

## پیش‌بینی دبی جریان رودخانه با استفاده از داده‌کاوی و سری زمانی

سید مرتضی سیدیان<sup>۱\*</sup>، مریم سلیمانی<sup>۲</sup>، مجتبی کاشانی<sup>۳</sup>

۱. استادیار، دانشکده کشاورزی، دانشگاه گنبد کاووس

۲. دانشجوی کارشناسی ارشد آبخیزداری، دانشگاه آمل

۳. مربی، دانشکده علوم، دانشگاه گنبد کاووس

(تاریخ دریافت: ۹۳/۰۸/۲۵ - تاریخ تصویب: ۹۳/۱۱/۲۲)

## چکیده

شبیه‌سازی جریان رودخانه به‌منظور آگاهی از دبی رودخانه در دوره‌های زمانی آینده از مسائل مهم و کاربردی است. با توجه به اهمیت اطلاع از دبی جریان در سال‌های آینده، در این مطالعه دبی جریان در سه ایستگاه حاجی‌قوشان، قره‌شور و تمر در حوضه آبخیز گرگانرود برای سال‌های آبی ۹۰-۱۳۸۱ شبیه‌سازی شد. به‌منظور شبیه‌سازی از روش آماری سری زمانی در قالب الگوی اتورگرسیون (AR) و داده‌کاوی در قالب ماشین بردار پشتیبان (SVM) به دو صورت ماهانه و هفتگی استفاده شد. نتایج در مقیاس ماهانه نشان داد هر دو روش در ایستگاه تمر، دقت کم و در ایستگاه حاجی‌قوشان، دقت خوبی دارند. در ایستگاه قره‌شور SVM توانست ضریب تعیین سری زمانی ماهانه را به مقدار ۰/۲۹ افزایش و خطای RMSE را ۳۵ درصد کاهش دهد و شبیه‌سازی دقیق‌تری انجام دهد. هر دو روش در ایستگاه‌های تمر و قره‌شور دبی هفتگی را با دقت کمی پیش‌بینی کردند. در ایستگاه حاجی‌قوشان ضریب تعیین روش سری زمانی هفتگی ۰/۹۱ و SVM برابر ۰/۸۶ است. آماره DDR نشان داد در ایستگاه حاجی‌قوشان در مقیاس ماهانه روش SVM نسبت به سری زمانی دارای دقت بیشتری است و در مقیاس هفتگی دقت این دو روش برابر است. نتایج این مطالعه نشان داد که روش SVM در هر دو مقیاس ماهانه و هفتگی نسبت به سری زمانی دارد؛ همچنین دقت هر دو روش در مقیاس ماهانه بیشتر از مقیاس هفتگی است.

واژه‌های کلیدی: داده‌کاوی، دبی رودخانه، سری زمانی، گرگانرود، ماشین بردار پشتیبان.

## مقدمه

اهمیت برنامه‌ریزی و مدیریت منابع آب و همچنین رشد روزافزون جمعیت و محدودیت منابع آب سطحی در کشور، پیش‌بینی دقیق‌تر جریان رودخانه با استفاده از ابزارها و روش‌های نوین مدل‌سازی را به ضرورتی اجتناب‌ناپذیر تبدیل کرده است. از طرف دیگر پیش‌بینی مناسب جریان رودخانه در ساماندهی رودخانه، سامانه‌های هشدار سیل و به‌خصوص برنامه‌ریزی برای بهره‌برداری بهینه لازم است. به‌منظور پیش‌بینی جریان رودخانه در طی سالیان گذشته روش‌های مختلفی ابداع شده است که به‌طور کلی این روش‌ها را می‌توان به دو دسته مدل‌های مفهومی و مدل‌های مبتنی بر آمار یا داده‌ای طبقه‌بندی کرد. اساس اکثر روش‌های پیش‌بینی، نوعی شبیه‌سازی وضعیت موجود سیستم است که در اصطلاح به آن مدل‌سازی گفته می‌شود. با توجه به اینکه در اغلب موارد مدل‌های مفهومی به داده و دانش صحیح و کامل از فرایندهای مؤثر بر پدیده نیاز دارند و این امر تاکنون با مشکلات زیادی همراه بوده است، پژوهشگران به استفاده از مدل‌های آماری روی آورده‌اند. در طی چهار دهه گذشته، مدل‌های سری‌های زمانی به‌عنوان یکی از مدل‌های آماری، کاربرد گسترده‌ای در پیش‌بینی جریان رودخانه پیدا کرده‌اند [۱۴، ۲۳]. با معرفی مدل‌های باکس-جنکینز کاربرد این مدل‌ها در زمینه‌های مختلف پیشرفت کرد. در روش‌های پیش‌بینی سری زمانی، پیش‌بینی‌کننده با استفاده از اطلاعات به دست‌آمده از گذشته و با فرض ادامه الگو در آینده، الگوی تعمیم‌پذیر را به‌دست می‌آورد [۱]. تجزیه و تحلیل و مدل‌سازی سری‌های زمانی به‌دلیل توانایی در تحلیل داده‌ها در پژوهش‌های هیدرولوژی و منابع آب کاربرد گسترده‌ای دارد. سری‌های هیدرولوژی و هیدروژئولوژی نظیر بارندگی، درجه حرارت، دبی رودخانه و دبی چشمه دارای مؤلفه‌های تناوبی فصلی با دوره‌های دوازده‌ماهه‌اند [۱۲]. اگر متغیرها و مؤلفه‌ها با یکدیگر نوعی ارتباط (همبستگی) داشته باشند، می‌توان مدلی آماری را که توصیف‌کننده این رابطه باشد، بنا کرد. استفاده از این روش پیش‌بینی در بسیاری از زمینه‌های منابع آب توسعه پیدا کرده است. بیشتر مدل‌های سری زمانی رایج در هیدرولوژی و منابع آب، تحلیل مدل‌های خطی سری زمانی است. مدل‌های مختلفی در سری‌های زمانی وجود دارد، ولی آنچه در هیدرولوژی کاربرد بیشتری دارد و در منابع مختلف دیده

