

کاربرد الگوریتم هیبریدی ماشین بردار پشتیبان حداقل مربعات-نهنگ (LSSVM_WOA) جهت ریزمقیاس‌نمایی و پیش‌بینی بارش تحت شرایط تغییر اقلیم (مطالعه موردی: حوضه کارون ۳)

مهدی ولیخان انارکی^۱، سعید فرزین^{۲*}، سید فرهاد موسوی^۳، حجت کرمی^۴

تاریخ ارسال: ۱۳۹۷/۱۲/۲۱

تاریخ پذیرش: ۱۳۹۸/۰۵/۰۶

مقاله پژوهشی برگرفته از پایان نامه کارشناسی ارشد

چکیده

در پژوهش حاضر، با استفاده از روش‌های یادگیری شامل الگوریتم هیبریدی ماشین بردار پشتیبان حداقل مربعات و الگوریتم بهینه‌سازی نهنگ (LSSVM_WOA)، K نزدیکترین همسایه (KNN) و شبکه عصبی مصنوعی (ANN) اقدام به ریزمقیاس‌نمایی بارش در شش ایستگاه حوزه کارون ۳ پرداخته شده است. برای ریزمقیاس‌نمایی بارش، ابتدا روزهای سال با استفاده از الگوریتم‌های MARS و درخت مدل M5 به روزهای تر و خشک تقسیم می‌شوند. سپس، مقدار بارش برای روزهای تر با استفاده از هر یک از روش‌های LSSVM_WOA، KNN و ANN تخمین زده می‌شود. نتایج پژوهش حاکی از برتری الگوریتم MARS نسبت به M5 می‌باشد. همچنین، براساس میانگین بارش شش ایستگاه الگوریتم ANN با ۰/۵ درصد ضریب‌نش بیشتر، اندکی بهتر از الگوریتم LSSVM_WOA عمل می‌کند. در حالی که با در نظر گرفتن میانگین انحراف معیار مقدار ضریب‌نش برای الگوریتم ANN تا ۵/۰۴ درصد دقیق‌تر از الگوریتم LSSVM_WOA است. در نهایت مقدار بارش برای افق‌های ۲۰۲۰-۲۰۴۰ و ۲۰۷۰-۲۱۰۰ تحت سناریوهای مدل CanESM2 شامل RCP2.6، RCP4.5 و RCP8.5 پیش‌بینی شده است. نتایج حاصل از الگوریتم LSSVM_WOA حاکی از کاهش بارش نسبت به دوره پایه (۲۰۰۱-۱۹۷۲) تحت هر سه سناریو می‌باشد. بیشترین مقدار کاهش بارش برابر با ۱۸ درصد و برای سناریو RCP8.5 در افق ۲۰۷۰-۲۱۰۰ محاسبه شده است. کمترین مقدار کاهش بارش (۱ درصد) نیز مربوط به سناریو RCP2.6 در افق ۲۰۲۰-۲۰۴۰ می‌باشد. اما مقدار تغییرات بارش پیش‌بینی شده توسط ANN در دوره آینده نسبت به دوره پایه از ۴۳- درصد تا ۷۲ درصد تغییر می‌کند. بنابراین، جواب‌های حاصل از LSSVM_WOA به دلیل عدم قطعیت کمتر، قابل اعتمادتر است.

واژه‌های کلیدی: LSSVM_WOA، بارش، ریزمقیاس‌نمایی، پیش‌بینی، تغییر اقلیم.

^۱ گروه مهندسی و مدیریت منابع آب، دانشکده سمنان، دانشگاه سمنان، سمنان، ایران، mvalikhan@semnan.ac.ir

^۲ گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، سمنان، ایران saeed.farzin@semnan.ac.ir (نویسنده مسئول).

^۳ گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، سمنان، ایران، fmousavi@semnan.ac.ir

^۴ گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، سمنان، ایران. hkarami@semnan.ac.ir

مقدمه

در چند دهه اخیر به دلیل افزایش عواملی مانند فعالیت‌های انسانی، رشد جمعیت و انتشار گازهای گلخانه‌ای، بیشتر مناطق زمین با افزایش میانگین دمای سالانه حداقل تا ۲ درجه سلسیوس روبه‌رو شده‌اند. دیگر پارامترهای هیدرولوژیک نیز مانند بارش، پوشش ابر و تبخیر-تعرق با تغییرات قابل توجهی مواجه شده‌اند. این پدیده بدون هیچ تردیدی تغییر اقلیم نام دارد (Ashofteh et al., 2012). یکی از روش‌های بررسی پدیده مذکور شبیه‌سازی متغیرهای بزرگ مقیاس گردش عمومی است. لیکن، این داده‌ها قابل استفاده در مقیاس محلی نیستند. لذا، نیاز به ابزاری برای ریزمقیاس‌نمایی این متغیرها وجود دارد (آبکار و همکاران، ۱۳۹۲). در میان روش‌های ریزمقیاس‌نمایی مختلف، روش‌های رگرسیونی به دلیل هزینه و پیچیدگی محاسباتی کمتر دارای محبوبیت بالای در میان محققان می‌باشند (Chen et al., 2010).

در دهه‌های گذشته مطالعات گسترده‌ای به منظور ریزمقیاس‌نمایی متغیرهای گردش عمومی با استفاده از روش‌های رگرسیونی صورت گرفته است. Wilby et al., 1999 روش رگرسیون چند جمله‌ای را در ریزمقیاس-نمایی بارش و دما اعمال کردند. Harpham and Wilby, 2005 نیز در پژوهشی به منظور ریزمقیاس‌نمایی بارش روزانه، مدل SDSM را با شبکه‌های عصبی شعاعی و پرسپترون چندلایه مقایسه کردند که نتایج بیانگر دقت بیشتر مدل SDSM بود.

در سال‌های اخیر ماشین‌های یادگیری از جمله روش‌های ریزمقیاس‌نمایی رگرسیونی هستند که کاربردی موفق در ریزمقیاس‌نمایی پارامترهای هیدرولوژیکی مختلف مانند بارش و دما داشته‌اند. Tavakol-Davani et al., 2012 با استفاده از روش‌های داده‌کاوی بارش را در چندین ایستگاه در ایران ریزمقیاس کردند که نتایج مدل M5 دارای تطابق بیشتری با داده‌های مشاهداتی بود. در پژوهش Nasser et al., 2013 در بحث ریزمقیاس-نمایی وقوع و مقدار بارش، مقایسه‌ای بین ترکیب روش‌های مارس، مدل M5، k نزدیکترین همسایه و ماشین

بردار پشتیبان بهینه شده انجام شد. نتایج این پژوهش نشان دهنده دقت بالاتر ترکیب مدل درخت و مارس بود. Devak et al., 2015 هیبرید ماشین بردار پشتیبان و k نزدیکترین همسایه را برای ریزمقیاس‌نمایی بارش به کار بردند که روش هیبریدی مذکور سبب بهبود نتایج شد. در پژوهش Kundu et al., 2017 ماشین بردار پشتیبان حداقل مربعات را به منظور ریزمقیاس‌نمایی بارش، دما و تبخیر تعرق مرجع استفاده شد که عملکرد مطلوب ماشین بردار پشتیبان حداقل مربعات مورد تأیید قرار گرفت. در پژوهش Nourani et al., 2018 برای ریز-مقیاس‌نمایی بارش، روش‌های مختلف از جمله، ماشین بردار پشتیبان حداقل مربعات، شبکه‌های عصبی مصنوعی و رگرسیون خطی چند متغیره به کار برده شدند. روش‌های شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان حداقل مربعات از نظر بیشترین دقت در رتبه‌های اول و دوم قرار داده شدند.

ماشین‌های یادگیری از جمله الگوریتم ماشین بردار پشتیبان دارای پارامترهایی است که تأثیر زیادی به عملکرد این روش دارند. انتخاب بهینه این پارامترها با استفاده از الگوریتم‌های تکاملی می‌تواند موجب افزایش دقت این روش شود. برخی از پژوهش‌های انجام شده در سال‌های اخیر، در ادامه آورده شده است. Beheshti et al., 2015 در پیش‌بینی بارش، از هیبرید الگوریتم‌های ازدحام ذرات با شتاب مرکز گرا، جستجوی گرانشی و رقابت استعماری جهت بهینه‌سازی شبکه‌های عصبی مصنوعی پرسپترون چند لایه استفاده کردند. نتایج، بیانگر برتری هیبرید الگوریتم بهینه‌سازی ازدحام ذرات با شتاب مرکز گرا و شبکه‌های عصبی مصنوعی نسبت به دو روش دیگر بود. Al-Shammari et al., 2016 از الگوریتم هیبریدی ماشین بردار پشتیبان و کرم شبتاب برای پیش‌بینی نقطه شبنم در شهر اصفهان استفاده کردند و نشان دادند روش مذکور نسبت به ماشین بردار پشتیبان، شبکه عصبی و برنامه ریزی ژنتیک دقت بیشتری دارد. Mirjalili et al., 2016 برای نخستین بار الگوریتم نهنگ را جهت حل مسائل بهینه‌سازی مهندسی به کار بردند. نتایج نشان داد که این الگوریتم در مقایسه با الگوریتم-

۳- الگوریتم‌های LSSVM_WOA، KNN و ANN به صورت جداگانه اجرا شوند و مقدار بارش تعیین شود.

۴- با استفاده از داده‌های GCM و با توجه به گام-های ۲ و ۳، بارش برای دوره آینده تحت سناریوهای تغییر اقلیم پیش‌بینی می‌گردد.

