

مقاله پژوهشی

پیش‌بینی فرآیند بارش - رواناب با بهره‌گیری از مدل ترکیبی بهینه‌سازی تجمعی ذرات - ماشین بردار پشتیبان موجکی (مطالعه موردی: دشت سیلاخور)

مهدی کماسی^{۱*} سروش شرقی^۲

تاریخ دریافت: ۱۳۹۸/۱۰/۱۵ تاریخ پذیرش: ۱۳۹۹/۱۲/۲۳

- ۱- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آیت اله العظمی بروجردی (ره)
۲- دانشجوی کارشناسی ارشد گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آیت اله العظمی بروجردی (ره)
* مسئول مکاتبات، پست الکترونیکی: komasi@abru.ac.ir

چکیده

مدل‌سازی و پیش‌بینی فرآیند بارش-رواناب نقش مهمی را در مدیریت منابع آب، برنامه‌ریزی‌های شهری، عملکرد مخازن سد و... ایفا می‌کند. ماشین بردار پشتیبان (SVM) به عنوان یکی از مدل‌های نوین هوش مصنوعی، از قابلیت انعطاف‌پذیری بالایی در پیش‌بینی داده‌های هیدرولوژیکی برخوردار است. در این پژوهش ایده‌ی مدل‌سازی فرآیند بارش-رواناب توسط مدل ترکیبی الگوریتم بهینه‌سازی تجمعی ذرات و ماشین بردار پشتیبان موجکی (PSO-WT-SVM) مطرح گردیده است. در ساختار الگوریتم SVM پارامترهای ثابتی وجود دارد که می‌بایست توسط کاربر تعیین گردند بطوریکه انتخاب نامناسب این پارامترها موجب کاهش قابل توجه کارایی مدل می‌گردد. جهت حل این مشکل از الگوریتم بهینه‌سازی تجمعی ذرات (PSO) برای یافتن مقادیر بهینه‌ی پارامترهای مدل SVM استفاده شده و مدل ترکیبی PSO-SVM معرفی می‌شود. در گام بعدی، با انجام عمل پیش‌پردازش بر روی داده‌ها توسط تبدیل موجک (WT) مدل PSO-WT-SVM مطرح می‌گردد. نهایتاً سری زمانی روزانه بارش-رواناب دشت سیلاخور واقع در استان لرستان توسط مدل ساده SVM و مدل‌های ترکیبی PSO-SVM و PSO-WT-SVM مدل‌سازی و پیش‌بینی شده و دقت مدل‌سازی توسط دو معیار ضریب تبیین و میانگین مربع خطاها (RMSE) مورد سنجش قرار می‌گیرد. نتایج حاصل از این مدل‌سازی در مرحله صحت‌سنجی نشان می‌دهد که مدل ترکیبی PSO-SVM و PSO-WT-SVM با ضریب تبیین به ترتیب ۰/۷۲ و ۰/۸۹ جایگزین بسیار مناسبی نسبت به مدل SVM با ضریب تبیین ۰/۵۷ برای پیش‌بینی سری زمانی بارش-رواناب دشت سیلاخور می‌باشند.

واژه‌های کلیدی: آنالیز موجک، الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، مدل ماشین بردار پشتیبان (SVM)، مدل ترکیبی

Rainfall-Runoff Process Predicting Using the Hybrid Model of Particle Swarm Optimization-Wavelet Support Vector Machine (Case study: Silakhor Plain)

M Komasi^{1*}, S Sharghi²

Received: January 5, 2020 Accepted: March 13, 2021

1- Assoc. Prof., Faculty of Civil Engineering, University of Ayatollah Ozma Borujerdi

2- MSc. Student, Faculty of Civil Engineering, University of Ayatollah Ozma Borujerdi

Corresponding, Author, Email: komasi@abru.ac.ir.

Abstract

Rainfall-runoff modeling and predicting play an essential role in water resource managing, urban planning, reservoir operating, etc. Support vector machine (SVM), as one of the new models of artificial intelligence, has high capability and flexibility in predicting hydrological data. In this research, the idea of rainfall-runoff process modeling using the hybrid model of Particle Swarm Optimization-Wavelet Transform-Support Vector Machine (PSO-WT-SVM) is proposed. There are constant parameters in the SVM algorithm that should be appropriately determined by the user, whereas a wrong choice of these parameters results in a significant reduction in the model performance. In order to solve this problem, the Particle Swarm Optimization (PSO) algorithm is employed to find the best values of SVM constant parameters introducing the PSO-SVM hybrid model. In the next step, applying the Wavelet Transform (WT) pre-processing method on the raw data, this research aims at proposing PSO-WT-SVM hybrid model. Finally, the daily rainfall-runoff time series of the Silakhor plain located in Lorastan province are modeled and forecasted using the SVM single model, PSO-SVM, and PSO-WT-SVM hybrid models. The models' accuracy is assessed using DC and RMSE criteria. The results indicate that PSO-SVM and PSO-WT-SVM hybrid models with DC of 0.72 and 0.89, respectively, supersede the SVM single model with DC of 0.57 in the verification step for Silakhor plain rainfall-runoff time series modeling.

Keywords: Hybrid model, Particle swarm optimization, Support vector machine model, Wavelet analysis

مقدمه

مدل‌های جعبه سیاه یا هوش مصنوعی (AI)^۱، اخیراً مورد توجه پژوهشگران قرار گرفت. یکی از شاخص‌ترین مدل‌ها در این نگرش مدل شبکه عصبی مصنوعی (ANN)^۲ است که دارای کاربردهای فراوانی در زمینه‌های مختلف پیش‌بینی فرآیندهای هیدرولوژیکی می‌باشد (کماسی و شرقی ۲۰۱۴، سولگس و همکاران ۲۰۱۵). از نخستین تحقیقات در زمینه‌ی مدل‌سازی پدیده بارش- رواناب توسط مدل ANN می‌توان به پژوهش‌های هسو و همکاران (۱۹۹۵)، اسمیت و الی

فرآیند تبدیل بارش به رواناب یکی از فرآیندهای مهم چرخه‌ی هیدرولوژیکی محسوب می‌شود که تعیین و پیش‌بینی دقیق آن از نظر شاخص‌های مدیریتی منابع آب، برنامه‌ریزی‌های شهری، مدیریت بحران و ... بسیار حائز اهمیت است. در این راستا پژوهشگران متعددی تلاش نمودند تا با استفاده از مدل‌های هوشمند کامپیوتری به پیش‌بینی سری‌های زمانی هیدرولوژیکی از جمله سری زمانی بارش- رواناب بپردازند. پیشینه و نتایج این تلاش‌ها به اختصار در ادامه بیان می‌شود.