می‌شود، شامل مدل‌های خودهمبستگی، میانگین متحرک، میانگین متحرک خودهمبسته و میانگین متحرک تجمعی خودهمبسته است [۳۱]. توماس و فایرینگ از اولین کسانی بودند که از مدل‌های خطی اتورگرسیون در تحلیل جریان‌های رودخانه استفاده کردند [۲۸]. پس از آنها مطالعات متعددی انجام گرفت که می‌توان به تحقیقات هیپل و مک لود [۱۵]، تامپ استون و همکاران [۲۹]، وانگ و همکاران [۳۳] و یورکلی و همکاران [۳۶] اشاره کرد. شاید اولین گام مهم در کاربرد عملی سری‌های زمانی در هیدرولوژی را مک‌کرچار و دولر برداشتند که با توجه به ویژگی‌های فصلی در پارامترهای جریان رودخانه مدل ساریما و پارما را برای شبیه‌سازی رودخانه انتخاب کردند [۱۸]. در ایران نیز مطالعاتی در زمینه مدل‌های خطی سری زمانی انجام گرفته که می‌توان به پژوهش‌های خلیلی و همکاران [۳]، صباغیان و شریفی [۵] و سبزی‌پرور و همکاران [۴] اشاره کرد. موسوی و همکاران [۶] به پیش‌بینی جریان روزانه ورودی به مخزن سد دز توسط مدل‌های سری زمانی با استفاده از روش باکس-جنکینز پرداختند. نتایج نشان داد که مدل (۴ و ۰ و ۵) ARIMA توانسته است جریان روزانه ورودی به مخزن سد دز را برای دوره‌های مختلف در طی دو سال آینده با دقت‌های مختلف پیش‌بینی کند. در این بین، عملکرد روش‌های سنتی پیش‌بینی از قبیل سری زمانی و روش‌های تکنیکی آماری، با تردیدهایی برای پیش‌بینی دقیق رفتار پویا در فرایند مواجه شده و در سال‌های اخیر با پیشرفت علوم کامپیوتری، روش‌های نوینی مانند استفاده از هوش مصنوعی مورد توجه قرار گرفته است. مندزم و همکاران [۲۱] با استفاده از مدل سری زمانی در قالب روش باکس-جنکینز و شبکه عصبی مصنوعی، رواناب ماهانه و روزانه رودخانه سالاس در کشور اسپانیا را پیش‌بینی کردند. خزایی و میرزایی [۲] به مقایسه کارایی پیش‌بینی دبی ماهانه با استفاده از شبکه عصبی مصنوعی و سری‌های زمانی پرداختند. آنها نشان دادند در بین مدل‌های مختلف باکس-جنکینز بهترین پیش‌بینی را مدل آرما نوع چهار از مقادیر دبی ارائه کرده است. نتایج نشان داد شبکه عصبی دقت بیشتری نسبت به سری زمانی دارد. به‌تازگی روش ماشین‌های بردار پشتیبان نیز به‌عنوان یکی از زیرمجموعه‌های هوش مصنوعی برای حل مسائل رگرسیون غیرخطی و سری زمانی در مدت کمی توانسته

این مطالعه دبی جریان در سه ایستگاه واقع در حوضه آبریز گرگانرود با استفاده از روش سری زمانی در قالب الگوی اتورگرسیون (AR) و داده‌کاوی در قالب ماشین بردار پشتیبان (SVM) به دو صورت ماهانه و هفتگی شبیه‌سازی و پیش‌بینی شد.

## مواد و روش‌ها

### منطقه تحقیق

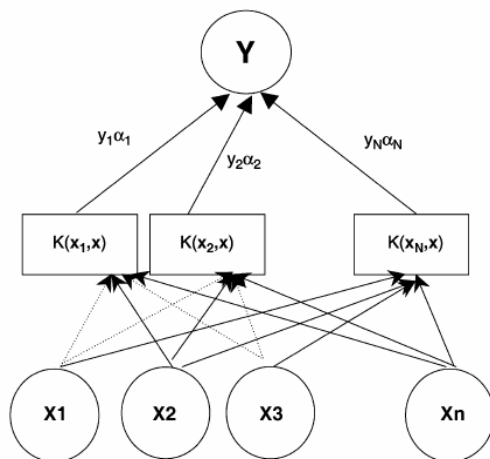
حوضه آبخیز گرگانرود یکی از سه حوضه اصلی در استان گلستان است که در جنوب شرقی دریای خزر قرار دارد و در دسته‌بندی کلی هیدرولوژی ایران، بخشی از حوضه آبخیز دریای خزر است. رودخانه اصلی این حوضه نقش مهمی در اقتصاد منطقه دارد. بخش بزرگی از مساحت این حوضه را زمین‌های کشاورزی تشکیل می‌دهد و یکی از سیل‌خیزترین حوضه‌های استان گلستان نیز به‌شمار می‌رود. رودخانه اصلی این حوضه عامل مهمی در آبدهی سد وشمگیر و تأمین آب مورد نیاز منطقه است. در این تحقیق به‌منظور پیش‌بینی دبی از آمار و اطلاعات ایستگاه‌های هیدرومتری تمر، قره‌شور و حاجی‌قوشان برای سال‌های آبی ۹۰-۱۳۸۱ واقع در حوضه آبخیز گرگانرود استفاده شده است. مشخصات ایستگاه‌ها در جدول ۱ آورده شده است. برای پیش‌بینی دبی از دو روش سری زمانی در قالب الگوی خودهمبستگی و داده‌کاوی در قالب ماشین بردار پشتیبان، در دو مقیاس هفتگی و ماهانه استفاده شد. بدین منظور ۸۰ درصد از کل داده‌ها برای واسنجی، به‌منظور پیدا کردن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای و ۲۰ درصد بقیه برای صحت‌سنجی و ارزیابی مدل‌ها به‌کار گرفته شد.

است کارایی خود را در علوم مختلف نشان دهد. ساختار مدل SVM<sup>۱</sup> توسط یک ریاضیدان روس به‌نام واپنیک در دهه ۱۹۶۰ مطرح شد [۳۲]. از کاربردهای آن می‌توان به مطالعات مهندس و همکاران [۲۲] اشاره کرد که برای پیش‌بینی سرعت باد، عملکرد این روش را در مقایسه با شبکه‌های عصبی مصنوعی بررسی کردند و نشان دادند که SVM نتایج بهتری نسبت به شبکه‌های عصبی مصنوعی (ANN) ارائه می‌دهد. ساخاره و دئو [۲۶] و محجوبی و مسبب [۲۰] از SVM به‌ترتیب برای پیش‌بینی طیف موج و ارتفاع موج مشخصه استفاده کردند. از SVM در تحقیقات مختلفی در زمینه هیدرولوژی استفاده شده است. دیبایک و همکاران قابلیت‌های SVM را در خصوص پیش‌بینی‌های هیدرولوژیکی بررسی کردند. آنها نشان دادند این روش در زمینه دسته‌بندی داده‌های سنجش از دور و مدلسازی بارش و رواناب پیش‌بینی دقیقی انجام داده است [۱۳]. لیونگ و همکاران از SVM برای پیش‌بینی سیلاب استفاده کردند [۱۹]. کوی و چان [۱۱]، یو و همکاران [۳۵]، بری و هان [۹] و بهزاد و همکاران [۸] از SVM برای پیش‌بینی رواناب استفاده کردند. تریپاتی و همکاران از روش SVM برای برآورد بارندگی ماهانه در هند استفاده کردند. آنها پیشنهاد کردند که SVM به‌عنوان گزینه برتر نسبت به سایر روش‌های معمول، برای پیش‌بینی بارش استفاده شود [۳۰]. چن و همکاران از SVM برای ریزمقیاس کردن بارش روزانه استفاده کردند و با روش آنالیز چندمعیاره مقایسه کردند و نشان دادند که نتایج پیش‌بینی‌های حاصل از SVM دقیق‌تر است [۱۰]. مرور منابع نشان می‌دهد تاکنون تحقیقی در ایران با استفاده از ماشین بردار پشتیبان به‌منظور پیش‌بینی سری زمانی در زمینه هیدرولوژی صورت نگرفته است. در