الگوریتم بهینه‌سازی نهنگ

الگوریتم بهینه‌سازی نهنگ (Mirjalili et al., 2016) یک الگوریتم بهینه‌سازی جمعیت محور است که بر مبنای رفتار وال‌های گوژپشت در شکار دسته ماهی‌ها و میگوها عمل می‌کند. گام‌های تشکیل دهنده این الگوریتم شامل محاصره شکار و حمله شبکه حبابی می‌شود. در گام محاصره شکار، حرکت نهنگ‌ها به سمت نهنگ با بهترین موقعیت (جواب بهینه تاکنون)، با استفاده از روابط ۱ تا ۳ بیان می‌شود:

$$D = |C * X_{best}(t) - X(t)| \quad (1)$$

$$X(t+1) = X_{best}(t) - A * D \quad (2)$$

$$A = 2a * r - a, C = 2r \quad (3)$$

که t معرف شمارگان تکرارها، X موقعیت فعلی نهنگ، X_{best} بهترین موقعیت نهنگ‌ها، A و C نیز ضرایب برداری هستند. در رابطه ۵ پارامتر a با افزایش تعداد تکرارها، به صورت خطی از ۲ تا صفر کاهش پیدا می‌کند. r نیز یک عدد تصادفی با توزیع یکنواخت است. در گام حمله شبکه حبابی نهنگ‌ها از دو رویکرد محاصره تنگ‌شونده و حرکت مارپیچی استفاده می‌کنند. اما از آنجا که امکان شبیه‌سازی این دو حرکت به صورت همزمان وجود ندارد، برای هر یک از رویکردهای مذکور احتمال مساوی برابر با ۰/۵ در نظر گرفته می‌شود.

این گام به شکل رابطه زیر بیان می‌شود:

$$X(t+1) = \quad (4)$$

$$\begin{cases} X_{best}(t) - A * D & p < 0.5 \\ X(t) + D * e^{bl} * \cos(2\pi l) & p > 0.5 \end{cases}$$

که d فاصله اقلیدوسی وال تا شکار، b ثابت مربوط به شکل مارپیچ و ۱ یک عدد تصادفی با توزیع یکنواخت بین

هایی همچون ازدحام ذرات، جواب بهینه مطلق مسئله را با دقت بیشتر و با تعداد پارامترهای کمتر به دست می‌آورد. در پژوهش Du et al., 2018 نیز الگوریتم بهینه‌سازی نهنگ جهت بهینه‌سازی ماشین بردار پشتیبان حداقل مربعات در بحث پیش‌بینی انرژی الکتریکی به کار برده شد. در این پژوهش روش مذکور نسبت به روش‌های شبکه‌های عصبی رگرسیون عمومی و شبکه‌های عصبی پس انتشار خطا از دقت بیشتری برخوردار بود.

استفاده از روش‌های یادگیری به دلیل در نظر گرفتن روابط غیرخطی بین پیش‌بینی کننده‌ها و بارش می‌تواند سبب افزایش دقت ریزمقیاس‌نمایی بارش شود. در پژوهش حاضر به ریزمقیاس‌نمایی بارش حوزه آبخیز کارون ۳ با استفاده از ماشین‌های یادگیری پرداخته شده است. لذا، نوآوری پژوهش حاضر، به کار بردن ترکیب الگوریتم‌های درخت مدل M5 و MARS، جهت طبقه‌بندی بارش و الگوریتم LSSVM_WOA جهت ریزمقیاس‌نمایی مقدار بارش می‌باشد. علاوه بر این، الگوریتم‌های KNN و ANN جهت نتایج مقایسه ریزمقیاس‌نمایی مقدار بارش استفاده شده‌اند. پس از ریزمقیاس‌نمایی بارش در دو گام وقوع و مقدار بارش، عملکرد الگوریتم‌های بررسی شده در هر گام مورد ارزیابی قرار می‌گیرد و بهترین روش انتخاب می‌شود. در نهایت مقدار بارش در دو افق ۲۰۲۰ تا ۲۰۴۰ و ۲۰۷۰ تا ۲۱۰۰، تحت سناریوهای مدل CanESM2 شامل RCP2.6، RCP4.5 و RCP8.5 محاسبه می‌شود.

مواد و روش‌ها

روش ریزمقیاس‌نمایی

روش ریزمقیاس‌نمایی در پژوهش حاضر در گام‌های زیر خلاصه شده است:

۱- پیش‌بینی کننده‌های پایگاه داده‌ها با استفاده از آنالیز همبستگی انتخاب می‌شوند.

۲- الگوریتم‌های MARS و M5 اجرا و روزهای سال به دو گروه تر و خشک تقسیم می‌شوند. در این گام مقدار بارش روزهای خشک برابر با صفر قرار داده می‌شود.

الگوریتم بهینه‌سازی نهنگ با جستجو در فضای دو بعدی مسأله، موقعیتی را می‌یابد که به ازای آن بهینه‌ترین مقدار تابع هدف وجود داشته باشد. مراحل انجام این الگوریتم در ادامه شرح داده شده است:

- ۱- پارامترهای اولیه الگوریتم نهنگ شامل بیشینه جمعیت و تعداد تکرارها تعیین شود.
- ۲- جمعیت اولیه تولید گردد.
- ۳- تابع هدف بر اساس رابطه ۷ برای هر نهنگ مورد ارزیابی قرار گیرد و بهترین موقعیت (C, σ) تعیین شود.

$$Z(C, \sigma) = R_{test} \quad (7)$$

که R_{test} ضریب همبستگی خروجی مدل و داده‌های مشاهداتی در دوره‌ی آزمون می‌باشد.

- ۴- یک واحد به شمارگان اضافه گردد و موقعیت نهنگ‌ها به روز رسانی شود.

- ۵- در صورت رسیدن به شرط خاتمه (در اینجا حداکثر تعداد تکرار) الگوریتم متوقف و در غیر این صورت مراحل ۳ و ۴ تکرار شوند. شکل ۱ طرح شماتیک این الگوریتم را نشان می‌دهد.

مقاله باید شامل چکیده فارسی، واژه‌های کلیدی، مقدمه، مواد و روش‌ها، نتایج و بحث، نتیجه‌گیری، تقدیر و تشکر و منابع باشد.

۱- و ۱ می‌باشد. جهت مطالعه بیشتر به پژوهش (Mirjalili et al., 2016) مراجعه شود.

الگوریتم ماشین بردار پشتیبان حداقل مربعات

ماشین بردار پشتیبان حداقل مربعات توسط سویکنز ارائه شده است. این الگوریتم به دلیل بهره‌گیری از روش بهینه‌سازی حداقل مربعات به جای روش مرتبه دوم از پیچیدگی و هزینه کمتری نسبت روش ماشین بردار پشتیبان استاندارد برخوردار است (Suykens., 2001). این روش با نگاشت ورودی‌ها از فضایی با ابعاد پایین تر به فضایی با ابعاد بالاتر رابطه غیر خطی بین ورودی‌ها و خروجی‌ها را به یک رابطه خطی تبدیل می‌کند. این موضوع در بحث ریزمقیاس‌نمایی و حل مسائل غیر خطی سودبخش است. رابطه ۵ ارتباط رگرسیونی خطی بین ورودی‌ها (x) و خروجی‌ها (\hat{y}) را در الگوریتم ماشین بردار پشتیبان حداقل مربعات بیان می‌کند:

$$\hat{y} = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (5)$$

که α_i ، K و b به ترتیب معرف بردار پشتیبان α_m ، تابع کرنل و بایس مدل می‌باشند. تابع کرنل در مسائل غیر خطی مورد استفاده قرار می‌گیرد. تاکنون توابع کرنل مختلف از جمله توابع کرنل خطی، چند جمله‌ای، سیگموئید و شعاعی معرفی شده‌اند. اما، مطابق با مرجع (Mujumdar and Ghosh, 2008)، تابع کرنل شعاعی از عملکرد بهتری برخوردار بوده است. به همین دلیل در پژوهش حاضر از تابع کرنل شعاعی استفاده شده است. رابطه ۶ فرمول تابع کرنل شعاعی را ارائه می‌دهد:

$$K(x, x_i) = \exp\left(\frac{-\|x - x_i\|^2}{2\sigma^2}\right) \quad (6)$$

روش هیبریدی ماشین بردار پشتیبان حداقل مربعات و الگوریتم بهینه‌سازی نهنگ:

در این روش ضرایب پنالتی (C) و عرض تابع کرنل (σ) به عنوان متغیرهای تصمیم (موقعیت هر نهنگ) در الگوریتم بهینه‌سازی نهنگ در نظر گرفته می‌شوند.



شکل (۱): مراحل تعیین پارامترهای C و sigma با استفاده از الگوریتم بهینه‌سازی نهنگ

2007). این الگوریتم از یک لایه ورودی، یک یا چندین لایه پنهان و یک لایه خروجی تشکیل شده است. در این الگوریتم هر لایه نیز از تعدادی نرون تشکیل شده است. لینک‌های ارتباطی بین نرون‌ها نیز دارای یک وزن است که با جمع مقدار حاصل ضرب ورودی‌های هر نرون در وزن لینک مربوط و عبور آن از یک تابع انتقالی، یک خروجی می‌دهد. این خروجی به عنوان ورودی نرون‌های لایه بعدی استفاده می‌شود. با تنظیم لینک‌های ارتباطی در این فرآیند نزدیکترین خروجی به خروجی مشاهداتی تعیین می‌شود (Singh and V.P Singh., 2010). در پژوهش حاضر از پرسپترون چند لایه به عنوان ساختار شبکه‌های عصبی مصنوعی استفاده شده است (Ahmadi et al., 2014). روش Levenberg-Marquardt و پس-انتشار خطا نیز به عنوان روش آموزش استفاده شده است (Hadi and Tombul, 2018).

