸۹۹	۰/۹۳۶	۰/۸۰۶	R	
۰/۳۰۳	۰/۳۲۸	۰/۵۶۰	۰/۸۰۰	۰/۱۷۹	۰/۳۶۱	۰/۲۵۵	۰/۵۴۳	RMSE	کاولان
۰/۱۸۳	۰/۲۴۳	۰/۳۷۲	۰/۵۷۱	۰/۱۲۱	۰/۲۷۳	۰/۱۸۱	۰/۴۲۸	MAE	
۰/۹۴۰	۰/۹۲۸	۰/۸۲۴	۰/۶۸۲	۰/۹۷۹	۰/۹۲۰	۰/۹۶۰	۰/۸۱۴	R	
۰/۳۱۸	۰/۳۳۵	۰/۴۵۱	۰/۷۶۹	۰/۲۱۹	۰/۲۸۲	۰/۳۸۲	۰/۵۷۸	RMSE	قزل گنبد
۰/۲۰۳	۰/۲۵۲	۰/۳۲۱	۰/۵۴۸	۰/۱۵۱	۰/۲۱۱	۰/۲۷۸	۰/۴۳۲	MAE	
۰/۹۸۵	۰/۸۹۹	۰/۸۶۳	۰/۶۶۱	۰/۹۷۸	۰/۹۶۲	۰/۹۳۰	۰/۸۰۴	R	
۰/۳۴۶	۰/۴۰۱	۰/۵۷۳	۰/۸۳۴	۰/۲۳۲	۰/۳۱۴	۰/۳۹۱	۰/۵۸۰	RMSE	منوچهر
۰/۲۲۶	۰/۳۱۶	۰/۴۱۶	۰/۶۱۲	۰/۱۶۴	۰/۲۳۱	۰/۳۰۰	۰/۴۳۸	MAE	
۰/۹۲۲	۰/۹۱۲	۰/۸۴۹	۰/۷۲۳	۰/۹۷۶	۰/۹۵۳	۰/۹۲۳	۰/۷۸۹	R	
۰/۳۳۱	۰/۳۶۹	۰/۵۴۴	۰/۶۳۷	۰/۲۵۹	۰/۳۴۵	۰/۴۵۶	۰/۵۷۷	RMSE	رحیم خان
۰/۲۱۴	۰/۲۵۳	۰/۳۶۱	۰/۴۹۴	۰/۱۸۸	۰/۲۵۹	۰/۳۳۵	۰/۴۴۵	MAE	
۰/۹۱۹	۰/۹۰۴	۰/۸۲۷	۰/۷۸۷	۰/۹۶۷	۰/۹۴۲	۰/۸۹۶	۰/۸۰۱	R	



شکل ۳- نمودار راداری شاخص RMSE برای مدل‌های WANN در سطوح تجزیه L1 و L2 و مدل منفرد ANN در مرحله آزمون برای مقیاس زمانی سه ماهه

حاصل در جداول ۶ و ۷ به ترتیب برای سطح تجزیه یک L1 و دو L2 ارائه شده است.

در این مطالعه مدل WSVM نیز با همان ضرایب تعیین شده در حالت منفرد مدل SVM اجرا و نتایج

جدول ۶- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از مدل WSVM در سطح یک تجزیه