جدول ۱. مشخصات ایستگاه‌های مورد استفاده بر روی رودخانه گرگانرود


ردیف	رودخانه	نام ایستگاه	مختصات متریک		ارتفاع از سطح دریا
			X	Y	
۱	گرگانرود	حاجی‌قوشان	۳۵۶۱۶۹	۴۱۴۲۷۸۹	۴۵
۲	قره‌شور	قره‌شور	۳۵۵۱۵۱	۴۱۳۳۳۷۱	۹۰
۳	گرگانرود	تمر	۳۶۷۵۸۴	۴۱۵۰۵۰۴	۱۳۲

1. Support Vector Machine



شکل ۱. فرایند مدل SVM

ماشین‌های بردار پشتیبان همانند شبکه‌های عصبی مصنوعی، نوعی الگوریتم داده کاوی است. مراحل حل مسئله در الگوریتم ماشین‌های بردار پشتیبان همانند الگوریتم شبکه‌های عصبی مصنوعی به دو مرحله آموزش، و آزمایش یا صحت‌سنجی تقسیم می‌شود. از الگوریتم ماشین‌های بردار پشتیبان، علاوه بر طبقه‌بندی می‌توان برای خطی‌سازی داده‌ها نیز استفاده کرد که این کار با اندکی تغییر در الگوریتم طبقه‌بندی امکان‌پذیر است. اولین بار واپنیک [۳۲] الگوریتم خطی‌سازی ماشین‌های بردار پشتیبان را ارائه کرد. در یک الگوریتم خطی‌سازی با فرض مقادیر ورودی  $x_i$  و مقادیر خروجی  $y_i$  هدف یافتن تابعی است که کمترین انحراف  $\epsilon$  را از  $y_i$  ها داشته باشد (شکل ۲).

شکل ۲. روش خطی‌سازی با کمک الگوریتم ماشین‌های بردار پشتیبان با در نظر گرفتن انحراف  $\epsilon$ 

در یک مدل رگرسیونی SVM باید وابستگی تابع متغیر وابسته  $y$  به مجموعه‌ای از متغیرهای مستقل  $x$  تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط

## سری‌های زمانی

منظور از یک سری زمانی مجموعه‌ای از داده‌های آماری است که در فواصل زمانی مساوی و منظمی جمع‌آوری شده باشند و روش‌های آماری که از این گونه داده‌های آماری استفاده می‌کنند، تحلیل سری‌های زمانی نامیده می‌شوند. سری زمانی مجموعه‌ای از مشاهدات است که برحسب زمان (یا هر کمیت دیگر) مرتب شده باشد و اغلب آن را به صورت رابطه ۱ نشان می‌دهند.

$$Xt_1, Xt_2, \dots, Xt_n \quad (1)$$

انواع مدل سری‌های زمانی عبارتند از مدل اتورگرسیون، مدل میانگین متحرک و مدل ترکیبی. برخی از فرایندها نه تنها واجد شرایط خودهمبستگی اند، ویژگی‌های میانگین متحرک را نیز دارند. در چنین مواردی از مدل‌های ترکیبی مدل‌های اتورگرسیون - میانگین متحرک و مدل‌های اتورگرسیون - میانگین متحرک تجمعی استفاده می‌شود. اولین گام در مدل‌سازی، تعیین یا شناسایی مدل براساس ویژگی‌های سری مشاهداتی است. تحلیل تغییرات پارامترهای آماری نظیر میانگین، انحراف معیار و چولگی در گام نخست می‌تواند برخی ویژگی‌های مدل را آشکار کند.

## ماشین بردار پشتیبان (SVM)

در سال ۱۹۶۵ محقق روس به نام ولادیمیر واپنیک گامی بسیار مهم در طراحی طبقه‌بندی‌کننده‌ها برداشت. وی نظریه آماری یادگیری را به صورت مستحکم‌تری بنا نهاد و ماشین‌های بردار پشتیبان را بر این اساس ارائه داد. ماشین‌های بردار پشتیبان دارای خواص زیرند:

۱. طراحی طبقه‌بندی‌کننده با حداکثر تعمیم؛  
 ۲. رسیدن به نقطه بهینه کلی تابع؛  
 ۳. تعیین خودکار ساختار و توپولوژی بهینه برای طبقه‌بندی‌کننده؛  
 ۴. مدل کردن توابع تمایز غیرخطی با استفاده از هسته‌های غیرخطی و مفهوم حاصل ضرب داخلی در فضاها هیلبرت.

SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابرصفحه را حاصل می‌کنند. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابرصفحه، بردارهای پشتیبان گفته می‌شود. تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود [۲۷]. شکل ۱ فرایند مدل SVM را نشان می‌دهد.

پیش‌بینی دقیقی انجام دهد و در صورتی که برازش کمتر انجام گیرد، مدل داده‌های آموزش را به خاطر می‌سپرد و داده‌های غیر از آموزش را نمی‌تواند پیش‌بینی کند. پارامتر  $C$  یک کنترل‌کننده است و مقدار خطای پیش‌بینی به مقدار کمی تحت تأثیر آن است [۳۴]. مقدار بهینه  $\varepsilon$  به نوع نویز موجود در داده‌ها بستگی دارد. محدوده پارامترهای  $C$ :  $10^{-5}$  تا  $10^{-1}$ ،  $\varepsilon$ :  $10^{-1}$  و  $\gamma$ :  $10^{-1}$  است [۳۵، ۱۶]. با توجه به اینکه پارامتر  $C$  تأثیر کمتری نسبت به دو پارامتر دیگر دارد، ابتدا  $C$  ثابت نگه داشته شده و با تغییر پارامترهای  $\varepsilon$  و  $\gamma$  مقادیر بهینه این دو پارامتر انتخاب می‌شود. سپس پارامتر  $C$  تغییر داده شده و مقادیر بهینه دو پارامتر دیگر دوباره تعیین می‌شود. این روند تا پیدا کردن مقادیر بهینه هر سه پارامتر ادامه می‌یابد.

#### معیارهای ارزیابی عملکرد مدل

از توابع هدف مختلفی می‌توان برای ارزیابی دقت مدل‌های هیدرولوژیکی استفاده کرد. تابع هدف انتخاب‌شده، به هدف مطالعه بستگی دارد. در این تحقیق عملکرد پیش‌بینی مدل‌ها با استفاده از معیارهای آماری RMSE<sup>۵</sup>، MBE<sup>۶</sup> بررسی شد که این معیارها با استفاده از روابط ۶ و ۷ محاسبه می‌شوند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^{i=n} (A_i - B_i)^2}{n}} \quad (6)$$

$$MBE = \frac{\sum_{i=1}^{i=n} (A_i - B_i)}{n} \quad (7)$$

که در آن  $A_i$ : مقدار دبی محاسبه‌شده؛  $B_i$ : مقدار دبی مشاهداتی؛ و  $n$ : تعداد مشاهدات است.