درخت مدل M5

الگوریتم درخت مدل M5 (Quinlan et al., 1992)، بر اساس ایده تقسیم فضای داده‌های اصلی به زیرمجموعه‌ها، روابط غیرخطی بین ورودی‌ها و خروجی‌ها را پیش‌بینی می‌کند. الگوریتم M5 در مرحله اول همه‌ی صفت‌ها (ورودی‌ها) را برای تولید یک زیرمجموعه بررسی می‌کند. سپس زیرمجموعه با بیشترین کاهش خطا انتخاب می‌شود. تقسیم‌بندی یا رشد درخت تا زمانی ادامه پیدا می‌کند که دیگر تغییر قابل توجهی در کاهش مقدار خطا ایجاد نشود یا تنها دو حالت برای زیرمجموعه‌ها باقی‌مانده باشد (Rezaie-balf et al., 2017). معیار

الگوریتم K نزدیکترین همسایه

الگوریتم K نزدیکترین همسایه یک روش رگرسیون ناپارامتری است. این روش بدون هیچ فرضی در مورد رابطه بین ورودی‌ها و خروجی مقدار خروجی‌ها را محاسبه می‌کند. این الگوریتم به جستجو و انتخاب K تا از شبیه‌ترین بردارهای ویژگی با داده‌های مشاهداتی می‌پردازد. این شباهت بر مبنای فاصله اقلیدوسی محاسبه می‌شود. پس از محاسبه فاصله اقلیدوسی، فرمول تابع کرنل R برای تخمین خروجی‌های مدل، به شکل رابطه ۸ قابل محاسبه است:

$$R(D_n) = \frac{1/D_n}{\sum_{j=1}^K D_{nj}} \quad (8)$$

که K تعداد داده‌های مشاهداتی با کمترین فاصله با داده‌ی پیش‌بینی شونده است. D_n نیز معرف فاصله اقلیدوسی بین داده مشاهداتی t ام و پیش‌بینی شونده τ ام است.

در ادامه برای پیش‌بینی خروجی‌ها از رابطه ۹ استفاده شده است:

$$Y_r = \sum_{i=1}^n R(D_{ij}) * Y_j \quad (9)$$

شبکه‌های عصبی مصنوعی

الگوریتم شبکه‌های عصبی مصنوعی یک سیستم پردازش اطلاعات است که با تقلید از انتقال اطلاعات نرون‌های سیستم‌های بیولوژیکی، عمل می‌کند (Lee et al.,

دارد. به منظور کاهش خطای مدل و غلبه بر مشکل پیش‌برازش تعداد شاخه‌های اضافی درخت در گام هرس حذف می‌شوند. این مرحله تا جایی ادامه پیدا می‌کند که دیگر کاهش در خطای مدل مشاهده نشود.

رگرسیون تطبیقی چندگانه اسپیلاین (MARS)

روش رگرسیون تطبیقی چندگانه اسپیلاین (MARS) یک روش رگرسیون غیر پارامتریک است که اولین بار توسط (Friedman., 1991) معرفی شد. این الگوریتم دارای توانایی بیان روابط غیرخطی و پیچیده بین ورودی‌ها مربع را زهکشی می‌کند. دبی رودخانه کارون بزرگ در محل احداث سد کارون ۳ در حدود ۳۰۰ متر مکعب بر ثانیه می‌باشد.

شکل ۲ موقعیت حوضه کارون ۳ را در حوضه کارون بزرگ و موقعیت ایستگاه‌های بررسی شده در حوضه کارون ۳ را نشان می‌دهد.

به منظور آموزش و آزمون الگوریتم‌های به کار برده شده علاوه بر بارش مشاهداتی، از پیش‌بینی کننده‌های بزرگ‌مقیاس پایگاه داده‌های NCEP استفاده شده است

کاهش انحراف معیار SDR با استفاده از رابطه ۱۰ محاسبه می‌شود:

$$SDR = SD(T) - \sum_i \frac{|T_i|}{|T|} SD(T_i) \quad (10)$$

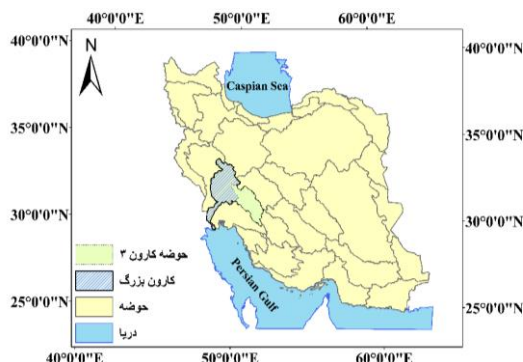
که T مجموعه وارد شده به گره، T_i نمونه‌های تقسیم شده از گره بر اساس صفت مورد نظر و SD مقدار انحراف معیار است. در ادامه، برای هر یک از زیرمجموعه‌های تولید شده در انتهای هر گره یا برگ یک رابطه رگرسیون خطی برازش داده می‌شود. در نهایت، به دلیل تعداد زیاد گره‌ها یا برگ‌های تولید شده امکان پیش‌برازش وجود و خروجی‌ها می‌باشد. الگوریتم MARS با استفاده از استراتژی تقسیم و حل ورودی‌ها را در دوره آموزش تقسیم بندی می‌کند و برای هر قسمت یک رابطه رگرسیونی پله‌ای تشکیل می‌دهد (Rezaie-Balf et al., 2017). همچنین الگوریتم در دو گام پیشرو و پسرو رابطه بین ورودی‌ها و خروجی‌ها را تخمین می‌زند. در فاز پیشرو یک مدل با تعداد زیادی رابطه تشکیل و در فاز پسرو روابط اضافی حذف می‌شوند. فاز پسرو باعث افزایش دقت مدل و جلوگیری از پیش‌برازش می‌شود. برای مطالعه بیشتر به پژوهش (Nasseri et al., 2013) مراجعه شود.

مطالعه موردی

مطالعه موردی در پژوهش حاضر، حوضه کارون ۳ می‌باشد. این حوضه منطقه‌ای به وسعت ۲۴۰۰۰ کیلومتر



ب.



الف.

شکل (۲): حوزه کارون ۳، الف) موقعیت حوزه کارون ۳ در حوزه کارون بزرگ و ب) موقعیت ایستگاه‌های بررسی شده

خطای صفر و دقت بالای مدل است (Singh et al., 2004). معیار (Refined Willmott index) d_r بیانگر اختلاف بین بزرگی خروجی‌های مدل شده و مشاهداتی می‌باشد. هر چه مقدار این معیار به صفر نزدیک‌تر باشد دقت مدل بیشتر است و مقدار منفی برای آن نشان دهنده عملکرد ضعیف مدل است. برای محاسبه d_r مقدار میانگین مطلق خطا و میانگین مطلق انحرافات از روابط ۱۴ و ۱۵ حاصل می‌شوند.

قدرت تفکیک مکانی NCEP ۲/۵ درجه طولی در ۲/۵ درجه عرضی است. همچنین برای بررسی اثر تغییر اقلیم از سناریوهای مدل CanESM2 (با قدرت تفکیک ۲/۸۱۲۵ درجه طولی در ۲/۸۱۲۵ درجه عرضی) شامل RCP2.6، RCP4.5 و RCP8.5 استفاده شده است. داده‌های مذکور از سایت تغییر اقلیم کانادا (CCCSN) (<http://www.cccsn.ec.gc.ca>) دانلود شده است. دوره ۱۹۷۲ تا ۲۰۰۲ جهت آموزش (۷۰ درصد داده‌ها) و آزمون (۳۰ درصد داده‌ها) استفاده شده است. همچنین برای بررسی تغییر اقلیم، از دوره ۲۰۲۰ تا ۲۰۴۰ به منظور برنامه‌ریزی‌های کوتاه مدت و دوره ۲۰۷۰ تا ۲۱۰۰ جهت برنامه‌ریزی‌های بلند مدت استفاده شده است.

معیارهای ارزیابی

به منظور بررسی عملکرد مدل‌های ارائه شده از معیارهای ارزیابی شامل ضریب همبستگی پیرسون R ، مجذور میانگین مربعات نسبی d_r و ضریب نش استفاده شده است. معیارهای مذکور به ترتیب در روابط ۱۱، ۱۲، ۱۳ و ۱۶ بیان شده‌اند. معیار RRMSE در رابطه ۱۲ نرمالایز شده معیار RMSR می‌باشد و مقدار بهینه آن برابر با صفر و نشان دهنده‌ی مجذور میانگین مربعات

$$R = \frac{\sum_{i=1}^n (O_{obs i} - \overline{O_{obs i}})(O_{pred i} - \overline{O_{pred i}})}{\sqrt{\sum_{i=1}^n (O_{obs i} - \overline{O_{obs i}})^2 \sum_{i=1}^n (O_{pred i} - \overline{O_{pred i}})^2}} \quad (11)$$

$$RRMSE = RMSE / std_{obs} = \frac{\sqrt{\sum_{i=1}^n (O_{obs i} - O_{pred i})^2}}{\sqrt{\sum_{i=1}^n (O_{obs i} - \overline{O_{obs}})^2}} \quad (12)$$

$$d_r = \begin{cases} 1 - MAE / 2MAD, & MAE \leq 2MAD \\ 2MAD / MAE - 1, & 2MAD \leq MAE \end{cases} \quad (13)$$

$$MAE = \sum_{i=1}^n |(O_{obs i} - O_{pred i})| / N \quad (14)$$

$$MAD = \sum_{i=1}^n |(O_{obs i} - \overline{O_{obs i}})| / N \quad (15)$$

$$NC = 1 - \frac{\sum_{i=1}^n (O_{obs} - O_{pred})^2}{\sum_{i=1}^n (O_{obs} - \overline{O_{obs}})^2} \quad (16)$$

در جدول ۲ نمایش داده شده است. در این جدول بیشترین همبستگی مربوط به رطوبت نسبی در تراز ۵۰۰ هکتوپاسکال با مقدار ۰/۵۳۹ و کمترین آن مربوط به سرعت مداری در تراز ۵۰۰ هکتوپاسکال با مقدار ۰/۲۵۹ می‌باشد. علاوه بر این متغیرهای انتخاب شده در دیگر پژوهش‌ها مانند (Tavakol-Davani., et al., 2012) برای ریزمقیاس‌نمایی بارش استفاده شده‌اند

که O_{pred} ، $\overline{O_{pred}}$ ، O_{obs} ، $\overline{O_{obs}}$ به ترتیب خروجی مشاهداتی، میانگین خروجی مشاهداتی، خروجی مدل و میانگین خروجی مدل می‌باشند.