مرحله آموزش				مرحله آزمون				آماره	ایستگاه
SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3	SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3		
۰/۲۳۰	۰/۲۶۳	۰/۴۳۴	۰/۶۱۴	۰/۲۱۹	۰/۲۸۷	۰/۳۸۲	۰/۵۸۸	RMSE	داشبند بوکان
۰/۱۵۲	۰/۱۹۵	۰/۳۰۱	۰/۴۷۷	۰/۱۵۰	۰/۲۱۸	۰/۲۶۹	۰/۴۵۶	MAE	
۰/۹۱۴	۰/۹۱۰	۰/۸۴۱	۰/۷۵۶	۰/۹۷۷	۰/۹۶۰	۰/۹۳۱	۰/۸۰۳	R	
۰/۳۵۸	۰/۴۲۰	۰/۵۸۱	۰/۶۸۷	۰/۲۵۷	۰/۳۶۱	۰/۴۵۱	۰/۵۷۵	RMSE	تازه کند میاندوآب
۰/۲۵۰	۰/۳۱۳	۰/۴۲۰	۰/۵۳۷	۰/۱۹۰	۰/۲۶۴	۰/۳۲۶	۰/۴۳۸	MAE	
۰/۹۱۲	۰/۸۹۸	۰/۸۴۱	۰/۸۱۴	۰/۹۶۹	۰/۹۳۶	۰/۸۹۹	۰/۸۰۱	R	
۰/۲۷۱	۰/۳۴۱	۰/۵۵۷	۰/۸۳۴	۰/۱۸۲	۰/۲۵۰	۰/۳۶۲	۰/۵۴۷	RMSE	کاولان
۰/۱۸۰	۰/۲۳۸	۰/۳۸۳	۰/۵۸۴	۰/۱۲۶	۰/۱۷۷	۰/۲۷۸	۰/۴۳۲	MAE	
۰/۹۵۲	۰/۹۲۶	۰/۸۲۶	۰/۶۳۶	۰/۹۷۹	۰/۹۶۲	۰/۹۲۰	۰/۸۰۸	R	
۰/۳۰۲	۰/۳۰۹	۰/۴۶۲	۰/۷۱۰	۰/۲۱۸	۰/۲۹۸	۰/۳۸۷	۰/۵۸۱	RMSE	قرل‌گنبد
۰/۱۹۹	۰/۲۳۷	۰/۳۳۰	۰/۵۰۰	۰/۱۵۳	۰/۲۲۰	۰/۲۷۷	۰/۴۳۴	MAE	
۰/۹۰۲	۰/۹۱۳	۰/۸۵۴	۰/۷۱۲	۰/۹۷۹	۰/۹۵۸	۰/۹۲۸	۰/۸۰۲	R	
۰/۳۳۷	۰/۴۱۶	۰/۵۵۳	۰/۸۵۲	۰/۲۳۳	۰/۳۰۰	۰/۳۹۵	۰/۵۷۸	RMSE	منوچهر
۰/۲۲۶	۰/۳۲۵	۰/۴۰۶	۰/۶۱۷	۰/۱۶۶	۰/۲۲۰	۰/۳۰۴	۰/۴۳۶	MAE	
۰/۹۲۷	۰/۹۰۳	۰/۸۵۴	۰/۷۰۵	۰/۹۷۵	۰/۹۵۷	۰/۹۲۱	۰/۷۹۲	R	
۰/۳۱۴	۰/۳۴۴	۰/۵۳۸	۰/۶۳۷	۰/۲۶۳	۰/۳۴۶	۰/۴۶۱	۰/۵۷۷	RMSE	رحیم‌خان
۰/۲۰۹	۰/۲۴۸	۰/۳۶۳	۰/۴۹۳	۰/۱۹۰	۰/۲۶۲	۰/۳۳۹	۰/۴۴۴	MAE	
۰/۹۲۷	۰/۹۱۶	۰/۸۳۱	۰/۷۸۸	۰/۹۶۷	۰/۹۴۲	۰/۸۹۴	۰/۸۰۲	R	


جدول ۷- نتایج آماری پیش‌بینی خشکسالی‌های حوضه آبریز با استفاده از مدل WSVM در سطح دو تجزیه

مرحله آموزش				مرحله آزمون				آماره	ایستگاه
SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3	SPIIm-12	SPIIm-9	SPIIm-6	SPIIm-3		
۰/۲۲۵	۰/۲۵۴	۰/۳۹۹	۰/۶۰۴	۰/۲۱۰	۰/۲۷۶	۰/۳۷۰	۰/۵۷۹	RMSE	داشبند بوکان
۰/۱۵۲	۰/۱۹۰	۰/۲۸۸	۰/۴۷۰	۰/۱۴۵	۰/۲۱۶	۰/۲۶۸	۰/۴۴۵	MAE	
۰/۹۱۸	۰/۹۱۶	۰/۸۶۳	۰/۷۶۵	۰/۹۷۹	۰/۹۶۳	۰/۹۳۶	۰/۸۱۰	R	
۰/۳۴۹	۰/۴۰۹	۰/۵۴۱	۰/۶۸۵	۰/۲۲۶	۰/۳۳۳	۰/۴۲۲	۰/۵۵۹	RMSE	تازه کند میاندوآب
۰/۲۴۸	۰/۳۰۲	۰/۴۰۹	۰/۵۳۸	۰/۱۶۹	۰/۲۵۲	۰/۳۱۷	۰/۴۲۲	MAE	
۰/۹۱۷	۰/۹۰۳	۰/۸۶۳	۰/۸۱۴	۰/۹۷۶	۰/۹۴۶	۰/۹۱۲	۰/۸۱۳	R	
۰/۲۵۲	۰/۲۹۲	۰/۴۹۸	۰/۸۸۲	۰/۱۶۸	۰/۲۶۴	۰/۳۴۲	۰/۵۰۰	RMSE	کاولان