مقادیر مثبت MBE نشان می‌دهد مدل، دبی را بیشتر از مقدار واقعی و مقادیر منفی نشان می‌دهد مدل دبی را کمتر از مقدار واقعی پیش‌بینی می‌کند.

#### آماره نسبت تفاوت توسعه یافته<sup>۷</sup> (DDR)

با استفاده از آماره‌های  $R^2$  و RMSE نمی‌توان در مورد عملکرد مدل و نحوه توزیع خطا قضاوت درستی انجام داد، به دلیل اینکه این دو آماره، بیانگر معیار متوسطی از خطا

یک تابع معین  $f$  به علاوه یک مقدار اضافی نویز<sup>۱</sup> مشخص می‌شود.

$$y = f(x) + noise \quad (2)$$

بنابراین موضوع اصلی یافتن فرم تابع  $f$  است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است پیش‌بینی کند. این تابع از راه آموزش مدل SVM بر روی یک مجموعه داده به عنوان مجموعه آموزش که شامل فرآیندی به منظور بهینه‌سازی دائمی تابع خطا است، قابل دسترسی است. تابع خطا به صورت رابطه ۳ بیان می‌شود.

$$\frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i \sum_{i=1}^N \xi_i^o \quad (3)$$

تابع خطای مذکور باید با توجه به محدودیت‌های رابطه ۴ کمینه شود.

$$\begin{aligned} W^T \phi(X_i) + b - y_i &\leq \varepsilon + \xi_i^o \\ Y_i - W^T \phi(X_i) - b &\leq \varepsilon + \xi_i^o \\ \xi_i, \xi_i^o &\geq 0, \quad i = 1, \dots, N \end{aligned} \quad (4)$$

که در این روابط  $C$  ثابت گنجایش<sup>۲</sup>؛  $W$  بردار ضرایب،  $W^T$  ترانهاده بردار ضرایب؛  $\xi_i^o$  و  $\xi_i$  ضرایب کمبود<sup>۳</sup>؛  $b$  ضریبی ثابت؛  $N$  الگوی آموزش مدل؛ و  $\phi$  تابع کرنل است. کرنل تابع پایه شعاعی<sup>۴</sup> به عنوان بهترین انتخاب از بین دیگر توابع کرنل گزارش شده است [۲۴]. بنابراین در این تحقیق تابع مذکور که توسط  $\gamma$  در رابطه ۵ تعریف شده است، به کار گرفته شد.

$$K(x_i, x) = \exp(-\gamma |x_i - x|^2) \quad (5)$$

با توجه به روابط قبل لازم است برای پیش‌بینی دبی ماهانه توسط مدل SVM سه پارامتر  $\gamma$ ،  $\varepsilon$  و  $C$  بهینه شوند.

پارامتر  $\gamma$  در SVM مهم است، زیرا این پارامتر ممکن است به بیش‌برازش یا برازش کمتر منجر شود. برازش کمتر هنگامی اتفاق می‌افتد که مدل نتواند برای داده‌های آموزش

5. Root Mean Square Error  
6. Mean Bias Error  
7. Developed Discrepancy Ratio

1. Noise  
2. Capacity Constant  
3. Slack Variables  
4. Radial Base Function (RBF)

گوسی مقادیر نرمال شده DDR (QDDR) محاسبه شود.



### نتایج و بحث

اجرای مدل SVM با فرایند آزمون و خطا و به منظور تعیین مقادیر بهینه سه پارامتر  $\gamma$ ،  $\epsilon$  و C انجام گرفت. تعیین بهترین مدل سری زمانی شامل مراحل است که نمونه‌ای از آن برای ایستگاه تمر در مقیاس ماهانه در شکل ۳ ارائه شده است. داده‌های سری زمانی دارای روند نزولی اند که به منظور حذف روند از یک تفاضل درجه اول استفاده شد (شکل ۳). برای بررسی صحت فرایند حذف روند و تعیین بهترین مدل سری زمانی، نمودارهای خودهمبستگی و خودهمبستگی جزئی (شکل ۴) ترسیم شد. با توجه به اینکه نمودار خودهمبستگی حالت نزولی (سینوسی) دارد و خودهمبستگی جزئی، قطع شده از مرتبه ۱ است، مدل از نوع اتورگرسیون و به صورت  $AR(1, 0)$  است. در این تحقیق برای پیش‌بینی دبی از دو روش SVM و سری زمانی در دو مقیاس ماهانه و هفتگی استفاده شد. مدل‌های بهینه شده براساس داده‌های بخش صحت‌سنجی ارزیابی شده و نتایج به دو صورت کمی و کیفی مقایسه شد.



در مدل بوده و به شدت تحت تأثیر تعداد الگوهای مورد استفاده و همچنین داده‌های پرت هستند [۷]؛ برای تعیین بهترین مدل، علاوه بر آماره‌های مذکور، باید از پارامتر آماری مناسب دیگری نیز استفاده کرد. به منظور دستیابی به آماره‌ای مناسب برای ارزیابی عملکرد مدل، تلاش‌های متعددی صورت گرفته است که از جمله می‌توان به آماره ارائه شده توسط جین و ایندروتی و همچنین نوری و همکاران اشاره کرد [۱۷، ۲۵]. آماره نسبت تفاوت توسعه‌یافته (DDR) به صورت رابطه ۸ است.

$$DDR = \left( \frac{\text{Predicted Value}}{\text{Observed Value}} \right)^{-1} \quad (8)$$

براساس رابطه ۸، اگر  $DDR=0$ ، آن‌گاه مقادیر پیش‌بینی شده معادل مقادیر اندازه‌گیری شده می‌شود. اگر  $DDR > 0$ ، مقدار پیش‌بینی شده از مقدار مشاهداتی بیشتر و اگر  $DDR < 0$ ، مقدار پیش‌بینی شده از مقدار مشاهداتی کمتر می‌شود. برای قضاوت بهتر در این مورد می‌توان تابع گوسی مقادیر DDR را محاسبه و به صورت یک توزیع نرمال استاندارد رسم کرد. برای این منظور ابتدا باید مقادیر DDR استاندارد شود و سپس با استفاده از تابع



شکل ۳. سری زمانی ماهانه در ایستگاه هیدرومتری تمر (سمت راست) و سری زمانی ماهانه تمر پس از یک مرحله تفاضل (سمت چپ)



شکل ۴. خودهمبستگی ماهانه در ایستگاه هیدرومتری تمر (سمت راست) و خودهمبستگی جزئی ماهانه در ایستگاه

هیدرومتری تمر (سمت چپ)