نتایج و بحث

در پژوهش حاضر از آنالیز همبستگی برای انتخاب پیش‌بینی‌کننده‌ها استفاده شده است. از آنجا که تعداد ایستگاه‌ها زیاد است، به صورت خلاصه مشخصات مربوط به پیش‌بینی‌کننده‌های انتخاب شده برای ایستگاه ارمند

جدول (۲): مشخصات پیش‌بینی‌کننده‌های انتخاب شده در ایستگاه ارمند

نام متغیر	تأخیر	طول	عرض	ضریب
رطوبت نسبی در تراز ۵۰۰ هکتوپاسکال	۰	۴۷/۸۱۰	۳۴/۸۸۰	۰/۵۳۹
سرعت نصف‌النهاری در سطح زمین	۰	۵۳/۴۴۰	۲۹/۳۰۰	۰/۳۹۷
سرعت مداری در تراز ۸۵۰ هکتوپاسکال	۰	۵۳/۴۴۰	۲۹/۳۰۰	۰/۳۹۷
رطوبت ویژه در سطح زمین	۰	۴۷/۸۱۰	۳۴/۸۸۰	۰/۳۳۴
سرعت مداری در تراز ۵۰۰ هکتوپاسکال	۰	۵۳/۴۴۰	۳۴/۸۸۰	۰/۳۱۸
رطوبت نسبی در سطح زمین	۰	۵۳/۴۴۰	۳۴/۸۸۰	۰/۳۱۲
واگرایی در تراز ۸۵۰ هکتوپاسکال	۱	۵۰/۶۳۰	۳۴/۸۸۰	-۰/۳۰۴
قدرت جریان هوا در تراز ۵۰۰ هکتوپاسکال	۰	۵۰/۶۳۰	۳۴/۸۸۰	۰/۲۹۸
ارتفاع ژئوپتانسیل در تراز ۵۰۰ هکتوپاسکال	۰	۵۰/۶۳۰	۲۹/۳۰۰	-۰/۲۸۲
سرعت مداری در سطح زمین	۱	۵۰/۶۳۰	۳۴/۸۸۰	-۰/۲۷۹
چرخندگی در سطح زمین	۱	۵۳/۴۴۰	۲۹/۳۰۰	-۰/۲۶۳
سرعت مداری در تراز ۵۰۰ هکتوپاسکال	۰	۵۰/۶۳۰	۳۴/۸۸۰	۰/۲۵۹

نیز بیشترین و کمترین مقدار به ترتیب برابر با ۱۰۰ و ۰/۰۱ محاسبه شده است. این تغییرات برای ضریب پنالتی و عرض تابع کرنل در ماه‌های مختلف نشان‌گر تغییرات پراکندگی سری زمانی بارش در ماه‌های مختلف است

مقادیر بهینه ضریب پنالتی و عرض تابع کرنل در جدول ۳ ارائه شده است. با توجه به نتایج، مقدار ضریب پنالتی به دست آمده برای ماه‌ها و ایستگاه‌های مختلف در محدوده ۰/۰۱ تا ۱۰۰ قرار دارد. در مورد عرض تابع کرنل

جدول (۳): نتایج آنالیز حساسیت پارامترهای الگوریتم بهینه‌سازی نهنگ در ایستگاه‌های بررسی شده

ماه	پارامتر	ارمند	بارز	دهکده شهید	پاتاوه	شهرکرد	ياسوج
ژانویه	ضریب پنالتی	۰/۴۴	۰/۷۹	۵/۵۲	۱۰۰/۰۰	۴/۳۵	۱/۲۴
	عرض تابع کرنل	۸/۷۵	۳/۷۹	۱۰/۳۴	۲۱/۷۰	۱۳/۱۵	۸/۳۴
فوریه	ضریب پنالتی	۱۰۰/۰۰	۰/۱۳	۱۰۰/۰۰	۰/۱۴	۲۲/۵۶	۰/۳۱
	عرض تابع کرنل	۹۰/۰۰	۵/۷۳	۷۳/۹۸	۳/۲۸	۷/۹۶	۳/۶۹
مارس	ضریب پنالتی	۰/۱۶	۲/۹۶	۱۰۰/۰۰	۱/۲۵	۰/۷۲	۱/۰۴
	عرض تابع کرنل	۲/۰۸	۱/۷۶	۵/۹۴	۱۷/۸۷	۲/۸۶	۳/۵۵
آوریل	ضریب پنالتی	۱۰۰/۰۰	۱۰۰/۰۰	۱۰۰/۰۰	۰/۳۵	۹/۱۰	۱/۷۴
	عرض تابع کرنل	۱۸/۳۵	۲۶/۳۷	۱۲/۲۱	۱/۹۱	۲۲/۶۲	۳۹/۸۶
مه	ضریب پنالتی	۵/۵۷	۳/۵۶	۱۰۰/۰۰	۰/۱۴	۶/۴۴	۱/۳۷
	عرض تابع کرنل	۱۲/۶۱	۵/۲۶	۷/۲۱	۲/۳۲	۱۰/۰۶	۱/۲۴
ژوئن	ضریب پنالتی	-	۱۰۰/۰۰	۰/۰۱	-	۱۳/۷۶	۰/۵۳
	عرض تابع کرنل	-	۱/۸۹	۲/۱۷	-	۱۰۰/۰۰	۲/۸۹
ژوئیه	ضریب پنالتی	-	۱۰۰/۰۰	۰/۳۲	۰/۰۱	۰/۰۱	۶۷/۹۵
	عرض تابع کرنل	-	۲۱/۲۴	۱/۹۷	۰/۰۱	۱۰۰/۰۰	۰/۰۱
آگوست	ضریب پنالتی	-	-	۰/۰۱	-	۰/۰۱	-
	عرض تابع کرنل	-	-	۰/۶۱	-	۳/۵۹	-
سپتامبر	ضریب پنالتی	-	-	-	-	۴/۵۲	-
	عرض تابع کرنل	-	-	-	-	۱۰۰/۰۰	-
اکتبر	ضریب پنالتی	۱۰۰/۰۰	۱۲/۹۱	۰/۳۰	۱۰۰/۰۰	۱۰۰/۰۰	۱/۰۴
	عرض تابع کرنل	۸/۷۱	۶/۲۲	۳/۵۵	۲/۹۸	۹/۶۷	۴/۷۸
نوامبر	ضریب پنالتی	۱۰۰/۰۰	۱۰۰/۰۰	۳/۷۳	۱۰۰/۰۰	۰/۹۶	۴/۲۹
	عرض تابع کرنل	۱۵/۷۴	۱۴/۴۰	۳/۱۹	۶/۶۲	۴/۲۹	۵/۴۶
دسامبر	ضریب پنالتی	۳۵/۷۲	۰/۰۵	۰/۲۳	۰/۱	۳۵/۵۰	۰/۱۸
	عرض تابع کرنل	۱۰۰/۰۰	۳/۱۷	۱/۵۷	۲/۵۹	۱۰۰/۰۰	۴/۰۱

دقت قابل قبول ۰/۷ می‌باشد (Chen et al., 2010). در این شکل، هر دو الگوریتم در طبقه‌بندی روزهای تر و خشک در دوره آموزش و همچنین، روزهای خشک در دوره آزمون از دقت بالا و نزدیک برخوردار می‌باشند.

در جدول ۴ دقت مربوط به طبقه‌بندی بارش (بر حسب درصد) با استفاده از الگوریتم‌های MARS و M5 در ایستگاه‌های مختلف ارائه شده است.

این دقت بر مبنای نسبت روزهای درست تعیین شده به کل روزها دوره آماری سنجیده می‌شود. حداقل مقدار

جدول (۴): نتایج دقت طبقه‌بندی روزهای تر و خشک

مدل	نوع طبقه‌بندی	ارمند	بارز	دهکده شهید	پاتاوه	شهرکرد	یاسوج
MARS	روزهای تر	۰/۹۱۶	۰/۸۹۵	۰/۸۵۶	۰/۷۹۸	۰/۷۹۹	۰/۸۷۷
M5	روزهای تر	۰/۹۳۱	۰/۹۲۳	۰/۹۲۱	۰/۸۴۱	۰/۸۷۶	۰/۸۷۷
MARS	روزهای خشک	۰/۷۸۲	۰/۷۹۰	۰/۸۲۴	۰/۸۵۳	۰/۸۹۵	۰/۷۶۷
M5	روزهای خشک	۰/۹۶۶	۰/۹۶۵	۰/۹۵۳	۰/۹۷۵	۰/۹۷۸	۰/۹۱۰
MARS	روزهای تر	۰/۸۳۶	۰/۷۸۱	۰/۸۱۰	۰/۷۶۵	۰/۸۳۴	۰/۸۸۸
M5	روزهای تر	۰/۵۳۴	۰/۵۰۰	۰/۵۱۸	۰/۶۱۷	۰/۵۸۷	۰/۵۶۳
MARS	روزهای خشک	۰/۸۱۱	۰/۸۲۳	۰/۸۰۵	۰/۸۱۳	۰/۸۴۶	۰/۷۲۴
M5	روزهای خشک	۰/۹۲۴	۰/۹۴۱	۰/۹۳۵	۰/۹۰۹	۰/۹۳۵	۰/۹۲۴

تخمین زده است. بنابراین با توجه به نتایج، عملکرد هر سه روش مورد تأیید می‌باشد.