¹ Artificial Intelligence

² Artificial Neural Network

۲۰۰۷، لین و همکاران (۲۰۰۹). در سال‌های اخیر کاربردهای مدل SVM در مباحث هیدرولوژیکی و هواشناسی در مقایسه با مدل شبکه عصبی مصنوعی موردسنجش قرار گرفته است (آسفا و همکاران ۲۰۰۶، ونگ و همکاران ۲۰۰۸، بهزاد و همکاران ۲۰۰۹). برای نمونه فنگ و همکاران (۲۰۲۰) با استفاده از مدل SVM و مدل تجزیه‌ی متغیر (VMD)^۲ به پیش‌بینی سری زمانی رواناب ماهانه در حوضه‌ی یانگتسه چین پرداختند. در پژوهش مذکور توانایی بالای مدل ترکیبی VMD-SVM در مدل‌سازی سری زمانی ماهانه‌ی رواناب تبیین شد بطوریکه مدل VMD در نقش پیش‌پردازنده و تجزیه کننده‌ی سری زمانی ورودی و SVM در نقش پیش‌بینی کننده‌ی سری زمانی خروجی (عمق رواناب) ظاهر شدند. از سویی، در ساختار الگوریتم مدل SVM پارامترهای ثابتی وجود دارند که می‌بایست قبل از اجرا توسط کاربر تعیین گردند. تعیین این پارامترها از الگو و نظم خاصی پیروی نکرده و اختصاص مقادیر نامناسب به آن‌ها موجب کاهش کارایی و دقت مدل‌سازی می‌گردد. بنابراین کاربرد الگوریتم بهینه‌سازی تکاملی^۳ در ترکیب با مدل SVM جهت تعیین مقادیر مناسب و بهینه پارامترهای ثابت این مدل بسیار ضروری به نظر می‌رسد. همچنین با توجه به پیچیدگی سری‌های زمانی هیدرولوژیکی و در بر داشتن مقیاس‌های زمانی مختلف، استفاده از روش پیش‌پردازش^۴ داده‌ها در ترکیب با مدل SVM می‌تواند پیشنهاد مناسبی برای بهبود کارایی این مدل باشد.

در راستای استفاده از الگوریتم‌های بهینه‌سازی در بهبود کارایی روش‌های شبیه‌سازی هیدرولوژیکی، به عنوان کماسی و همکاران (۲۰۱۸) با استفاده از الگوریتم بهینه‌سازی جستجوی فاخته^۵ و مدل SVM به پیش‌بینی خشکسالی پرداختند و به این نتیجه دست

(۱۹۹۵)، مینس و هال (۱۹۹۶) و شمس‌الدین (۱۹۹۷) اشاره داشت. مدل ANN در پژوهش‌های اخیر نیز کاربردهای فراوان نیز داشته است. کماسی و شرقی (۲۰۱۶) با استفاده از ترکیب تبدیل موجک و مدل ANN به پیش‌بینی سیلاب حوضه ليقوان‌چای پرداختند. آن‌ها در این پژوهش تأثیر مطلوب پیش‌پردازش داده‌ها را بوسیله تبدیل موجک بر روی دقت مدل‌سازی به روش ANN مطرح نمودند. هرچند روش‌های مدل‌سازی سری زمانی هیدرولوژیکی بر پایه شبکه عصبی و یا عصبی فازی مناسب می‌باشند، اما نقص اساسی این روش‌ها این است که روند و ساختار شبکه آموزش‌دیده در قالب یک ماتریس ضرایب وزن بیان می‌گردد که در این حالت نمی‌توان تعبیر و تفسیر چندان درستی از پدیده ارائه نمود (ساویس و همکاران ۱۹۹۹). به بیان دیگر در این‌گونه روش‌ها، مدل‌سازی غیرصریح بوده و به‌سادگی توسط دیگران قابل درک و استفاده نمی‌باشد. علاوه بر آن تعداد نرون‌های لایه ورودی و لایه مخفی به‌سادگی قابل تعیین نبوده و نیازمند فرآیند سعی و خطای زیادی است.

امروزه مدل ماشین بردار پشتیبان (SVM)^۱ به عنوان ابزار و نسل نوینی از روش‌های هوش مصنوعی جهت مدل‌سازی سری‌های زمانی مطرح گردیده است. این مدل برای اولین بار توسط وپنیک و کورتس (۱۹۹۵) برپایه تئوری یادگیری آماری ارائه شد. پژوهش‌های انجام شده گویای این واقعیت است که روش SVM سریع‌تر از ANN و ANFIS آموزش می‌بیند (لین و همکاران ۲۰۰۹). یکی دیگر از مزایای روش SVM در مقایسه با سایر روش‌ها این است که این مدل نیاز به داده‌های آموزشی کمتری برای مدل‌سازی دارد. همچنین در روش SVM زمان اجرا نسبت به سایر روش‌ها کوتاه‌تر است (چوی و چن ۲۰۰۳). از طرفی این مدل کارایی مناسبی در کار با داده‌های غیرخطی نسبت به سایر مدل‌ها از خود نشان داده است (هان و همکاران

² Variation mode decomposition

³ Evolutionary

⁴ Pre-processing

⁵ Cuckoo search

¹ Support Vector Machine

یافتند که ترکیب الگوریتم فاخته با مدل SVM می‌تواند منجر به پیش‌بینی شاخص بارش استاندارد شده (SPI^1) با دقت بالایی شود چراکه با استفاده از الگوریتم بهینه‌سازی فاخته می‌توان به بهینه‌سازی پارامترهای ورودی مدل پرداخت. از این رو، در پژوهش حاضر مدل SVM با الگوریتم بهینه‌سازی تجمعی ذرات (PSO)^۲ و روش تبدیل موجک (WT) ترکیب شده و مدل ترکیبی PSO-SVM و PSO-WT-SVM مطرح می‌گردد. در مدل ترکیبی PSO-SVM ابتدا مقادیر بهینه پارامترهای ثابت مدل SVM توسط الگوریتم PSO تعیین شده و سپس سری زمانی روزانه فرآیند بارش-رواناب دشت سیلاخور واقع در استان لرستان در طول سال‌های آبی ۱۳۸۳ تا ۱۳۹۳ توسط مدل بهبود یافته SVM مدل‌سازی و پیش‌بینی می‌گردد. همچنین در مدل ترکیبی PSO-WT-SVM ابتدا پارامترهای ثابت مدل بهینه‌یابی شده و پس از تبدیل و تفکیک سری زمانی توسط فرآیند پیش‌پردازش WT، سری زمانی بارش-رواناب پیش‌بینی می‌گردد. در نهایت کارایی و دقت مدل‌سازی مدل ترکیبی PSO-SVM و PSO-WT-SVM با مدل ساده SVM مقایسه شده و تاثیر الگوریتم PSO و روش پیش‌پردازش تبدیل موجک بر روی مدل SVM مورد تحقیق قرار می‌گیرد.