## ارزیابی مدل‌های ایجادشده

## مقایسه کمی

پس از آنکه مقادیر دبی در دو مقیاس ماهانه و هفتگی به دو روش SVM و سری زمانی پیش‌بینی شد، به‌منظور ارزیابی عملکرد مدل‌ها از پارامترهای آماری MBE (میانگین خطای اریب)، RMSE (ریشه میانگین مربعات خطا) و  $R^2$  (ضریب تعیین) بین مقادیر دبی پیش‌بینی‌شده با مقادیر دبی مشاهداتی تعیین شد. با توجه به شاخص‌های آماری به‌دست‌آمده، عملکرد روش ماشین بردار پشتیبان در تخمین دبی با نتایج حاصل از روش سری زمانی مقایسه شد (جدول ۲). مقدار ضریب تعیین در ایستگاه تمر برای دو روش SVM و سری زمانی به‌ترتیب ۰/۶۱ و ۰/۳۶ است. همچنین مقدار خطای RMSE برای این دو روش به‌ترتیب ۰/۵۸ و ۰/۷۴ است. اگرچه ضریب تعیین SVM به‌مقدار چشمگیری بیشتر و مقدار خطای RMSE آن کمتر از سری زمانی است، هیچ‌کدام از این دو روش نتوانسته‌اند در این ایستگاه مقادیر دبی ماهانه را با دقت مناسبی پیش‌بینی کنند. مقدار مثبت و منفی MBE نشان می‌دهد SVM دبی ماهانه را بیشتر؛ و سری زمانی، آن را کمتر از مقدار واقعی پیش‌بینی کرده است. در ایستگاه حاجی‌قوشان مقادیر ضریب تعیین هر دو روش بسیار زیاد است، اما مقدار خطای RMSE در روش SVM و سری زمانی به‌ترتیب ۰/۱۱ و ۰/۴۷ است که نشان می‌دهد خطای RMSE در روش سری زمانی بیش از سه‌برابر SVM است. همچنین مقدار MBE  $(-۰/۳۰)$  در سری زمانی نشان می‌دهد در این روش دبی ماهانه تا حد زیادی کمتر از مقدار واقعی تخمین زده شده است. مقادیر خطا نشان می‌دهد در این ایستگاه SVM دبی ماهانه را با دقت بیشتری تخمین زده است. در ایستگاه قره‌شور ضریب تعیین برای SVM و سری زمانی به‌ترتیب ۰/۸۰ و ۰/۵۱ است. خطای RMSE سری زمانی بیش از ۱/۵ برابر SVM است. مدل SVM بیش‌برآوردی در تخمین دبی ماهانه داشته  $(MBE=۰/۱)$  و سری زمانی دبی ماهانه را کمتر از مقدار مشاهده‌ای  $(MBE=-۰/۰۸)$  تخمین زده است؛ از این‌رو در این ایستگاه نیز SVM توانسته دبی ماهانه را با دقت بیشتری تخمین بزند. مقایسه دو روش SVM و سری زمانی در مقیاس ماهانه در سه ایستگاه نشان می‌دهد که در هر سه ایستگاه دقت SVM در پیش‌بینی دبی ماهانه

بیشتر از سری زمانی است. در ایستگاه تمر اگرچه SVM دقت بیشتری نسبت به سری زمانی دارد، پیش‌بینی آن به‌دلیل ضریب تعیین کم و خطای زیاد قابل قبول نیست. در هر سه ایستگاه، SVM مقدار دبی ماهانه را بیشتر از مقدار واقعی و سری زمانی کمتر از مقدار واقعی پیش‌بینی کردند. جدول ۳ مقادیر ضریب تعیین و مقادیر خطای RMSE و MBE را برای دو روش SVM و سری زمانی در پیش‌بینی دبی به‌صورت هفتگی در سه ایستگاه تمر، حاجی‌قوشان و قره‌شور نشان می‌دهد. در ایستگاه تمر مقدار ضریب تعیین برای SVM و سری زمانی به‌ترتیب ۰/۶۳ و ۰/۳۸ و مقدار خطای RMSE نیز به‌ترتیب ۰/۶۰ و ۰/۷۲ است. مقادیر MBE برای SVM و سری زمانی به‌ترتیب ۰/۱۱ و ۰/۰۲ است که نشان می‌دهد میانگین خطای سری زمانی بسیار کم است. در این ایستگاه هر دو روش دبی هفتگی را با دقت کمی پیش‌بینی کرده‌اند. در ایستگاه حاجی‌قوشان مقدار ضریب تعیین برای SVM و سری زمانی به‌ترتیب ۰/۸۶ و ۰/۹۱ است که نشان می‌دهد دقت هر دو روش قابل قبول است. مانند ایستگاه تمر مقدار RMSE هر دو روش تقریباً یکسان است و مقدار MBE نشان می‌دهد دبی‌ها در روش SVM بیشتر از مقدار واقعی و در روش سری زمانی کمتر از مقدار واقعی تخمین زده می‌شود. در ایستگاه قره‌شور مقدار ضریب تعیین هر دو روش کمتر از ۰/۶۰ است که نشان می‌دهد هر دو روش نتوانسته‌اند دبی را در این ایستگاه با دقت قابل قبولی پیش‌بینی کنند. مقادیر MBE نشان می‌دهد هر دو روش دبی را بیشتر از مقدار واقعی پیش‌بینی می‌کنند. مقایسه ضرایب تعیین و مقادیر خطای دو روش بیانگر دقت کم هر دو روش در پیش‌بینی دبی در مقیاس هفتگی است. هر دو روش فقط نتوانسته‌اند در ایستگاه حاجی‌قوشان دبی هفتگی را به‌خوبی پیش‌بینی کنند و در دو ایستگاه دیگر دقت هر دو روش کم است. همچنین مقادیر MBE در سه ایستگاه نشان می‌دهد به‌جز روش سری زمانی در ایستگاه حاجی‌قوشان بقیه حالت‌ها دبی را بیشتر از مقدار واقعی پیش‌بینی کرده‌اند. همچنین مقدار MBE در سری زمانی کمتر از SVM است که نشان می‌دهد تخمین کمتر یا بیشتر از مقدار واقعی در سری زمانی یکنواخت‌تر از SVM است.

جدول ۲. نتایج مرحله آزمایش مدل های SVM و AR در مقیاس ماهانه

نام ایستگاه	روش داده کاوی		مشخصه آماری	
	مدل	مشخصات	RMSE	MBE
تمر	SVM	$\varepsilon=0/1$ $c=700$ $\gamma=1/9$	0/58	0/06
	AR	AR(1,1,0)	0/74	-0/11
حاجی قوشان	SVM	$\varepsilon=0/1$ $c=20000$ $\gamma=5/5$	0/11	0/04
	AR	AR(1,1,0)	0/47	-0/30
قره شور	SVM	$\varepsilon=0/2$ $c=3000$ $\gamma=0/005$	0/32	0/10
	AR	AR(1,1,0)	0/49	-0/08

جدول ۳. نتایج مرحله آزمایش مدل های SVM و AR، در مقیاس هفتگی

نام ایستگاه	روش داده کاوی		مشخصه آماری	
	مدل	مشخصات	R <sup>2</sup>	MBE
تمر	SVM	$\varepsilon=0/55$ $c=8000$ $\gamma=0/002$	0/63	0/11
	AR	AR(1,1,0)	0/38	0/02
حاجی قوشان	SVM	$\varepsilon=0/06$ $c=15000$ $\gamma=0/003$	0/86	0/25
	AR	AR(1,1,0)	0/91	-0/04
قره شور	SVM	$\varepsilon=0/04$ $c=6000$ $\gamma=0/003$	0/57	0/06
	AR	AR(1,1,0)	0/39	0/04


واقعی تخمین زده است؛ در صورتی که در مقیاس هفتگی فقط در ایستگاه حاجی قوشان، سری زمانی دبی را کمتر از مقدار واقعی پیش بینی کرده است و در دیگر حالت ها تخمین بیشتر از مقدار واقعی بوده است. در مقیاس هفتگی مقدار MBE در سری زمانی کمتر از SVM است.