با بررسی نتایج این جدول در دوره آزمون، می‌توان دریافت که الگوریتم LSSVM_WOA مقدار ضریب R، RRMSE، dr و NSC را در محدوده ۰/۹۰۷ تا ۰/۹۹۳، ۰/۱۱۷ تا ۰/۴۲۴، ۰/۸۸۱ تا ۰/۹۵۳ و ۰/۸۰۴ تا ۰/۹۸۵، محاسبه می‌کند. این مقادیر توسط الگوریتم KNN در حدود ۰/۹۴۸ تا ۰/۹۸۴، ۰/۲۹۴ تا ۰/۵۸۶، ۰/۷۹۱ تا ۰/۸۹۳ و ۰/۶۲۵ تا ۰/۹۱۵ می‌باشد. در مورد الگوریتم ANN، نیز مقدار معیار R، RRMSE، dr و NSC در محدوده ۰/۹۷۳ تا ۰/۹۸۳، ۰/۱۸۳ تا ۰/۳۵۳، ۰/۸۶۸ تا ۰/۹۲۹ و ۰/۸۲۶ تا ۰/۹۶۶ محاسبه شده است. مطابق با نتایج، هر یک از الگوریتم LSSVM_WOA و ANN نسبت به دیگر الگوریتم‌های بررسی شده در سه ایستگاه دارای بیشترین دقت می‌باشند.

نتایج مربوط به انحراف معیار بارش ریزمقیاس شده در جدول ۵ ارائه شده است. در دوره آموزش، مطابق با نتایج، مقدار معیار R برای الگوریتم‌های LSSVM_WOA، KNN و ANN به ترتیب از ۰/۸۸۸ تا ۰/۹۷۰، ۰/۹۷۶ تا ۰/۹۸۷ و ۰/۹۲۴ تا ۰/۹۷۱ تغییر می‌کند. مقدار معیارهای RRMSE، dr و NSC نیز برای الگوریتم LSSVM_WOA به ترتیب در محدوده ۰/۴۷۵ تا ۰/۷۷۷، ۰/۶۵۱ تا ۰/۷۸۹ و ۰/۳۴۲ تا ۰/۷۸۹ قرار دارد.

اما، دقت الگوریتم M5 برای تعیین روزهای تر در دوره آزمون کمتر از ۰/۷ است. در حالی که روزهای تر توسط الگوریتم MARS نسبت به الگوریتم M5 با دقت بیشتری در حدود ۴۷ تا ۱۰۰ درصد تعیین شده است. این موضوع به دلیل وجود روابط غیرخطی در الگوریتم MARS می‌باشد. در پژوهش Nasserri و همکاران (۲۰۱۳) نیز الگوریتم‌های MARS و M5 در میان روش‌های یادگیری مختلف دارای بیشترین دقت بودند. همچنین، به توانایی تقسیم‌بندی داده‌های ورودی و تشکیل یک رابطه رگرسیونی برای هر قسمت به عنوان دلیل این برتری اشاره شد.

عملکرد الگوریتم‌های LSSVM_WOA، KNN و ANN به منظور ریزمقیاس‌نمایی بارش در دوره آموزش در جدول ۴ مورد مقایسه قرار گرفته است. مقدار معیارهای R، RRMSE، dr و NSC برای الگوریتم LSSVM_WOA به ترتیب، در محدوده ۰/۹۶۶ تا ۰/۹۹۸، ۰/۰۶۲ تا ۰/۲۵۷، ۰/۸۹۹ تا ۰/۹۳۵ و ۰/۹۲۸ تا ۰/۹۹۶ قرار دارد. در حالی که این مقادیر برای الگوریتم KNN به ترتیب در حدود ۰/۹۸۳ تا ۰/۹۹۵، ۰/۲۶۶ تا ۰/۳۵۶، ۰/۸۴۶ تا ۰/۸۹۸، ۰/۸۶۲ تا ۰/۹۳۴ به دست آمده است. الگوریتم ANN نیز مقدار معیار R، RRMSE، dr و NSC را به ترتیب، در محدوده ۰/۹۴۷ تا ۰/۹۹۲، ۰/۱۴۶ تا ۰/۳۶۳، ۰/۸۶۹ تا ۰/۹۳۳ و ۰/۸۵۷ تا ۰/۹۷۷ قرار دارد.

جدول (۵): میانگین ماهانه بارش ریزمقیاس شده برای روش‌ها و ایستگاه‌های مختلف

نام ایستگاه	نام مدل	آموزش				آزمون			
		NSC	d_f	RRMSE	R	NSC	d_f	RRMSE	R
ارمند	LSSVM_WOA	۰/۹۶۶	۰/۲۵۷	۰/۹۳۵	۰/۹۲۸	۰/۹۰۷	۰/۴۲۴	۰/۸۸۱	۰/۸۰۴
	KNN	۰/۹۸۷	۰/۲۶۷	۰/۸۹۰	۰/۹۲۲	۰/۹۸۴	۰/۲۹۴	۰/۸۹۳	۰/۹۰۶
	ANN	۰/۹۶۸	۰/۲۵۸	۰/۹۱۰	۰/۹۲۷	۰/۹۷۷	۰/۲۳۶	۰/۹۳۶	۰/۹۳۹
بارز	LSSVM_WOA	۰/۹۹۸	۰/۰۶۲	۰/۸۸۲	۰/۹۹۶	۰/۹۹۳	۰/۱۱۷	۰/۹۵۳	۰/۹۸۵
	KNN	۰/۹۸۳	۰/۲۶۶	۰/۸۹۸	۰/۹۲۳	۰/۹۸۰	۰/۲۷۹	۰/۸۹۷	۰/۹۱۵
	ANN	۰/۹۴۷	۰/۳۶۳	۰/۸۶۹	۰/۸۵۷	۰/۹۷۳	۰/۲۷۱	۰/۹۰۵	۰/۹۲۰
دهکده شهید	LSSVM_WOA	۰/۹۷۰	۰/۲۳۷	۰/۸۹۹	۰/۹۳۹	۰/۹۳۱	۰/۳۹۹	۰/۸۵۷	۰/۸۲۶
	KNN	۰/۹۹۱	۰/۳۵۶	۰/۸۴۶	۰/۸۶۲	۰/۹۴۸	۰/۵۸۶	۰/۷۹۱	۰/۶۲۵
	ANN	۰/۹۹۰	۰/۱۴۶	۰/۹۳۳	۰/۹۷۷	۰/۹۷۵	۰/۳۵۳	۰/۸۶۸	۰/۸۶۴
شهرکرد	LSSVM_WOA	۰/۹۸۰	۰/۲۳۳	۰/۹۰۲	۰/۹۴۱	۰/۹۸۶	۰/۱۸۷	۰/۹۳۳	۰/۹۶۲
	KNN	۰/۹۸۴	۰/۳۰۸	۰/۸۶۱	۰/۸۹۶	۰/۹۶۱	۰/۳۷۶	۰/۸۵۷	۰/۸۴۶
	ANN	۰/۹۵۷	۰/۳۳۲	۰/۸۸۶	۰/۸۷۹	۰/۹۷۸	۰/۲۶۰	۰/۸۹۵	۰/۹۲۶
پاتاوه	LSSVM_WOA	۰/۹۷۴	۰/۲۱۷	۰/۹۰۷	۰/۹۴۸	۰/۹۶۱	۰/۲۹۴	۰/۸۹۸	۰/۹۰۵
	KNN	۰/۹۸۴	۰/۳۳۱	۰/۸۵۴	۰/۸۸۰	۰/۹۷۴	۰/۴۰۰	۰/۸۵۱	۰/۸۲۶
	ANN	۰/۹۸۷	۰/۱۸۴	۰/۹۲۶	۰/۹۶۳	۰/۹۴۹	۰/۳۳۹	۰/۸۷۵	۰/۸۷۵
ياسوج	LSSVM_WOA	۰/۹۸۸	۰/۱۸۹	۰/۹۴۲	۰/۹۶۱	۰/۹۶۲	۰/۳۲۴	۰/۸۸۲	۰/۸۸۵
	KNN	۰/۹۹۵	۰/۲۴۶	۰/۸۹۵	۰/۹۳۴	۰/۹۸۱	۰/۳۲۲	۰/۸۸۳	۰/۸۸۷
	ANN	۰/۹۹۲	۰/۱۶۸	۰/۹۳۶	۰/۹۶۹	۰/۹۸۳	۰/۱۸۳	۰/۹۲۹	۰/۹۶۴

۰/۹۷۵، ۰/۵۳۱ تا ۰/۶۸۷، ۰/۷۱۸ تا ۰/۷۵۹ و ۰/۴۸۵ تا ۰/۶۹۲ تغییر می‌کنند. مشابه با نتایج دوره آموزش، الگوریتم ANN در چهار ایستگاه و الگوریتم LSSVM_WOA در دو ایستگاه از نظر بیشترین دقت در رتبه اول قرار داده می‌شوند. دقت مطلوب الگوریتم‌های LSSVM_WOA به دلیل در نظر گرفتن روابط غیرخطی بین ورودی‌ها و خروجی‌ها با استفاده از تابع کرنل می‌باشد. همچنین، استفاده از الگوریتم WOA جهت تعیین بهینه پارامترهای LSSVM موجب افزایش دقت این الگوریتم نسبت به الگوریتم‌های ANN و KNN در برخی از ایستگاه‌ها شده است. در برخی از ایستگاه‌ها نیز، الگوریتم ANN دارای نتایج بهتری می‌باشد. این موضوع به دلیل در نظر گرفتن روابط غیرخطی بین ورودی‌ها و خروجی‌ها با پردازش اطلاعات در چندین لایه و تعیین دقیق تعداد لایه‌ها و نرون‌ها می‌باشد. همچنین، الگوریتم KNN نسبت به دیگر الگوریتم‌ها دارای دقت کمتری است. این موضوع می‌تواند به دلیل در نظر گرفتن مقادیر