مواد و روش‌ها

الگوریتم بهینه‌سازی تجمعی ذرات (PSO)

الگوریتم بهینه‌سازی تجمعی ذرات (PSO)^۲ یکی از انواع الگوریتم‌های تکاملی^۳ و یا فراکاشی^۴ محسوب می‌شود که اولین بار در سال ۱۹۹۵ توسط کندی و ابرهات مطرح شد (کندی و ابرهات ۱۹۹۵). این الگوریتم یکی از جدیدترین روش‌های ارائه شده برای حل مسائل بهینه‌سازی است که مبتنی بر هوش جمعی عمل می‌کند و

تقریب مناسبی از پاسخ بهینه به دست می‌آورد. منبع الهام الگوریتم PSO، رفتار اجتماعی حیوانات، همانند حرکت دسته جمعی پرندگان و ماهی‌ها است. در واقع این الگوریتم با تنظیم مسیر حرکت یک جمعیت از ذرات در فضای پاسخ مسئله بر پایه اطلاعات مربوط به بهترین کارایی پیشین مربوط به هر ذره و بهترین کارایی پیشین مربوط به همسایگان هر ذره، عمل جستجو را در فضای پاسخ انجام می‌دهد (کندی و ابرهات ۱۹۹۵). به بیان دیگر الگوریتم PSO از تعداد مشخصی از ذرات تشکیل می‌شود که به طور تصادفی، مقدار اولیه می‌گیرند. برای هر ذره دو مقدار وضعیت و سرعت، تعریف می‌شود که به ترتیب با یک بردار مکان و یک بردار سرعت، مدل می‌شوند (شکل ۱). این ذرات، بصورت تکرار شونده‌ای در فضای n بعدی مسئله حرکت می‌کنند تا با محاسبه‌ی مقدار بهینگی به عنوان یک ملاک سنجش، گزینه‌های ممکن جدید را جستجو کنند. بعد فضای مسئله، برابر تعداد پارامترهای موجود در تابع مورد نظر برای بهینه‌سازی می‌باشد. به عبارت دیگر بعد مسئله بیانگر تعداد مجهولات مسئله مورد نظر است. یک حافظه به ذخیره‌ی بهترین موقعیت^۵ هر ذره در گذشته ($Pbest$) و یک حافظه به ذخیره‌ی بهترین موقعیت پیش آمده در میان همه‌ی ذرات ($Gbest$)، اختصاص می‌یابد. با تجربه‌ی حاصل از این حافظه‌ها، ذرات تصمیم می‌گیرند که در نوبت بعدی، چگونه حرکت کنند. در هر بار تکرار^۶، همه‌ی ذرات در فضای n بعدی مسئله حرکت می‌کنند تا بالاخره نقطه‌ی بهینه‌ی عام پیدا شود (شکل ۱). همچنین سرعت و موقعیت ذرات بر حسب بهترین جواب‌های مطلق و محلی به‌روز می‌شوند. روابط ۱ و ۲ بردار سرعت و تغییر مکان تعداد i ذرات تجمعی را در فضای $n=j$ بعدی نشان می‌دهد.

¹ Standardized Precipitation Index

² Particle Swarm Optimization

³ Particle Swarm Optimization

⁴ Evolutionary Algorithm

⁵ Meta-heuristic

⁶ Position



⁷ Iteration

مسئله و میزان بهینه بودن جوابها بر اساس تعریف یک تابع هدف^۳ که اساس موقعیت ذرات می بایست کمینه یا بیشینه شود تعیین می گردد. مراحل الگوریتم بهینه سازی PSO در فلوجارت شکل ۲ نشان داده شده است. تعیین پارامترهای ورودی، شامل تعیین حدود بالا و پایین پارامترهای ω ، c_1 و c_2 ، جمعیت ذرات (n) و تعداد پارامترها یا همان بعد مسئله (m) و تعداد تکرار حلقه الگوریتم PSO (max_{ite}) می باشد. در پژوهش حاضر، بهترین مقادیر این پارامترها شامل $n=5$ ، $m=2$ ، $\omega_{min}=0.4$ ، $\omega_{max}=0.9$ و $max_{ite}=15$ می باشند (برگ و انگلبرچ ۲۰۰۵).

در پژوهش حاضر جهت تعیین دقت مدل سازی سری زمانی فرآیند بارش - رواناب از دو معیار ضریب تبیین (DC)^۴ (بی بعد) و جزر میانگین مربع خطاها (RMSE)^۵ بر حسب متر مکعب بر ثانیه استفاده می شود (روابط ۳ و ۴). مقادیر معیار DC هرچه به عدد یک نزدیکتر باشد و معیار خطای RMSE هرچه عدد کوچکتری را اختیار کند نشان دهنده دقت و کارایی بالای مدل سازی است. از این رو معیار خطای RMSE را می توان به عنوان تابع هدفی که باید کمینه شود به الگوریتم PSO معرفی کرد.

$$DC = 1 - \frac{\sum_{i=1}^N (\mathcal{Q}_{obs_i} - \mathcal{Q}_{com_i})^2}{\sum_{i=1}^N (\mathcal{Q}_{obs_i} - \bar{\mathcal{Q}}_{obs})^2} \quad [۳]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\mathcal{Q}_{obs_i} - \mathcal{Q}_{com_i})^2}{N}} \quad [۴]$$



شکل ۱- نحوه ی حرکت و تکامل محل قرار گیری یک

ذره به سمت مکان بهینه (بولگ و همکاران ۲۰۱۲).

$$V_{i,j}^{k+1} = \omega \times V_{i,j}^k + c_1 \times r_1 \times (Pbest_{i,j}^k - X_{i,j}^k) + c_2 \times r_2 \times (Gbest_j^k - X_{i,j}^k) \quad [۱]$$

$$X_{i,j}^{k+1} = X_{i,j}^k + V_{i,j}^{k+1} \quad [۲]$$

در این روابط $Pbest_{i,j}^k$ و $Gbest_j^k$ به ترتیب نشان دهنده ی بهترین مکان تجربه شده برای یک ذره^۱ و بهترین مکان تجربه شده ی توسط کل جمعیت^۲ در تعداد تکرار جابجایی k می باشد. ω و r c به ترتیب ضریب تسریع، عدد تصادفی بین ۰ و ۱ و ضریب هدایت کننده سرعت نام دارند. طبق رابطه ۲، موفقیت جدید قرارگیری یک ذره ($X_{i,j}^{k+1}$) عبارت است از موقعیت قبلی آن ذره ($X_{i,j}^k$) به اضافه ی بردار سرعت ($V_{i,j}^{k+1}$). در رابطه ۱ عبارت $V_{i,j}^{k+1}$ خود از سه عبارت مجزا تشکیل شده است که مجموع هر سه بردار که در واقع ضریبی از سه بردار می باشند به برداری از مکان اولیه به مکان ثانویه ی ذره ختم می شود. تغییرات مکانی ذرات در نهایت به گونه ای خواهد بود که همه ی ذرات در محل موقعیت بهینه متمرکز شوند و مختصات این موقعیت جواب مسئله بهینه سازی خواهد بود. معیار تعداد تکرار