#### مقایسه گرافیکی

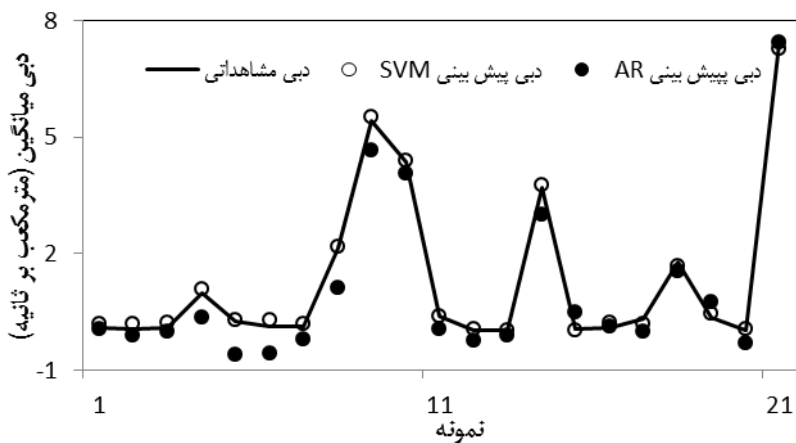
به منظور مقایسه گرافیکی مقادیر دبی پیش بینی شده، داده های آزمون در هر دو روش SVM و سری زمانی با مقادیر دبی مشاهداتی مقایسه شد. مقایسه مقادیر واقعی و خروجی از دو روش SVM و سری زمانی در مقیاس ماهانه در شکل های ۵، ۶ و ۷ آورده شده است.

مقایسه ضرایب تعیین دبی ماهانه و هفتگی ایستگاه های مختلف نشان می دهد در هر دو روش، سری زمانی و SVM در دو ایستگاه حاجی قوشان و قره شور، دبی در مقیاس ماهانه با دقت بیشتری نسبت به دبی در مقیاس هفتگی پیش بینی شده است؛ اما در ایستگاه تمر مقادیر ضریب تعیین و خطای RMSE دبی ماهانه و هفتگی مشابه یکدیگر است. به طور کلی هر دو روش دبی در مقیاس ماهانه را با دقت بیشتری نسبت به مقیاس هفتگی پیش بینی کرده اند. هنگام استفاده از مقیاس ماهانه، تغییرات دبی نسبت به مقیاس هفتگی کمتر می شود و در نتیجه روند تغییرات با دقت بیشتری قابل پیش بینی می شود. در مقیاس ماهانه در هر سه ایستگاه، سری زمانی، دبی را کمتر از مقدار واقعی و SVM بیشتر از مقدار

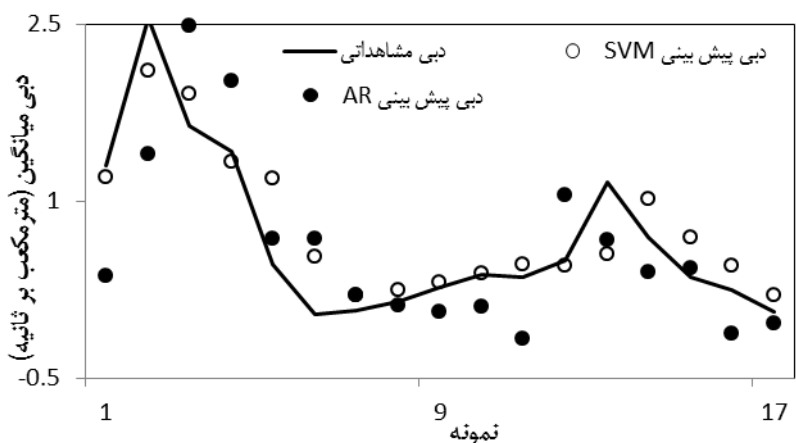




شکل ۵. مقایسه مقادیر دبی مشاهداتی و دبی پیش‌بینی شده به‌روش SVM و AR در ایستگاه تمر در دوره صحت‌سنجی (مقیاس ماهانه)



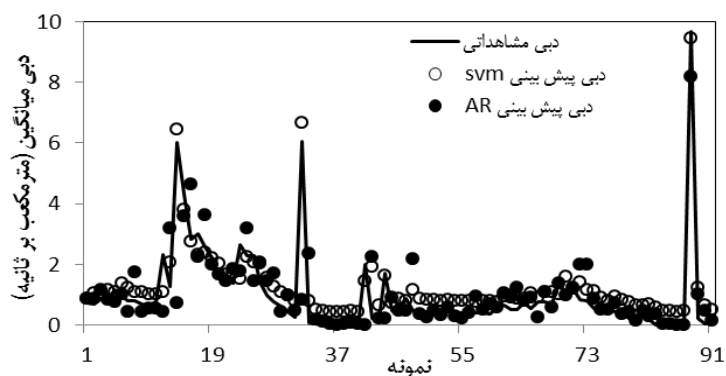
شکل ۶. مقایسه مقادیر دبی مشاهداتی و دبی پیش‌بینی شده به‌روش SVM و AR در ایستگاه حاجی قوشان در دوره صحت‌سنجی (مقیاس ماهانه)




شکل ۷. مقایسه مقادیر دبی مشاهداتی و دبی پیش‌بینی شده به‌روش SVM و AR در ایستگاه قره‌شور در دوره صحت‌سنجی (مقیاس ماهانه)

قره‌شور (شکل‌های ۸ و ۹) برای بعضی ماه‌ها دبی منفی پیش‌بینی کرده است. شکل‌های ۸، ۹ و ۱۰ مقایسه دبی‌های مشاهده‌ای و پیش‌بینی‌شده در مقیاس زمانی هفتگی را نشان می‌دهد. در ایستگاه تمر (شکل ۸) SVM روند تغییرات دبی مشاهده‌ای را به خوبی دنبال می‌کند، اما در دو ایستگاه دیگر تغییرات هر دو روش نسبت به مقادیر مشاهده‌ای زیاد است.