این مقادیر برای الگوریتم KNN به ترتیب برابر با ۰/۷۵۰ تا ۰/۹۴۱ و ۰/۵۶۳ تا ۰/۶۶۰ و ۰/۰۳۵ تا ۰/۴۱۸ می‌باشد. علاوه بر این، مقدار معیارهای RRMSE، d_f و NSC توسط الگوریتم ANN برابر با ۰/۶۰۷ تا ۰/۷۲۲، ۰/۶۶۶ تا ۰/۷۵۴ و ۰/۴۳۱ تا ۰/۶۷۱ محاسبه شده است. بنابراین در میان ایستگاه‌های بررسی شده الگوریتم ANN در چهار ایستگاه و الگوریتم LSSVM_WOA در دو ایستگاه از دقت بیشتری برای ریزمقیاس‌نمایی انحراف معیار بارش برخوردار است. در دوره آزمون، مقادیر معیارهای R، RRMSE، d_f و NSC برای الگوریتم LSSVM_WOA بین ۰/۸۷۳ تا ۰/۹۸۵، ۰/۵۳۹ تا ۰/۷۴۱، ۰/۶۹۹ تا ۰/۷۷۲ و ۰/۴۰۱ تا ۰/۶۸۲ به دست آمده است. این مقادیر برای الگوریتم KNN برابر با ۰/۹۳۴ تا ۰/۹۸۴، ۰/۷۴۵ تا ۰/۹۰۲، ۰/۶۱۹ تا ۰/۶۹۹ و ۰/۱۱۲ تا ۰/۳۹۴ برآورد شده است. مطابق با دیگر نتایج جدول ۴، معیارهای R، RRMSE، d_f و NSC برای الگوریتم ANN در محدوده ۰/۷۹۱ تا

ایستگاه‌های مختلف است. تفاوت نتایج ریزمقیاس‌نمایی میانگین و انحراف معیار بارش نیز به دلیل فرضیات متفاوت در الگوریتم‌های مختلف است

یکسان برای وزن ورودی‌ها باشد. تفاوت نتایج در ایستگاه‌های مختلف به دلیل تفاوت در معیارهای پراکندگی سری زمانی بارش و موقعیت جغرافیایی در

جدول (۶): انحراف معیار بارش ریزمقیاس شده برای روش‌ها و ایستگاه‌های مختلف در دوره آزمون

آزمون				آموزش				نام مدل	نام ایستگاه
NSC	dr	RRMSE	R	NSC	dr	RRMSE	R		
۰/۴۰۱	۰/۷۱۷	۰/۷۴۱	۰/۹۰۵	۰/۴۳۳	۰/۶۹۸	۰/۷۲۱	۰/۸۸۸	LSSVM_WOA	ارمند
۰/۳۹۴	۰/۶۹۹	۰/۷۴۵	۰/۹۷۸	۰/۳۸۷	۰/۶۵۶	۰/۷۵۰	۰/۹۷۹	KNN	
۰/۵۲۸	۰/۷۵۹	۰/۶۵۸	۰/۹۰۰	۰/۵۹۸	۰/۷۵۶	۰/۶۰۷	۰/۹۲۴	ANN	
۰/۴۰۳	۰/۷۰۱	۰/۷۴۰	۰/۹۸۲	۰/۴۶۹	۰/۷۱۵	۰/۶۹۸	۰/۹۵۰	LSSVM_WOA	بارز
۰/۲۳۳	۰/۶۵۷	۰/۸۳۸	۰/۹۷۷	۰/۳۰۶	۰/۶۴۸	۰/۷۹۷	۰/۹۸۲	KNN	
۰/۵۴۵	۰/۷۳۰	۰/۶۴۶	۰/۹۶۷	۰/۵۹۸	۰/۷۴۲	۰/۶۰۷	۰/۹۴۷	ANN	
۰/۴۷۳	۰/۶۹۹	۰/۶۹۵	۰/۹۸۵	۰/۳۴۲	۰/۶۵۷	۰/۷۷۷	۰/۹۳۵	LSSVM_WOA	دهکده-
۰/۱۱۲	۰/۶۱۹	۰/۹۰۲	۰/۹۷۵	۰/۰۳۵	۰/۵۶۳	۰/۹۴۱	۰/۹۸۴	KNN	
۰/۵۹۵	۰/۷۳۲	۰/۶۰۹	۰/۹۴۸	۰/۴۳۱	۰/۶۶۶	۰/۷۲۲	۰/۹۴۴	ANN	
۰/۶۸۱	۰/۷۶۳	۰/۵۴۱	۰/۹۷۴	۰/۶۵۲	۰/۷۳۴	۰/۵۶۵	۰/۹۴۲	LSSVM_WOA	شهرکرد
۰/۳۸۹	۰/۶۶۶	۰/۷۴۹	۰/۹۳۴	۰/۳۰۰	۰/۶۰۴	۰/۸۰۱	۰/۹۷۶	KNN	
۰/۶۹۲	۰/۷۵۶	۰/۵۳۱	۰/۹۷۵	۰/۵۸۳	۰/۷۴۶	۰/۶۱۸	۰/۹۳۳	ANN	
۰/۴۱۷	۰/۶۹۹	۰/۷۳۱	۰/۹۲۷	۰/۶۳۲	۰/۷۴۱	۰/۵۸۱	۰/۹۷۰	LSSVM_WOA	پاتاوه
۰/۱۵۸	۰/۶۲۶	۰/۸۷۹	۰/۹۷۹	۰/۳۴۳	۰/۶۳۷	۰/۷۷۶	۰/۹۹۲	KNN	
۰/۴۸۵	۰/۷۱۸	۰/۶۸۷	۰/۷۹۱	۰/۶۷۱	۰/۷۵۴	۰/۵۴۹	۰/۹۶۸	ANN	
۰/۶۸۳	۰/۷۷۲	۰/۵۳۹	۰/۸۷۳	۰/۷۵۳	۰/۷۸۹	۰/۴۷۵	۰/۹۲۸	LSSVM_WOA	یاسوج
۰/۳۶۴	۰/۶۷۶	۰/۷۶۴	۰/۹۸۴	۰/۴۱۸	۰/۶۶۰	۰/۷۳۰	۰/۹۸۷	KNN	
۰/۵۷۴	۰/۷۴۹	۰/۶۲۵	۰/۹۵۶	۰/۶۴۵	۰/۷۴۴	۰/۵۷۰	۰/۹۷۱	ANN	



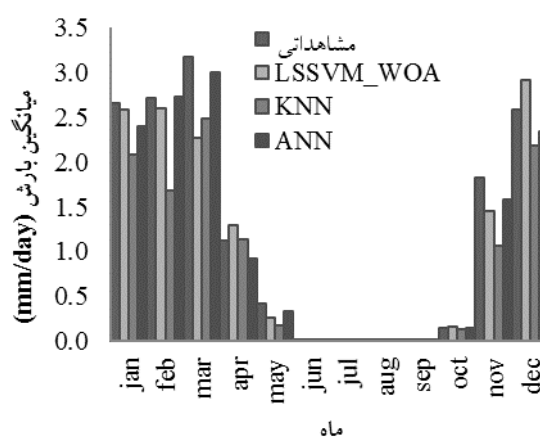

دقت در رتبه‌های اول و دوم قرار داده می‌شوند. دقیق‌ترین نتایج معیارهای R، RRMSE، dr و NSC مربوط به ANN و برابر با ۰/۹۹۸، ۰/۱۱۵، ۰/۹۵۵ و ۰/۹۸۶ است. در حالی که معیارهای مذکور برای الگوریتم LSSVM_WOA برابر با ۰/۹۷۲، ۰/۲۴۱، ۰/۹۲۱ و ۰/۹۳۷ محاسبه شده است.

همچنین، انحراف معیار میانگین ماهانه بارش مشاهداتی و ریزمقیاس شده در شکل ۴ نمایش داده شده است. در دوره آموزش، مطابق با شکل ۴، الگوریتم ANN، LSSVM_WOA و KNN از نظر بیشترین دقت در تعیین انحراف معیار بارش، به ترتیب در رتبه‌های اول، دوم و سوم قرار داده می‌شوند. براساس این شکل، الگوریتم ANN با مقادیر ۰/۹۹۰، ۰/۶۰۵، ۰/۷۳۷ و ۰/۶۰۱ برای معیارهای R، RRMSE، dr و NSC در میان الگوریتم‌های

شکل ۴، میانگین پارامترهای آماری (میانگین و انحراف معیار) حاصل از بارش مشاهداتی و ریزمقیاس شده را در شش ایستگاه نشان می‌دهد. همانطور که در این شکل مشاهده می‌شود، الگوریتم‌های LSSVM_WOA و ANN نسبت به الگوریتم KNN عملکرد بهتری در ریزمقیاس‌نمایی میانگین ماهانه بارش برخوردار است. با توجه به این شکل، در دوره آموزش، دقیق‌ترین مقدار معیارهای R، RRMSE، dr و NSC برای الگوریتم LSSVM_WOA به ترتیب برابر با ۰/۹۹۵، ۰/۱۰۳، ۰/۹۶۲ و ۰/۹۸۸ می‌باشد. همچنین این مقادیر برای الگوریتم ANN برابر با ۰/۹۹۳، ۰/۱۲۱، ۰/۹۴۴ و ۰/۹۸۴ محاسبه شده است. بنابراین، اختلاف این دو الگوریتم در دوره آموزش ناچیز است. در دوره آزمون الگوریتم ANN و LSSVM_WOA از نظر بیشترین

اندکی از الگوریتم LSSVM_WOA بهتر عمل کرده است. برتری اندک دقت الگوریتم ANN نسبت به LSSVM_WOA برای میانگین نتایج، می‌تواند به این علت باشد که میانگین بارش در ایستگاه‌های که توسط ANN بهتر شبیه‌سازی شده‌اند، بیشتر از سایر ایستگاه‌ها است

بررسی شده دارای بیشترین دقت است. در دوره آزمون نیز، الگوریتم LSSVM_WOA بر اساس معیار R، ۱/۱۹ درصد دقیق‌تر از ANN است. اما، با توجه به معیارهای dr، RRMSE و NSC، الگوریتم ANN نسبت به LSSVM_WOA به ترتیب برابر با ۴/۰۳، ۱/۴۷ و ۵/۰۴ درصد دقیق‌تر می‌باشد. بنابراین، می‌توان نتیجه گرفت الگوریتم ANN بر اساس میانگین بارش شش ایستگاه،




شکل (۴): مقایسه میانگین داده‌های بارش مشاهداتی و ریزمقیاس شده الف) میانگین ب) انحراف معیار

همچنین، در پژوهش (Nourani et al. (2018) الگوریتم ANN نسبت به LSSVM اندکی دقیق‌تر بود. این موضوع، نتایج پژوهش حاضر را تأیید می‌کند.