³ Objective Function


⁴ Determination Coefficient

⁵ Root Mean Square Error

¹ Personal experience

² Overall experience

زمانی داده‌های ورودی به زیر سری‌هایی با درجات تجزیه مختلف، از یکدیگر مجزا شده و جداگانه وارد مدل می‌شوند و این مدل شناخت دقیق‌تری را از داده‌های ورودی پیدا می‌کند تا عمل پیش‌بینی در نهایت دقت صورت پذیرد. در این پژوهش برای این منظور از تابع تبدیل موجک (WT)^۱ جهت پیش‌پردازش و تجزیه سری زمانی داده‌های ورودی استفاده شده و نهایتاً تاثیر مثبت عمل پیش‌پردازش بر روی مدل‌سازی ماشین بردار پشتیبان نشان داده شده است. شکل ۳ فرآیند تفکیک داده‌ها توسط تبدیل موجک را بصورت شماتیک نشان می‌دهد.



شکل ۳- طرح شماتیک تبدیل موجک (مالات ۱۹۹۸).

مدل ماشین بردار پشتیبان (SVM)

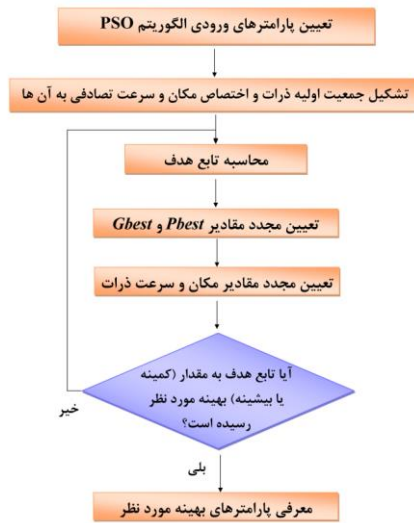
ماشین بردار پشتیبان (SVM) همانند دیگر روش‌های هوش مصنوعی بر مبنای الگوریتم داده‌کاوی عمل می‌کنند. مهمترین وظایف مدل SVM، طبقه بندی و خطی‌سازی یا رگرسیون داده‌ها است. خطی‌سازی داده‌ها بوسیله‌ی الگوریتم خطی‌سازی ϵ -SVR و با معرفی تابع ϵ -sensitive انجام می‌پذیرد. در یک الگوریتم خطی‌سازی ϵ -SVR، با فرض مقادیر ورودی و خروجی x_i و y_i هدف یافتن تابعی است که کمترین انحراف ϵ را از y_i ها داشته باشد. اگر داده‌های آموزشی به تعداد K سری به صورت $(x_1, y_1) \dots (x_k, y_k)$ مورد نظر باشند، تابع خطی‌سازی عبارت است از:

$$f(x) = (w, x) + b \text{ with } b \in R \quad (w, x) \in R^N \quad [5]$$

در تعیین تابع $f(x)$ باید همواره مقادیر خروجی

به‌گونه‌ای تعیین شوند که به طور هم زمان، میزان

کمترین انحراف ϵ تعیین شده و تابع مقدار مناسب w را



شکل ۲- فلوچارت مراحل اجرای الگوریتم PSO.


در روابط یادشده N تعداد داده‌های مشاهداتی، Q_{obs} داده‌های مشاهداتی، Q_{com} مقادیر پیش‌بینی شده و \bar{Q}_{obs} میانگین داده‌های مشاهداتی هستند. شایان ذکر است که کار اصلی همه‌ی الگوریتم‌های بهینه‌سازی تکاملی یافتن مقادیر بهینه یک یا چند متغیر می‌باشد که معیار و میزان بهینه بودن را تابع هدف معین می‌کند. حال رویکرد تعیین این مقادیر در الگوریتم PSO الهام گرفته از حرکت ذرات در طبیعت بوده و بر اساس روابط ۱ و ۲ تعریف می‌شود و تابع هدف نیز بستگی به هر مسئله می‌تواند متفاوت تعیین گردد.

تبدیل موجک (WT)

سری‌های زمانی غالباً نایستا بوده، به این معنی که این سری‌ها به زمان وابسته هستند و از سویی دیگر گسترده‌ی وسیعی از مقیاس‌های زمانی همچون دهه، سال و ماه را دربر می‌گیرند. بنابراین عملیات مدل‌سازی در مواجهه با این سری‌های زمانی با مشکل و عدم دقت روبرو می‌شود. در چنین وضعیتی اگر داده‌های ورودی به مدل مورد نظر توسط یک تابع تبدیل پیش‌پردازش نشوند دقت و کارایی مدل پایین خواهد آمد. عمل پیش‌پردازش داده‌ها می‌تواند با استفاده از یک تابع تبدیل انجام پذیرد به این صورت که سری

¹ Wavelet Transform

مسئله با ابعاد خیلی بالا از قضیه دوگانگی لاگرانژ برای تبدیل مسئله کمینه سازی مورد نظر به فرم دوگانی آن استفاده می گردد که در آن به جای تابع پیچیده Φ که به فضایی با ابعاد بالا می رود، تابع ساده تری به نام تابع هسته^۱ که ضرب برداری تابع Φ است ظاهر می شود (رابطه ۸). بنابراین کافی است در مسائل غیرخطی از کرنل مقادیر ورودی $(K(x_i, x))$ به جای خود تابع استفاده شود.



شکل ۴- مفهوم تبدیل از فضای ورودی به فضای مشخصه (دیبایک و همکاران ۲۰۰۱).

یکی از پرکاربردترین توابع هسته تابع هسته RBF^2 گوسی نام دارد که در این پژوهش نیز در ساختار مدل SVM از آن استفاده شده است. این تابع در رابطه ۹ نشان داده شده است. در ساختار این تابع نیز پارامتر ثابت σ موجود است که می بایست بطور مناسب توسط کاربر مقادری شود.

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad [9]$$

بر این اساس، پارامتر C و σ (KP)^۳ (روابط ۷ و ۹) که به ترتیب پارامتر خطای تولید و پارامتر تابع هسته نام دارند می بایست یا به طور مناسب توسط کاربر مقدار دهی شوند و یا توسط روش های بهینه سازی به مقادیر بهینه خود دست پیدا کنند.