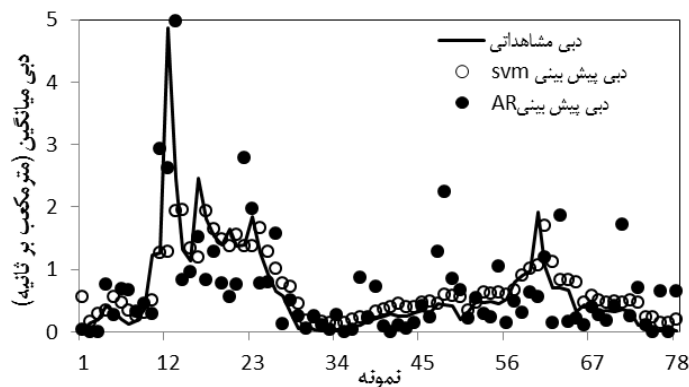
شکل‌های ۵، ۶ و ۷ نشان می‌دهد در ایستگاه حاجی‌قوشان (شکل ۶) روند تغییرات دبی مشاهده‌ای توسط دو روش SVM و سری زمانی به خوبی دنبال می‌شود، اما در دو ایستگاه قره‌شور و تمر روند تغییرات دبی پیش‌بینی‌شده با روش SVM و سری زمانی با مقادیر مشاهده‌ای زیاد است. دبی پیش‌بینی‌شده با روش SVM در تمام ایستگاه‌های مقادیر مثبت است، اما سری زمانی در ایستگاه‌های حاجی‌قوشان و



شکل ۸. مقایسه مقادیر دبی مشاهده‌ای، دبی پیش‌بینی‌شده به روش SVM و AR در ایستگاه تمر در دوره صحت‌سنجی (مقیاس هفتگی)



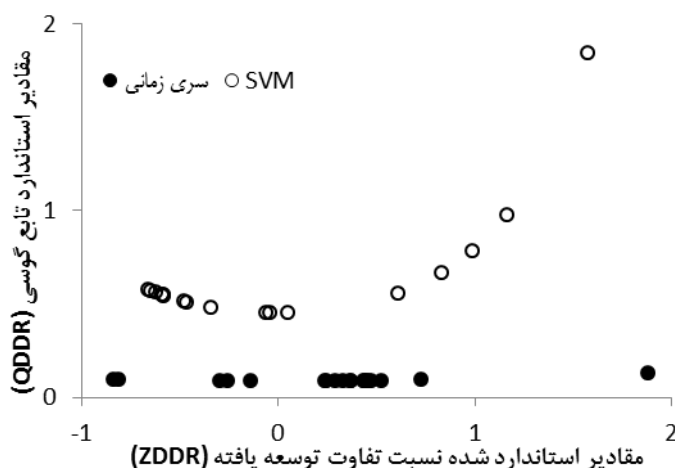
شکل ۹. مقایسه مقادیر دبی مشاهده‌ای، دبی پیش‌بینی‌شده به روش SVM و AR در ایستگاه حاجی‌قوشان در دوره صحت‌سنجی (مقیاس هفتگی)




شکل ۱۰. مقایسه مقادیر دبی مشاهده‌ای، دبی پیش‌بینی‌شده به روش SVM و AR در ایستگاه قره‌شور در دوره صحت‌سنجی (مقیاس هفتگی)

در شکل‌های ۱۱ و ۱۲ بزرگ‌تر بودن مقادیر QDDR نشان‌دهنده دقت بیشتر مدل است. با توجه به شکل ۱۱ مشخص است در ایستگاه حاجی‌قوشان در مقیاس ماهانه، روش SVM دارای دقت بیشتری نسبت به سری زمانی است. در مقیاس هفتگی دو نمودار مربوط به سری زمانی و SVM بر روی هم قرار گرفته‌اند که بیانگر دقت برابر این دو روش است.

مقایسه مقادیر خطا در دو مقیاس هفتگی و ماهانه برای سه ایستگاه (جدول‌های ۲ و ۳) نشان می‌دهد در ایستگاه حاجی‌قوشان در مقیاس هفتگی و ماهانه، ضریب تعیین و مقادیر خطای SVM و سری زمانی به یکدیگر نزدیک است. به‌منظور انتخاب بهترین روش در دو مقیاس هفتگی و ماهانه از آماره DDR استفاده شد. توزیع نرمال استاندارد برای هر یک از مدل‌های SVM و سری زمانی در شکل‌های ۱۱ و ۱۲ نشان داده شده است.



شکل ۱۱. نمودار توزیع نرمال استاندارد شده مقادیر DDR برای ایستگاه حاجی‌قوشان در مقیاس ماهانه



شکل ۱۲. نمودار توزیع نرمال استاندارد شده مقادیر DDR برای ایستگاه حاجی‌قوشان در مقیاس هفتگی

در ایستگاه حاجی‌قوشان ضریب تعیین هر دو روش زیاد است؛ اما خطای سری زمانی بیش از چهار برابر SVM است و در ایستگاه قره‌شور SVM دارای دقت بیشتری نسبت به سری زمانی است. در مقیاس هفتگی فقط در ایستگاه حاجی‌قوشان نتایج قابل قبول است و در دو ایستگاه دیگر،

### نتیجه‌گیری

در این تحقیق از دو روش سری زمانی و ماشین بردار پشتیبان (SVM) به‌منظور پیش‌بینی دبی ماهانه و هفتگی در سه ایستگاه استفاده شد. در مقیاس ماهانه در ایستگاه تمر هر دو روش با خطای زیادی دبی را پیش‌بینی کردند.

سری‌های زمانی، اولین کنفرانس بین‌المللی مدیریت منابع آب، ۲۷-۲۵ مرداد، دانشگاه صنعتی شاهرود.

[۶]. موسوی، سعید؛ بنی‌حبیب، محمد؛ بندری، ریحانه، ۱۳۹۰، پیش‌بینی جریان روزانه ورودی به مخزن سد دز با استفاده از مدل‌های سری زمانی، یازدهمین سمینار سراسری آبیاری و کاهش تبخیر، کرمان، ایران.

[۷]. نوری، روح‌الله؛ خاکپور، امیر؛ دهقانی مجید؛ فرخ‌نیا، اشکان، ۱۳۸۹، پیش‌بینی ماهانه جریان با استفاده از ماشین بردار پشتیبان بر مبنای آنالیز مؤلفه اصلی، مجله آب و فاضلاب، دوره ۲۲، شماره ۷۷: ۱۲۳-۱۱۸.

[8]. Behzad, M., Asghari, K. Eazi, M. and Palhang, M. 2009. Generalization performance of support vector machines and neural networks runoff modeling. *Expert System with Applications*, 36: 7624-7629.

[9]. Bray, M., and Han, D. 2004. Identification of support vector machines for runoff modeling. *Journal of Hydroinformatics*, 6: 265-280.

[10]. Chen, S.T., Yu, P.Sh. and Tang, H.Y. 2010. Statistical downscaling of daily Precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385: 13-23.

[11]. Choy, K.Y. and Chan, C.W. 2003. Modelling of river discharges and rainfall using radial basis function networks based on support vector regression. *International Journal of Svstems Science*, 34:763-773.

[12]. Ckersik N. 2001. Hydrogeology and groundwater modeling to solve problems. Translate: Manoucher Chitchian, Heidar Ali Kashkooli. Shahid Chamran University Press.

[13]. Dibike, Y.B., Velickov, S., Solomatine, D.P. and Abbott, M.B. 2001. Model induction with support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering*, 15: 208-216.

[14]. El-Shafie, Reda Taha, A. and Noureldin, A. 2007. A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water Resour Manage*. 21: 533-556.