برتری ANN نسبت به KNN نتایج پژوهش‌های Wu et al. (2010) و Mekanik et al. (2013) را تأیید می‌کند. برتری LSSVM نسبت به الگوریتم KNN در پژوهش (Modaresi et al. (2018) اثبات شده است.

برای الگوریتم ANN مقدار بارش تحت شرایط تغییر اقلیم در برخی سناریوها و ایستگاه‌ها نسبت به دوره پایه، با کاهش و در برخی با افزایش همراه است. با توجه به نتایج، بیشترین مقدار کاهش بارش (۴۳ درصد) مربوط به ایستگاه پاتاوه تحت سناریو RCP2.6 در افق ۲۰۲۰-۲۰۴۰ می‌باشد. اما، حداکثر مقدار افزایش بارش برابر با ۷۲ درصد و برای ایستگاه شهرکرد تحت سناریو RCP8.5 در افق ۲۰۲۰-۲۰۴۰ محاسبه شده است. این تفاوت نتایج برای الگوریتم ANN نشان‌گر عدم قطعیت بالای این الگوریتم می‌باشد. بنابراین، جواب‌های حاصل از الگوریتم LSSVM_WOA قابل اعتمادتر است

درصد تغییرات بارش نسبت به دوره پایه تحت سناریوهای مدل CanESM2 شامل RCP2.6، RCP4.5 و RCP8.5 در شکل ۵ نمایش داده شده است. با توجه به نتایج این شکل می‌توان دریافت که برای الگوریتم LSSVM_WOA در هر شش ایستگاه مقدار بارش تحت شرایط تغییر اقلیم کاهش خواهد یافت. بیشترین مقدار کاهش بارش (برابر با ۱۸ درصد) مربوط به ایستگاه دهکده شهید تحت سناریو RCP4.5 و در افق ۲۰۲۰-۲۰۴۰ می‌باشد. در حالی که مقدار کاهش بارش در ایستگاه ارمند تحت سناریو RCP2.6 در افق ۲۰۲۰-۲۰۴۰ دارای کمترین مقدار خود برابر با ۱ درصد می‌باشد.



(ب)



(الف)

شکل (۵): پیش‌بینی میانگین بارش تحت شرایط تغییر اقلیم، (الف) با استفاده از LSSVM_WOA و (ب) با استفاده از ANN

جواب‌های ANN در دوره آینده نسبت به دوره پایه از ۴۶- درصد تا ۷۲ درصد بود. بنابراین، می‌توان نتیجه گرفت که الگوریتم ANN دارای عدم قطعیت بالای است و جواب‌های به دست آمده از LSSVM_WOA دارای اطمینان‌پذیری بیشتری است. همچنین، با توجه به نتایج LSSVM_WOA، تغییر اقلیم در حوضه کارون ۳ در افق نزدیک و دور موجب کاهش بارش نسبت به دوره پایه می‌شود. این کاهش در جنوب شرق حوضه (ایستگاه دهکده شهید) بیشتر از دیگر نقاط حوضه است. بنابراین، نیاز است، تا تدابیری در خصوص مدیریت منابع آب و مقابله با پدیده تغییر اقلیم اتخاذ شود

نتیجه‌گیری

در پژوهش حاضر با استفاده از ماشین‌های یادگیری به ریزمقیاس‌نمایی بارش در شش ایستگاه مختلف در حوزه آبخیز کارون ۳ پرداخته شد سپس، با در نظر گرفتن دقیق‌ترین روش، تغییرات بارش نسبت به دوره پایه تحت سناریوهای مدل CanESM2 شامل RCP2.6 و RCP4.5 و RCP8.5 محاسبه شد. با توجه به نتایج الگوریتم MARS در طبقه‌بندی وقوع بارش و الگوریتم‌های LSSVM_WOA و ANN در ریزمقیاس‌نمایی مقدار بارش دارای بیشترین دقت بودند. در بحث پیش‌بینی بارش تحت شرایط تغییر اقلیم، بیشترین و کمترین مقدار کاهش بارش پیش‌بینی شده توسط LSSVM_WOA به ترتیب مربوط به سناریو RCP4.5 در افق ۲۰۲۰ تا ۲۰۴۰ با مقدار ۱۸ درصد و سناریو RCP2.6 در افق ۲۰۲۰ تا ۲۰۴۰ برابر با ۱ درصد می‌باشد. در حالی که تغییرات

منابع

- آبکار، ع، ج، م. حبیب نژاد، ک. سلیمانی و ه. نقوی. بررسی میزان کارایی مدل SDSM در شبیه‌سازی شاخص‌های دمایی در مناطق خشک و نیمه‌خشک. ۱۳۹۲. نشریه مهندسی آبیاری و آب. سال چهارم، شماره ۱۴، ص ۱-۱۷.
- Ahmadi, A., A. Moridi, E. K. Lafdani and G. Kianpisheh. 2014. Assessment of climate change impacts on rainfall using large scale climate variables and downscaling models—A case study. *Journal of Earth System Science*, 123(7): 1603-1618.
- Al-Shammari, E. T., K. Mohammadi, A. Ab. Keivani, Sh. Hamid, S. Akib, S. Shamshirband and D. Petković. 2016. Prediction of daily dewpoint temperature using a model combining the support vector machine with firefly algorithm. *Journal of Irrigation and Drainage Engineering*, 142(5): 04016013.
- Ashofteh, P. S., O. Bozorg Haddad and MA. Mariño. 2012. Climate change impact on reservoir performance indexes in agricultural water supply. *Journal of Irrigation and Drainage Engineering*, 139(2): 85-97.
- Beheshti, Z., M. Firouzi, SM. Shamsuddin, M. Zibarzani and Z. Yusop. 2016. A new rainfall forecasting model using the CAPSO algorithm and an artificial neural network. *Neural Computing and Applications*, 27(8): 2551-2565.
- Chen, S.T., P. S. Yu and Y. H. Tang. 2010. Statistical downscaling of daily precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385(1-4): 13-22.
- Devak, M., C. T. Dhanya and A. K. Gosain. 2015. Dynamic coupling of support vector machine and K-nearest neighbour for downscaling daily rainfall. *Journal of Hydrology*, 525: 286-301.
- Du, P., J. Wang, W. Yang and T. Niu. 2018. Multi-step ahead forecasting in electrical power system using a hybrid forecasting system. *Renewable Energy*, 122: 533-550.
- Friedman, J.H. 1991. Multivariate adaptive regression splines. *The Annals of Statistics*, 19(1): 1-67.
- Hadi, S. J and M. Tombul. 2018. Streamflow forecasting using four wavelet transformation combinations approaches with data-driven models: A comparative study. *Water Resources Management*, 32(14): 4661-4679.
- Harpham, C and R. L. Wilby. 2005. Multi-site downscaling of heavy daily precipitation occurrence and amounts. *Journal of Hydrology*, 312(1-4): 235-255.
- Kundu, S., D. Khare and A. Mondal. 2017. Future changes in rainfall, temperature and reference evapotranspiration in the central India by least square support vector machine. *Geoscience Frontiers*, 8(3): 583-596.
- Lee, K. T., Hung, W. C and Meng, C. C. 2008. Deterministic insight into ANN model performance for storm runoff simulation. *Water Resources Management*. 22(1), 67-82.
- Mekanik, F., M. A. Imteaz, S. Gato-Trinidad and A. Elmahdi. 2013. Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate models. *Journal of Hydrology*. 503:11-21.
- Mirjalili, S and A. Lewis. 2016. The whale optimization algorithm. *Advances in Engineering Software*, 95: 51-67.
- Modaresi, F., S. Araghinejad and K. Ebrahimi. 2018. A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and k-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions. *Water Resources Management*, 32(1), 243-258.
- Mujumdar, P. P and S. Ghosh. 2008. Modeling GCM and scenario uncertainty using a possibilistic approach: Application to the Mahanadi River, India. *Water Resources Research*, 44(6): W06407.



Nourani, V., A. H. Baghanam and H. Gokcekus. 2018. Data-driven ensemble model to statistically downscale rainfall using nonlinear predictor screening approach. *Journal of Hydrology*, 565: 538-551.

Quinlan, J. R. 1992. Learning with continuous classes, In 5th Australian Joint Conference on Artificial Intelligence, 92, 343-348.

Rezaie-Balf, M., Z. Zahmatkesh and S. Kim. 2017. Soft computing techniques for rainfall-runoff simulation: local non-parametric paradigm vs. model classification methods. *Water Resources Management*, 31(12): 3843-3865.

Singh, K. K., M. Pal and V. P. Singh. 2010. Estimation of mean annual flood in Indian catchments using backpropagation neural network and M5 model tree. *Water Resources Management* 24(10): 2007-2019.