حوضه ی مورد مطالعه

اختیار کند. با حل رابطه ی بهینه سازی زیر دست یابی به چنین شرایطی محقق می شود.

$$\text{Minimize } \frac{1}{2}w^2 \quad \text{subject to } \begin{cases} y_i - (w, x_i) - b \leq \varepsilon \\ (w, x_i) + b - y_i \leq \varepsilon \end{cases} \quad [6]$$

گاهی ممکن است نتوان میزان انحراف ε را لحاظ کرد و باید مقداری انحراف از همان مقدار ε را نیز قابل قبول فرض کرد. این میزان انحراف اضافه با لحاظ کردن متغیرهای (ξ_i, ξ'_i) در رابطه ی بهینه سازی ۶ اعمال می شود که منجر به رابطه ی بهینه سازی ذیل می شود (وینیک، ۱۹۹۵).

$$\text{Minimize } \frac{1}{2}w^2 + C \sum_{i=1}^k (\xi_i + \xi'_i) \quad \text{subject to } \begin{cases} y_i - (w, x_i) - b \leq \varepsilon + \xi_i \\ (w, x_i) + b - y_i \leq \varepsilon + \xi'_i \\ \xi_i, \xi'_i \geq 0 - \text{for all } i=1, 2, \dots, K \end{cases} \quad [7]$$

در رابطه ی ۷، C که خطای تولید نام دارد در واقع رابطه ی جایگزین را برای تابع $f(x)$ مشخص کرده و مقدارش تا مقدار مجاز انحراف ε افزایش می یابد. شایان ذکر است که هرچه مقدار C افزایش یابد، اهمیت میزان خطا بیشتر بوده و در مقابل w کمتر کاهش می یابد و بیشتر می شود. با افزایش w میزان حاشیه کاهش می یابد. بنابراین مقدار C باید به طور مناسب توسط کاربر انتخاب گردد. در نهایت با استفاده از توابع کرنل $k(x_i, x)$ و پارامترهای لاگرانژین λ_i و λ'_i رابطه ی تابع خطی سازی، به شکل رابطه ی ۸ باز نویسی خواهد شد.

$$f(x, b) = \sum_{i=1}^k (\lambda'_i - \lambda_i) k(x_i, x) + b \quad [8]$$

بیان این نکته ضروری است که قبل از خطی سازی داده ها یا همان تقسیم خطی، برای اینکه ماشین بردار پشتیبان بتواند داده های با پیچیدگی بالا را پیش بینی کند داده ها به وسیله تابع Φ به فضای با ابعاد خیلی بالاتر منتقل می شوند (شکل ۴). در این راستا برای حل

¹ Kernel Function

² Gaussian Radial Basis Function


³ Kernel Parameter

دریا، مربوط به جنوب شرقی محدوده می‌باشد. جدول ۱ ویژگی‌های آماری منطقه موردنظر را به صورت روزانه از مهرماه سال آبی (۱۳۸۴-۱۳۸۳) تا مهرماه سال آبی (۱۳۹۳-۱۳۹۴) نشان می‌دهد.

جدول ۱- ویژگی‌های آماری سری زمانی روزانه دشت سیلاخور.

سری زمانی روزانه	بیشینه	کمینه	میانگین
بارش (میلی‌متر)	۴۵/۴۰	۰	۲/۷۱
رواناب (مترمکعب بر ثانیه)	۴۹/۶۰	۰/۴	۵/۰۴

دشت سیلاخور با وسعتی به اندازه ۸۱۹ کیلومترمربع، بزرگ‌ترین زمین هموار استان لرستان در غرب ایران است و در ناحیه‌ای بنام محدوده دورود-بروجرد واقع شده است (شکل ۵). دشت سیلاخور در شمالی‌ترین قسمت حوضه آبریز کارون بزرگ قرار دارد. به علت ورود جریان‌های سطحی به این محدوده مطالعاتی و همچنین وجود بارندگی کافی و برف‌گیر بودن ارتفاعات این محدوده مسیل‌های واقع در آن دائمی بوده و زهکش اصلی این محدوده را رودخانه‌های سیلاخور، ماربره و تیره تشکیل می‌دهند. کمترین ارتفاع محدوده ۱۴۳۷ متر، مربوط به بخش‌های خروجی حوضه و بیشترین ارتفاع محدوده ۳۸۴۵ متر از سطح



شکل ۵- محدوده مطالعاتی دشت سیلاخور (دورود-بروجرد)

شوند بطوریکه ۷۵٪ کل داده‌ها جهت آموزش یا واسنجی^۱ و ۲۵٪ باقی مانده جهت آزمایش یا صحت-سنجی^۲ مدل SVM مورد استفاده قرار می‌گیرند. شایان ذکر است جهت پیاده‌سازی الگوریتم مدل SVM از زبان

نتایج و بحث

نتایج حاصل از مدل SVM

در این بخش از پژوهش حاضر، هدف مدل‌سازی و پیش‌بینی سری زمانی روزانه فرآیند بارش-رواناب دشت سیلاخور توسط مدل SVM می‌باشد. برای این منظور داده‌ها به دو گروه تقسیم می‌-

¹ Calibration

² Verification

شوند. در این پژوهش هر ذره دارای دو ویژگی یا دو بعد است. این دو بعد در واقع همان دو پارامتر ثابت C و KP می باشد. در هربار تکرار الگوریتم PSO، مکان ذرات بگونه ای تغییر می یابد (روابط ۱ و ۲) که موجب تعیین مقادیر بهینه تر دو پارامتر مورد نظر شود. به بیان دیگر، معیار تعیین مکان ذرات، کمینه سازی تابع هدف تعریف شده در مسئله است. با این رویکرد، الگوریتم PSO در هر بار اجرای مدل SVM، مقدار دو پارامتر C و KP را که در واقع همان دو بعد مختصاتی هر ذره می باشند، به گونه ای تعیین می کند که تابع هدف RMSE که همان خطای مدل سازی می باشد کمینه شود.