[15]. Hipel, K.W. and McLeod, A.I. 1994. Time series modeling of water resources and environmental systems. Elsevier, Amsterdam.

[16]. Hsu, C., Chang, C. and Lin, C. 2003. A practical guide to support vector classification. User manuall.

دقت روش‌ها کم است. به‌طور کلی پیش‌بینی در مقیاس هفتگی به دلیل تغییرات زیاد دبی دارای خطای زیادی است. روش SVM با استفاده از هوش مصنوعی توانست دقت تخمین دبی را در هر دو مقیاس ماهانه و هفتگی نسبت به سری زمانی افزایش دهد، اما به‌طور کلی در مقیاس هفتگی، نتایج کارایی کمی دارد. در مقیاس ماهانه، SVM دبی را بیشتر از مقدار واقعی و سری زمانی کمتر از مقدار واقعی پیش‌بینی کرد. در مقیاس هفتگی به‌جز سری زمانی در ایستگاه حاجی قوشان در دیگر حالت‌ها دبی بیشتر از مقدار واقعی پیش‌بینی شد. نتایج نشان داد SVM ابزاری توانمند در شبیه‌سازی تغییرات زمانی دبی است و می‌تواند پیش‌بینی بهتری نسبت به روش سری زمانی انجام دهد.

#### منابع

[۱]. اکانل، باورمن، ۱۳۷۵، پیش‌بینی سری‌های زمانی: شناسایی، تخمین و پیش‌بینی، ترجمه رضا شیوا، مؤسسه مطالعات و پژوهش‌های بازرگانی، تهران.

[۲]. خزایی، مجید؛ میرزایی، محمدرضا، ۱۳۹۲، مقایسه کارایی پیش‌بینی دبی ماهانه با استفاده از روش‌های شبکه عصبی مصنوعی و سری‌های زمانی. نشریه علمی- پژوهشی مهندسی و مدیریت آبخیز، جلد ۵، شماره ۲، ۱۳۹۲: ۸۴-۷۴.

[۳]. خلیلی، کیوان؛ فاخری‌فرد، احمد؛ حصاری، بهزاد، ۱۳۸۶، آنالیز منحنی‌های شدت- مدت و فراوانی خشکسالی و طرح مخازن برای کشاورزی و شرب، سومین کنگره عمران، ۱۳-۱۱ اردیبهشت، دانشگاه تبریز.

[۴]. سبزی‌پرور، علی‌اکبر؛ مختار، بهناز؛ صادقی‌فر، مجید؛ سقائی، صبا؛ ارشاد فتح، فرناز؛ نوروز ولاشدی، رضا، ۱۳۹۲، برآورد تبخیر روزانه از تشت با استفاده از مدل‌های موجود سری زمانی. نشریه علمی پژوهشی مهندسی و مدیریت آبخیز، جلد ۶، شماره ۱۳۹۳: ۵۱-۴۲.

[۵]. صباغیان، رضا؛ شریفی، محمداقبر، ۱۳۸۸، استفاده از مدل‌های اتفافی در شبیه‌سازی جریان رودخانه و پیش‌بینی دبی متوسط سالانه رودخانه توسط تحلیل

- [17]. Jain, A. and Indurthy, S.K. 2003. Comparative analysis of event based rainfall-runoff modeling techniques-deterministic, statistical, and artificial neural network. *Journal of Hydrologic Engineering*, 8: 93-98.
- [18]. Laux P., Vogl, S., Qiu, W., Knoche, H.R. and Kunstmann, H. 2011. Copula-based statistical refinement of precipitation in RCM simulations over complex terrain *Hydrol. Earth System Science*, 15: 2401-2419
- [19]. Liong, S.Y. and Sivapragasam, C. 2002. Flood stage forecasting with support vector machines. *Journal of the American Water Resources Association*, 38: 173-196.
- [20]. Mahjoobi, J. and Mosabbeq, A. 2009. Prediction of significant Wave height using regressive support vector machines. *Ocean Engineering*, 36: 339-347.
- [21]. Méndezm, C., Manteiga, G., Bandem, F., Sánchez, P. and Calderón, L. 2004. Modelling of the monthly and daily behavior of the runoff of the Xallas River using Box-Jenkins and Neural Networks methods. *Journal of Hydrology*, 296:38-58.
- [22]. Mohandes, M.A., Halawani, T.O., Rehman, S.A. and Hssain, A.A. 2004. Support vector machines for Wind speed prediction. *Renewable Energy*, 29: 939-947.
- [23]. Nayak, P.C., sudheer, K.P., Rangan, D.M. and Ramasastri, K.S. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291: 52-66.
- [24]. Noori, R., Karbassi, A., Farokhnia, A. and Dehghani, M. 2009. Predicting the longitudinal dispersion coefficient using support vector machine and adaptive neuro-fuzzy inference system techniques. *Environmental Engineering Science*, 26: 1503-1510.
- [25]. Noori, R., Karbassi, A.R., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M.H., Forokhnial, A. and Ghafari- Goushesh, M. 2011. Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*, 401: 177-189.
- [26]. Sakhare, S. and Deo, M.C. 2009. Derivation of wave spectrum using data driven methods. *Marine Structures*, 30: 1-16.
- [27]. Shin, S., Kyung, S., Lee, T. and Kim, J.H. 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28: 127-135.
- [28]. Thomas, H.A. and Fiering, M.B. 1962. Mathematical synthesis of stream flow sequences for the analysis of river basin by simulation. *Harward university press, Cambridge*, 751 pp.
- [29]. Thompstone, R.M., Hipel, K.W. and Mcleod, A.I. 1985. Forecasting quarter-monthly river flow. *Water Resources Bulletin*, 21: 731-741.
- [30]. Tripathi, Sh., Srinivas, V.V. and Nanjundiah, R.S. 2006. Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, 330: 62-640.
- [31]. Tsonis, A.A. 2001. Probing the linearity and nonlinearity in the transitions of the atmospheric circulation. *Nonlinear Processes Geophysics*. 8: 341-345.
- [32]. Vapnik, V.N. 1995. *The nature of statistical learning theory*, Springer-Verlag, New York.
- [33]. Wang, W., Van Gelder, P.H., Vrijling, J.K. and Ma, J. 2005. Testing and modeling autoregressive conditional heteroskedasticity of streamflow processes. *Nonlinear Processes Geophysics*, 12: 55-66.
- [34]. Wang, W.J., Xu, Z.B., Lu, W.Z. and Zhang, X.Y. 2003. Determination of the spread parameter in the Gaussian kernel for classification and regression. *Neurocomputing*, 55: 643-663.
- [35]. Yu, X., Liong, S.Y. and Babovic, V. 2004. EC-SVM approach for realtime hydrologic forecasting. *Journal of Hydroinformatics*, 6: 209-23.
- [36]. Yurekli K., Kurung A. and Ozturk F. 2005. Testing the Residuals of an ARIMA Model on the Cekerek Stream Watershed in Turkey. *Turkish Journal of Enviromental Science*, 29: 61-74.