Suykens, J. A. 2001. Nonlinear modelling and support vector machines. 2001. In *Instrumentation and Measurement Technology Conference. Proceedings of the 18th IEEE* 1, 287-294.

Tavakol-Davani, H., M. Nasserli and B. Zahraie. 2013. Improved statistical downscaling of daily precipitation using SDSM platform and data-mining methods. *International Journal of Climatology*, 33(11): 2561-2578.

Wilby, R. L., L. E. Hay and G. H. Leavesley. 1999. A comparison of downscaled and raw GCM output: Implications for climate change scenarios in the San Juan River basin, Colorado. *Journal of Hydrology*, 225(1-2): 67-91.

Wu, C. L., K. W. Chau and C. Fan. 2010. Prediction of rainfall time series using Modular Artificial Neural Networks coupled with data preprocessing techniques. *Journal of Hydrology*, 389: 146-167



Application of Hybrid Least Square Support Vector Machine-Whale Optimization Algorithm (LSSVM-WOA) for Downscaling and Prediction of Precipitation under Climate Change (Case Study: Karun3 Basin)

Mehdi. Valikhan Anaraki¹, saeed. Farzin², Seyyed. Farhad. Mousavi³, Hojat. Karami⁴

Abstract

In the present study, precipitation in six stations of Karun3 basin is downscaled by using the hybrid of least squares support vector machine and whale optimization algorithm (LSSVM-WOA), K nearest neighbor (KNN), and artificial neural network (ANN). For downscaling precipitation, first, the days of year are classified into wet and dry days by using MARS and M5 algorithms. Then, the amount of precipitation for wet days is estimated by using each of LSSVM-WOA, KNN and ANN methods. Based on the findings, MARS algorithm is superior over M5 algorithm. Based on the mean precipitation in the six stations, ANN is a little bit better than LSSVM-WOA (0.5 percent more accurate). While, by regarding the mean of standard deviations, the Nash-Sutcliff for Ann is up to 5.04 percent more accurate than LSSVM-WOA. Eventually, the amount of precipitation is predicted based on the CanESM2 model under RCP2.6, RCP4.5 and RCP8.5 scenarios for 2020-2040 and 2070-2100 periods. Based on the results of applying LSSVM-WOA, the precipitation in each three scenarios is decreased compared to the base period. Maximum decrease of precipitation (18%) is calculated by RCP8.5 for 2070-2100 period. Minimum decrease of precipitation (1%) is related to RCP2.6 scenario for 2020-2040 future period. But, the precipitation variation amount that is predicted by ANN is between -43 and 72 percent. Therefore, the results of LSSVM-WOA are more reliable and less uncertain.

Keywords: LSSVM_WOA, Precipitation, Downscaling, Prediction, Climate change.

¹ Department of Water Resources Engineering and Management, Faculty of Civil Engineering, Semnan University, Semnan, Iran, mvalikhan@semnan.ac.ir.

² Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, saeed.farzin@semnan.ac.ir. (corresponding author)

³ Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, fmousavi@semnan.ac.ir.

⁴ Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, hkarami@semnan.ac.ir.



Application of Hybrid Least Square Support Vector Machine-Whale Optimization Algorithm (LSSVM-WOA) for Downscaling and Prediction of Precipitation under Climate Change (Case Study: Karun3 Basin)

Mehdi. Valikhan Anaraki¹, saeed. Farzin², Seyyed. Farhad. Mousavi³, Hojat. Karami⁴

Introduction: In recent decades, due to different factors such as human activities, growth of population, and emission of greenhouse gases, most regions of the world have experienced an average annual temperature rise of at least 2 °C. Also, other hydrological parameters such as precipitation, cloud cover, and reference evapotranspiration have significantly changed (Ashofteh et al., 2012). This phenomenon is surely called climate change. One of the methods for investigating the mentioned phenomenon is simulation of large-scale global circulation models (GCMs). However, these data are not available at local scale. Hence, there is a need for a tool to downscale these variables (Abkar et al., 2014). Among different downscaling methods, regression methods for less computation cost and computation time have more popularity between researchers (Chen et al., 2010). In recent years, machine learning such as regression downscaling methods have successfully been applied in downscaling hydrological parameters such as precipitation and temperature. Devak et al. (2016) employed hybrid of support vector machine and K nearest neighbor for downscaling precipitation, which led to more accuracy in downscaling precipitation. In a study by Kundu et al. (2017), least square support vector machine was used for downscaling precipitation, temperature and reference evapotranspiration. Results showed that good application of least square support vector machine was confirmed. In a study by Nourani et al. (2018), different methods such least square support vector machine, artificial neural networks and multiple linear regression were used for downscaling precipitation. In this study, the least square support vector machine and artificial neural networks were placed in first and second rank. Also, hybrid of least square support vector machine and optimization algorithms have good application in different fields. Whale optimization algorithm (Mirjalili and Lewis (2016) is one of the powerful optimization algorithms that has better application than other optimization algorithms such as particle swarm optimization algorithm. Du et al. (2018) used hybrid of whale optimization algorithm and least square support vector machine for prediction of electrical energy. Results showed better accuracy of the mentioned method than general regression neural network and artificial neural network with back propagation network.

Methodology: In the present study, precipitation in six stations of Karun3 basin is downscaled by using the hybrid of least squares support vector machine and whale optimization algorithm (LSSVM-WOA), K nearest neighbor (KNN), and artificial neural network (ANN). For downscaling precipitation, first, the days of year are classified into wet and dry days by using MARS and M5 algorithms. Then, the amount of precipitation for wet days is estimated by using each of LSSVM-WOA, KNN and ANN methods. To train these algorithms, in addition to precipitation data, the twenty-four large scale predictors of NCEP are used. Thus, for investigation of climate change impact on precipitation in Karun3 basin, the output of CanESM2 model under three scenarios, including

¹ Department of Water Resources Engineering and Management, Faculty of Civil Engineering, Semnan University, Semnan, Iran, mvalikhan@semnan.ac.ir.

² Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, saeed.farzin@semnan.ac.ir. (corresponding author)

³ Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, fmousavi@semnan.ac.ir.

⁴ Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran, hkarami@semnan.ac.ir.



RCP2.6, RCP4.5 and RCP8.5, are employed. In this regard, the 1972-2000 is considered as the observation period, 2020-2040 is considered as the near future period, and 2070-2100 is considered as the far future period. It worth mentioning that the Pearson correlation coefficient (R), relative root mean square error (RRMSE), d_r , and Nash-Sutcliff criteria are employed for investigating the accuracy of the algorithms.

Results and Conclusion: Based on the findings, MARS algorithm is superior over M5 algorithm (47-100 percent more accurate). This better accuracy of MARS over M5 is because MARS divides the input data into multi sets and creates a nonlinear regression for each set. This superiority of MARS over M5 is similar to a study by Nasserri et al. (2013). Based on the mean precipitation in the six stations, ANN is a little bit better than LSSVM-WOA (0.5 percent more accurate). While, by regarding the mean of standard deviations, the Nash-Sutcliff for Ann is up to 5.04 percent more accurate than LSSVM-WOA. Eventually, the amount of precipitation is predicted based on the CanESM2 model under RCP2.6, RCP4.5 and RCP8.5 scenarios for 2020-2040 and 2070-2100 periods. Based on the results of applying LSSVM-WOA, the precipitation in each three scenarios is decreased compared to the base period. Maximum decrease of precipitation (18%) is calculated by RCP8.5 for 2070-2100 period. Minimum decrease of precipitation (1%) is related to RCP2.6 scenario for 2020-2040 future period. But, the precipitation variation amount that is predicted by ANN is between -43 and 72 percent. Therefore, the results of LSSVM-WOA are more reliable and less uncertain. Thus, the decreasing of precipitation in east-south of Karun3 basin is more than other parts of this station. Hence, it is needed to manage the water resources more properly and combat the climate change effects.

Keywords: LSSVM-WOA, Precipitation, Downscaling, Prediction, Climate change.

The most important references:

- Abkar, A., M. Habibnejad, K. Solaimani and H. Naghavi. 2014. Investigating the efficiency of SDSM model to simulate temperature indexes in arid and semi-arid regions. *Journal of Irrigation and Water Engineering*, 14(4): 1-17.
- Ashofteh, P. S., O. Bozorg Haddad and M. A. Mariño. 2012. Climate change impact on reservoir performance indexes in agricultural water supply. *Journal of Irrigation and Drainage Engineering*, 139(2): 85-97.
- Chen, S. T., P. S. Yu and Y. H. Tang. 2010. Statistical downscaling of daily precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385(1-4): 13-22.
- Devak, M., C. T. Dhanya and A. K. Gosain. 2015. Dynamic coupling of support vector machine and K-nearest neighbour for downscaling daily rainfall. *Journal of Hydrology*, 525: 286-301.
- Du, P., J. Wang, W. Yang and T. Niu. 2018. Multi-step ahead forecasting in electrical power system using a hybrid forecasting system. *Renewable Energy*, 122: 533-550.
- Kundu, S., D. Khare and A. Mondal. 2017. Future changes in rainfall, temperature and reference evapotranspiration in the central India by least square support vector machine. *Geoscience Frontiers*, 8(3): 583-596.
- Mirjalili, S. and A. Lewis. 2016. The whale optimization algorithm. *Advances in Engineering Software*, 95: 51-67.
- Nasserri, M., H. Tavakol-Davani and B. Zahraie. 2013. Performance assessment of different data mining methods in statistical downscaling of daily precipitation. *Journal of Hydrology*, 492: 1-14.
- Nourani, V., A. H. Baghanam and H. Gokcekus. 2018. Data-driven ensemble model to statistically downscale rainfall using nonlinear predictor screening approach. *Journal of Hydrology*, 565: 538-551.