در مدل ترکیبی PSO-SVM ابتدا می بایست تعداد ذرات و تعداد تکرار حلقه الگوریتم تعیین گردد. در این پژوهش از تعداد ۵ ذره با میزان مرتبه تکرار ۱۵ استفاده شده است. به عبارتی دیگر پنج ذره در یک فضای دو بعدی موجود است که هر کدام دارای دو ویژگی C و KP می باشند (شکل ۶). در این راستا الگوریتم PSO پانزده مرتبه موقعیت ذرات را بر اساس رابطه ۲ و کمینه سازی تابع هدف تغییر می دهد. در هر مرحله از تکرار، مقادیر C و KP محاسبه شده و به مدل SVM معرفی می شوند و سپس پس از مدل سازی فرآیند بارش-رواناب، مقدار ضریب خطای RMSE محاسبه می گردد. در نهایت بهترین ذره^۱ که مشخصه C و KP آن کمترین میزان تابع هدف^۲ را محاسبه می کند معرفی می گردد. به بیان دیگر ذرات به سمت مکان بهینه یا همان مقادیر بهینه C و KP متمرکز شده و بهترین جواب ارائه می شود. به عنوان نمونه، شکل ۷ تغییر مکان ۵ ذره مورد نظر را در طول ۶ تکرار نشان می دهد. در این شکل محور افقی و عمودی به ترتیب مقادیر پارامتر C و KP را نشان می دهد. همانطور که در شکل ۶ نشان داده شده است هنگام تکرار الگوریتم، ذرات در یک نقطه

برنامه نویسی MATLAB استفاده شده است. همانطور که اشاره شده، در ساختار الگوریتم مدل SVM، پارامترهای ثابت C و KP می بایست توسط کاربر مقدار دهی شوند. در این راستا مقادیر این دو پارامتر به صورت تصادفی و بدون هیچگونه الگو و منطقی خاصی در ۵ حالت مقداردهی شده و مدل سازی سری زمانی فرآیند بارش رواناب توسط مدل SVM انجام می پذیرد. نتایج بدست آمده از این مدل سازی در جدول ۲ نشان داده شده است. متغیرهای ورودی و خروجی این مدل به ترتیب بارش و رواناب می باشد.

جدول ۲- نتایج حاصل از مدل سازی سری زمانی

فرآیند بارش- رواناب دشت سیلاخور توسط مدل SVM

	واسنجی		صحت سنجی	
	DC	RMSE $m^3 s^{-1}$	DC	RMSE $m^3 s^{-1}$
C=1 KP=1	۰/۵۶	۳/۵۵	۰/۴۴	۵/۷۰
C=5 KP=5	۰/۵۷	۳/۱۳	۰/۵۱	۵/۳۳
C=5 KP=10	۰/۵۷	۳/۱۳	۰/۵۲	۵/۲۳
C=10 KP=5	۰/۵۸	۳/۰۹	۰/۵۱	۵/۳۱
C=10 KP=10	۰/۵۸	۳/۰۵	۰/۵۷	۴/۲۰

همانطور که در جدول ۲ نشان داده شده است، مقادیر مختلف پارامترهای C و KP موجب تغییر در دقت مدل سازی شده است بطوریکه به ازای $C=KP=1$ ضریب DC دقت ۴۴٪ را در مرحله صحت سنجی نشان می دهد درحالی که به ازای $C=KP=10$ دقت مدل سازی به ۵۷٪ افزایش می یابد.

نتایج حاصل از مدل ترکیبی PSO-SVM

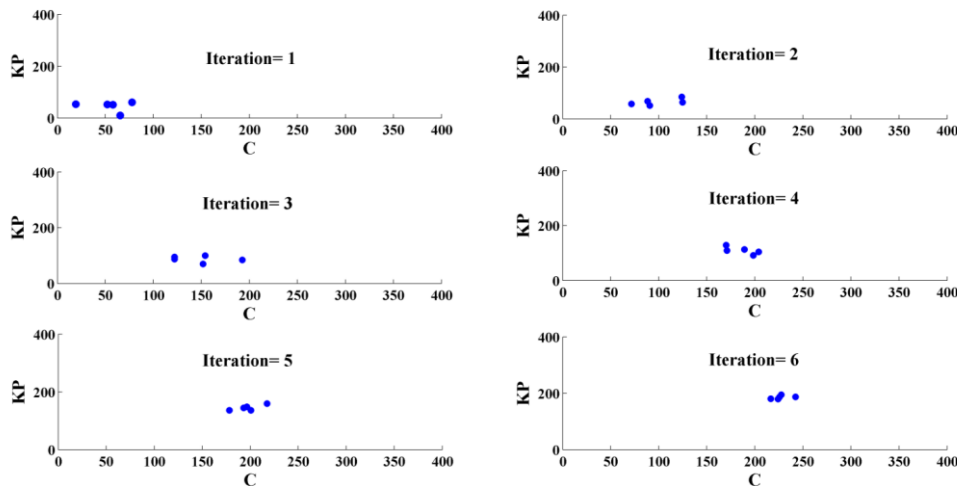
در این بخش الگوریتم PSO با مدل SVM ترکیب شده و مدل PSO-SVM را تشکیل می دهند. هدف از ترکیب این دو مفهوم، بهینه یابی مقادیر دو پارامتر C و KP و افزایش کارایی و دقت مدل سازی SVM می باشد. همانطور که اشاره شد، در الگوریتم PSO، مسئله بصورت یک فضای n بعدی تعریف می شود که تعداد ابعاد، معرف تعداد مجهولاتی است که باید بهینه سازی

¹ Best variable

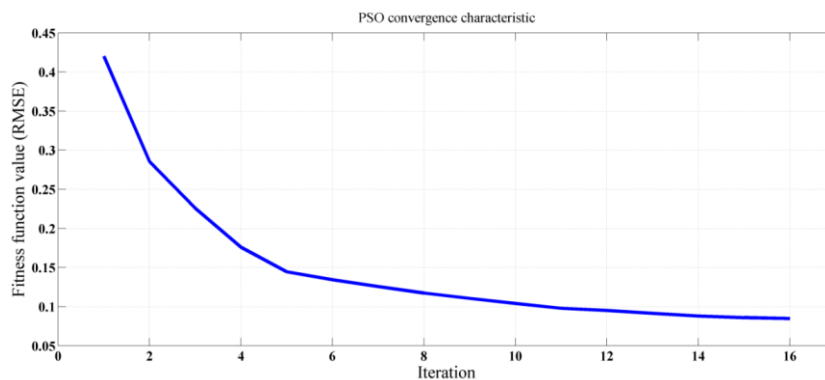
² Bestfun

هدف RMSE در مدل‌سازی فرآیند بارش-رواناب دشت سیلاخور پس از دوازده بار تکرار به مقدار ثابت ۰/۰۹۰ همگرا می‌شود. این مقدار تابع هدف به ازای مقادیر بهینه C و KP است به ترتیب ۱۰۲۱/۳۲ و ۳۴۴/۴۶ محاسبه شده‌اند.

که موقعیت بهینه می‌باشد متمرکز می‌شوند. نتایج حاصل از اجرای مدل ترکیبی PSO-SVM شکل ۷ نشان داده شده است. در این جدول مقادیر تابع هدف در ۱۵ بار تکرار به ازای بهترین ذره (بهترین جواب) به همراه شماره ذره مورد نظر نشان داده شده است. مقدار تابع



شکل ۶- موقعیت ذرات تجمعی مسئله بهینه‌سازی پارامترهای ثابت در طول ۶ مرتبه تکرار



شکل ۷- همگرایی تابع هدف RMSE در طول ۱۵ مرتبه تکرار مدل PSO-SVM.