۰/۱۷۴	۰/۲۱۳	۰/۳۶۹	۰/۶۲۴	۰/۱۱۷	۰/۱۸۵	۰/۲۶۵	۰/۳۹۱	MAE	
۰/۹۵۸	۰/۹۴۳	۰/۸۶۳	۰/۵۸۵	۰/۹۸۲	۰/۹۵۷	۰/۹۲۹	۰/۸۴۲	R	
۰/۲۷۹	۰/۲۹۰	۰/۴۳۶	۰/۶۸۰	۰/۲۰۵	۰/۲۸۳	۰/۳۷۱	۰/۵۸۳	RMSE	
۰/۱۸۲	۰/۲۲۶	۰/۳۰۲	۰/۴۹۶	۰/۱۴۶	۰/۲۱۵	۰/۲۶۲	۰/۴۴۴	MAE	قرزل گنبد
۰/۹۱۶	۰/۹۲۴	۰/۸۶۹	۰/۷۳۸	۰/۹۸۱	۰/۹۶۲	۰/۹۳۴	۰/۸۰۰	R	
۰/۳۲۶	۰/۳۷۴	۰/۵۳۸	۰/۸۵۶	۰/۲۲۰	۰/۲۹۱	۰/۳۴۴	۰/۵۵۵	RMSE	
۰/۲۲۴	۰/۲۹۲	۰/۳۹۶	۰/۶۱۸	۰/۱۵۹	۰/۲۲۸	۰/۲۵۹	۰/۴۲۵	MAE	منوچهر
۰/۹۳۱	۰/۹۲۰	۰/۸۶۵	۰/۷۰۰	۰/۹۷۸	۰/۹۵۹	۰/۹۴۱	۰/۸۱۱	R	
۰/۳۰۹	۰/۳۴۰	۰/۵۱۳	۰/۶۳۳	۰/۲۴۰	۰/۳۲۳	۰/۴۳۵	۰/۵۳۱	RMSE	
۰/۲۱۰	۰/۲۳۹	۰/۳۶۱	۰/۴۸۳	۰/۱۷۶	۰/۲۵۳	۰/۳۱۹	۰/۴۰۹	MAE	رحیم خان
۰/۹۲۹	۰/۹۱۸	۰/۸۴۷	۰/۷۹۱	۰/۹۷۲	۰/۹۴۹	۰/۹۰۶	۰/۸۳۵	R	

می‌شود که مقدار RMSE از ۰/۹۸۰ به ۰/۶۰۴ کاهش یافته است. برای سایر مقیاس‌های زمانی نیز مشاهده می‌شود که عملکرد مدل WSVM در سطح تجزیه L2 بهتر از L1 می‌باشد.

نتایج نشان می‌دهد که به مانند مدل ANN، کاربرد تجزیه موجکی در بهبود عملکرد مدل SVM بسیار تاثیرگذار بوده و خطا را به مقدار قابل توجهی کاهش داده است. در شکل ۴ برای مقیاس سه ماهه مشاهده



شکل ۴ - نمودار راداری شاخص RMSE برای مدل‌های WANN در سطوح تجزیه L1 و L2 و مدل منفرد ANN در مرحله آزمون برای مقیاس زمانی سه ماهه

آبریز سیمینه‌رود وجود ندارد. بنابراین می‌توان پیشنهاد داد که هر دو مدل با هیبرید موجکی می‌توانند گزینه مناسبی برای پیش‌بینی خشکسالی‌های حوضه آبریز سیمینه‌رود باشند. اما اگر چنانچه مدت زمان اجرا و نیز شرایط کاربرد مدل‌ها در نظر گرفته شود می‌توان

نتیجه‌گیری:

با مقایسه هر دو مدل WANN و WSVM مشاهده می‌شود که عملکرد هر دو مدل بسیار نزدیک به یکدیگر می‌باشد و عملاً هیچ تفاوت معنی‌داری بین مدل‌های فوق در پیش‌بینی خشکسالی‌های حوضه

کوتاه مدت نظیر ۳ و ۶ ماه اندکی بهتر از WANN است. همچنین شایان ذکر است که در اکثر ایستگاه‌ها و مقیاس زمانی مدل WSVM با سطح تجزیه L2 به بهترین عملکرد خود دست یافته و از این رو در این مطالعه به عنوان مدل نهایی انتخاب شده است.

چنین نتیجه گرفت که مدل WSVM هم زمان کمتری برای اجرا نیاز دارد و هم مانند مدل WANN نیاز به پیش فرض‌های مختلف نظیر تعداد لایه پنهان، نوع تابع محرک و نوع تابع یادگیری ندارد از این رو می‌تواند به عنوان مدل برتر شناخته شود. ضمن اینکه مدل WSVM در مقیاس‌های زمانی

منابع:

- ۱- رستمی، م.، پهلوانروی، ا.، مقدم نیا، ا. ۱۳۹۴. پیش‌بینی خشکسالی با بکارگیری از مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در حوزه مَند استان فارس. مجله مخاطرات محیط طبیعی. ۴(۶): ۳۲-۲۱.
- ۲- سلگی، ا.، زارعی، ج.، گلایی، م. ۱۳۹۶. بررسی عملکرد مدل برنامه ریزی بیان ژن با روش‌های پیش‌پردازش داده‌ها جهت مدل‌سازی جریان رودخانه. مجله پژوهش‌های حفاظت آب و خاک، ۲۴(۲): ۱۸۵-۲۰۱.
- ۳- صمدیان فرد، س.، اسدی، ا. ۱۳۹۶. پیش‌بینی نمایه خشکسالی SPI به روش‌های رگرسیون بردار پشتیبان و خطی چندگانه. نشریه حفاظت منابع آب و خاک. ۶(۴): ۱۶-۱.
- ۴- عباسی، ع.، خلیلی، ک.، بهمنش، ج.، شیرزاد، ا. ۱۳۹۹. مقایسه روش‌های شبکه‌های عصبی مصنوعی، شبکه بیزین و برنامه ریزی بیان ژن در پیش‌بینی خشکسالی (مطالعه موردی: ایستگاه سینوپتیک مراغه). پژوهشنامه مدیریت حوزه آبخیز. ۱۱ (۲۱): ۷۱-۵۹.
- ۵- علیزاده، ا.، ۱۳۸۷. هوا و اقلیم شناسی، چاپ یازدهم، دانشگاه فردوسی مشهد، صفحه ۳۰۵.
- 6- Hoyt, J. C. (1936). Droughts of 1930-34 (No. 680). Govt. Print. Off.
- Kao, S. C., & Govindaraju, R. S. (2010). A copula-based joint deficit index for droughts. *Journal of Hydrology*, 380(1-2), 121-134.
- 7- Mantero, P., Moser, G., & Serpico, S. B. (2005). Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 559-570.
- 8- Mehdizadeh, S., Ahmadi, F., Mehr, A. D., & Safari, M. J. S. (2020). Drought modeling using classic time series and hybrid wavelet-gene expression programming models. *Journal of Hydrology*, 587, 125017.
- 9- Pandey, R. P., Mishra, S. K., Singh, R., & Ramasastri, K. S. (2008). Streamflow drought severity analysis of Betwa river system (India). *Water resources management*, 22(8), 1127-1141.
- 10- Parmar, K. S., Makkhan, S. J. S., & Kaushal, S. (2019). Neuro-fuzzy-wavelet hybrid approach to estimate the future trends of river water quality. *Neural Computing and Applications*, 31(12), 8463-8473.
- 11- Shin, K. S., Lee, T. S., & Kim, H. J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert systems with applications*, 28(1), 127-135.
- 12- Sun, Y., Niu, J., & Sivakumar, B. (2019). A comparative study of models for short-term streamflow forecasting with emphasis on wavelet-based approach. *Stochastic Environmental Research and Risk Assessment*, 33(10), 1875-1891.

- 13- Tayyab, M., Zhou, J., Dong, X., Ahmad, I., & Sun, N. (2019). Rainfall-runoff modeling at Jinsha River basin by integrated neural network with discrete wavelet transform. *Meteorology and Atmospheric Physics*, 131(1), 115-125.
- 14- Wang, W., & Ding, J. (2003). Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 1(1), 67-71.
- 15- Wu, H., Hayes, M. J., Weiss, A., & Hu, Q. I. (2001). An evaluation of the Standardized Precipitation Index, the China-Z Index and the statistical Z-Score. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 21(6), 745-758.
- 16- Yaseen, Z. M., Sulaiman, S. O., Deo, R. C., & Chau, K. W. (2019). An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology*, 569, 387-408.

Development of a Wavelet Hybrid Models for Estimating Regional Droughts in Siminehroud Basin

Erfan Rostam zade¹, Alireza Parvishi^{2*}

1- M.Sc. of Water Recourse Management Engineering, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

2- Assistant Professor, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

a.parvishi@gmail.com

Abstract

In the present study, the drought of Simnehroud basin was investigated by intelligent support vector machine (SVM) models, artificial neural network (ANN) and wavelet theory (W). Data from six rain gauge stations in the region were used and drought index was calculated in four time scales. The first-order autocorrelation was also selected as the optimal delay. Then the appropriate structure of the artificial neural network was determined using trial and error method and the three coefficients of the SVM model were determined and modeled. The results of evaluating individual models showed that there is no significant difference between the two methods in predicting droughts. Then WANN and WSVM hybrid models were prepared. The results showed that the application of wavelet theory greatly improved the performance of individual models and the amount of RMSE and MAE indices decreased by 19 and 21% and the correlation coefficient increased by 30%, respectively.

Keywords: *Decomposition level, Modified standardized precipitation index, Hybrid models, Standalone models.*