روش ترکیبی PSO-SVM در مرحله صحت‌سنجی در شکل ۸ نشان داده شده است.


نهایتاً نتایج مدل‌سازی و پیش‌بینی فرآیند بارش-رواناب دشت سیلاخور توسط مدل PSO-SVM به ازای بهترین مقادیر بهینه‌سازی شده $C=1021.32$ و $KP=344.46$ در جدول ۳ نشان داده شده است. در این حالت دقت مدل‌سازی در مرحله صحت‌سنجی به اندازه ۷۲٪ بوده که این مقدار نسبت به مدل ساده SVM با دقت مدل‌سازی ۵۷٪ به میزان قابل توجهی افزایش یافته است. سری زمانی مربوط به داده‌های مشاهداتی^۱ و محاسباتی^۲ (شبیه‌سازی شده) در مدل‌سازی به

جدول ۳- نتایج حاصل از مدل‌سازی فرآیند بارش-رواناب دشت سیلاخور توسط مدل ترکیبی PSO-SVM

PSO-SVM			
واسنجی		صحت‌سنجی	
DC	RMSE $m^3 s^{-1}$	DC	RMSE $m^3 s^{-1}$
۰/۷۵	۲/۶۹	۰/۷۲	۳/۵۵

¹ Actual Runoff

² Simulated Runoff




شکل ۸- مقایسه سری زمانی رواناب شبیه سازی شده و مشاهداتی در مرحله صحت سنجی در مدل PSO-SVM

موجک به عنوان مناسب ترین توابع برای تجزیه سری- های زمانی هیدرولوژیکی معرفی شده است (کماسی و شرقی ۲۰۱۴، کماسی و شرقی ۲۰۱۶). نتایج حاصل از این مدل سازی برای انتخاب بهترین تابع موجک و درجه ی تجزیه در جدول ۴ آورده شده است. شکل ۹ به عنوان نمونه تجزیه ی سری زمانی بارش ناحیه ی مطالعاتی را به چهار زیرسری زمانی با تابع تبدیل موجک Haar نشان می دهد. از آنجایی که پارامترهای مدل، قبل از اعمال تبدیل موجک، بهینه یابی شده اند بنابراین تعداد آنها بعد از اعمال تبدیل موجک ثابت است. سری زمانی فرآیند بارش- رواناب نیز پس از پیش پردازش به چندین زیر سری زمانی تجزیه شده و انجام عملیات شبیه سازی بر روی هر یک از آنها صورت می گیرد سپس این زیر سری های زمانی شبیه سازی شده مجدداً ترکیب شده و به یک سری زمانی شبیه سازی شده واحد تبدیل می شود.

نتایج حاصل از مدل ترکیبی PSO-WT-SVM

در این مرحله به منظور سنجش اثر تبدیل موجک (WT) بر فرآیند مدل سازی، داده های پیش پردازش شده به عنوان ورودی های مدل SVM مورد استفاده قرار می گیرند. برای این منظور از WT به صورت مجزا استفاده می گردد. در این راستا پیش از پیش پردازش سری زمانی ورودی، پس از آنکه پارامترهای C و KP توسط الگوریتم PSO بهینه یابی شدند، سری های زمانی فرآیند بارش- رواناب دشت سیلاخور با درجه تجزیه ۱ تا ۷ توسط دو نوع تابع موجک مورد پیش پردازش قرار گرفته و تجزیه می شود. فرآیند پیش پردازش سری زمانی منتج به تبدیل سری زمانی ورودی با فرکانس- های پیچیده و متفاوت به چندین زیر سری زمانی با فرکانس های مجزا و قابل تحلیل می شود. تابع موجک Haar و Db2 (مالات ۱۹۹۸) توابع موجکی هستند که در این پژوهش از آنها استفاده شده است. این دو تابع



شکل ۹- نمونه تبدیل موجک سری زمانی بارش با تابع تجزیه موجک Haar.

جدول ۴- نتایج حاصل از مدل ترکیبی PSO-WT-SVM با توابع موجک و درجه‌های تجزیه متفاوت.

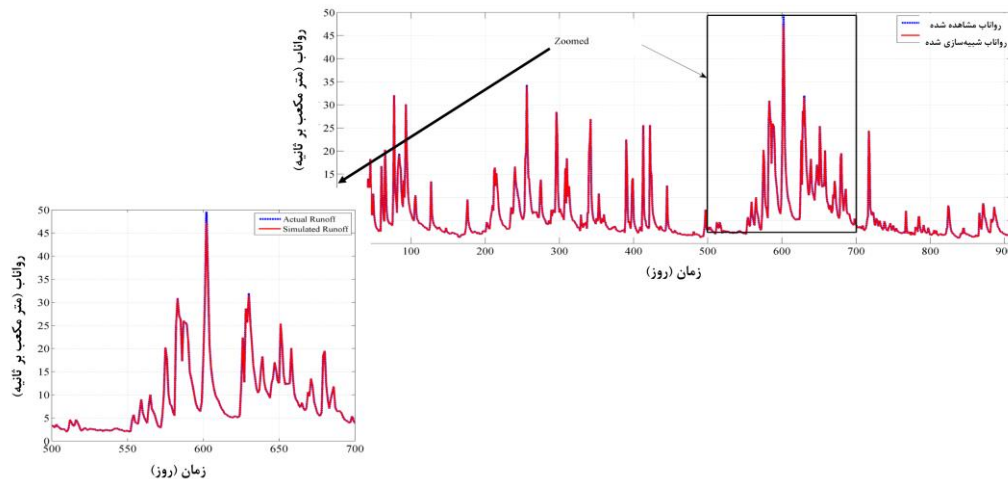
واسنجی			صحت‌سنجی		
تابع موجک	درجه تجزیه	DC	RMSE m ³ s ⁻¹	DC	RMSE m ³ s ⁻¹
Haar	۱	۰/۷۴	۲/۸۷	۰/۷۲	۳/۲۵
Haar	۲	۰/۷۹	۲/۵۰	۰/۷۹	۲/۷۲
Haar	۳	۰/۸۲	۲/۳۳	۰/۸۲	۲/۵۰
Haar	۴	۰/۸۳	۲/۱۶	۰/۸۴	۲/۲۷
Haar	۵	۰/۸۴	۲/۰۷	۰/۸۵	۲/۱۶
Haar	۶	۰/۸۵	۱/۹۶	۰/۷۶	۲/۹۶
Haar	۷	۰/۸۶	۱/۹۳	۰/۶۶	۳/۶۰
Db2	۱	۰/۷۶	۲/۷۱	۰/۷۵	۳/۰۳
Db2	۲	۰/۸۲	۲/۲۳	۰/۸۰	۲/۶۳
Db2	۳	۰/۸۴	۲/۰۶	۰/۸۴	۲/۱۹
Db2	۴	۰/۸۶	۱/۹۱	۰/۸۴	۱/۹۶
Db2	۵	۰/۹۰	۱/۵۰	۰/۸۹	۱/۷۵
Db2	۶	۰/۸۵	۱/۷۹	۰/۸۳	۲/۳۲
Db2	۷	۰/۸۵	۱/۷۸	۰/۸۲	۲/۵۰

درجه تجزیه موجک ۵ و تابع موجک Db2 ۸۹٪ می‌باشد. به بیان کامل‌تر وقتی تابع موجک داده‌های بارش و رواناب را به داده‌های با مقیاس زمانی مختلف تفکیک می‌کند، عمل طبقه‌بندی و رگرسیون داده‌ها بوسیله‌ی الگوریتم SVM با خطای کمتری صورت می‌پذیرد. سری زمانی مربوط به داده‌های مشاهداتی و محاسباتی در

با مقایسه‌ی نتایج جدول ۵ با نتایج مدل SVM می‌توان چنین نتیجه‌گیری کرد که مدل ترکیبی PSO-WT-SVM به دلیل عمل پیش‌پردازش بر روی داده‌های ورودی، نتایج دقیق‌تری را نسبت به مدل SVM ارائه کرده است بطوریکه دقت مدل‌سازی فرآیند بارش- رواناب دشت سیلاخور در مرحله صحت‌سنجی برای

جدول ۵ کاربرد الگوریتم تکاملی PSO و روش پیش-پردازش داده‌ها WT در ترکیب با مدل SVM و طرح مدل تکمیلی PSO-WT-SVM می‌تواند جایگزینی مناسب برای مدل ساده‌ی SVM در پیش‌بینی سری زمانی فرآیند بارش-رواناب باشد.

مدل‌سازی به روش ترکیبی PSO-WT-SVM برای بهترین تابع موجک (Db2) و درجه‌ی تجزیه ۵ در مرحله صحت‌سنجی در شکل ۱۰ نشان داده شده است. همانطور که از شکل ۱۰ بر می‌آید، مدل ترکیبی PSO-WT-SVM قابلیت بالایی در پیش‌بینی نقاط بیشینه سری زمانی فرآیند بارش-رواناب دارد. در نتیجه با توجه به



شکل ۱۰- مقایسه سری زمانی رواناب شبیه‌سازی شده و مشاهداتی در مرحله صحت‌سنجی در مدل PSO-WT-SVM. جدول ۵- مقایسه نتایج حاصل از مدل‌سازی فرآیند بارش-رواناب دشت سیلاخور.

واسنجی		صحت‌سنجی		مدل
DC	RMSE ($m^3 s^{-1}$)	DC	RMSE ($m^3 s^{-1}$)	
۰/۵۸	۳/۰۵	۰/۵۷	۴/۲۰	SVM
۰/۷۵	۲/۶۹	۰/۷۲	۳/۵۵	PSO-SVM
۰/۹۰	۱/۵۰	۰/۸۹	۱/۷۵	PSO-WT-SVM

سری‌های زمانی با مقیاس‌های فرکانسی مختلف تشکیل شده است که موجب پیچیدگی رفتار نوسانی آن‌ها می‌شود. با این حال وجود روش‌ها و ترفندهای پیش-پردازش سری‌های زمانی هیدرولوژیکی برای تبیین هرچه عمیق‌تر نوسانات و رفتارهای نهفته در سری‌های زمانی می‌تواند بر دقت شبیه‌سازی مدل‌های پیش‌بینی خصوصاً تخمین وقایع حدی بیافزاید. در این راستا در پژوهش مطروحه از روش پیش‌پردازش تبدیل موجک استفاده شده است تا با پیشنهاد مدل PSO-WT-SVM بتوان به این مهم دست یافت و با پیش‌پردازش سری

بطور کلی برآورد و تخمین دقیق وقایع حدی در مدل‌سازی سری‌های زمانی هیدرولوژیکی همواره از چالشی‌ترین مباحث در مدل‌های شبیه‌سازی می‌باشد. در پژوهش مطروحه اگرچه مدل‌های SVM و PSO-SVM روند و نوسانات غیر حدی سری زمانی فرآیند بارش-رواناب را به خوبی شبیه‌سازی نموده است اما در برآورد نقاط بیشینه از کارایی کافی برخوردار نیستند. دلیل این مهم، پیچیدگی رفتار سری‌های زمانی هیدرولوژیکی خصوصاً در هنگامه‌های وقایع حدی می‌باشد چراکه یک سری زمانی هیدرولوژیکی از مجموعه

شبیه‌سازی نقاط بیشینه شده بود. از سوی دیگر فنگ و همکاران (۲۰۲۰) از مدل پیش‌پردازش تجزیه‌ی متغیر برای بهبود دقت شبیه‌سازی فرآیند بارش-رواناب در مدل ترکیبی PSO-SVM بهره بردند. روش تجزیه‌ی متغیر بر اساس پهنای باند و فرکانس‌های مرکزی سری زمانی به تجزیه‌ی آن به تعدادی زیر سری می‌پردازد. بهبود دقت شبیه‌سازی فرآیند بارش-رواناب در پژوهش مذکور به سبب پیش‌پردازش داده‌های ورودی و استفاده از مدل ترکیبی کاملاً مشهود است. اما از آنجایی‌که روش پیش‌پردازش تبدیل موجک برای تجزیه‌ی سری‌های زمانی توابع موجک مختلفی را به کاربر ارائه می‌دهد (مانند هار^۲، مورلت^۳، کوفلت^۴ و ...) که ممکن است تحت شرایط مختلف هر کدام از این توابع کارایی بهتری داشته باشند، بنابراین می‌توان گفت فارغ از کارایی قابل توجه این روش در افزایش دقت شبیه‌سازی فرآیند بارش-رواناب، استفاده از روش تبدیل موجک می‌تواند گزینه‌ی مطلوب‌تری برای پیش‌پردازش داده‌ها باشد.

نتیجه‌گیری کلی

معرفی و ارائه روش‌های نوین داده‌کاوی و فراکاوشی جهت مدل‌سازی فرآیندهای هیدرولوژیکی بخصوص فرآیند بارش-رواناب همواره موضوعی مهم و ضروری در بین پژوهشگران حوزه علوم و مهندسی آب بوده است. اخیراً مدل‌هایی که برپایه‌ی هوش مصنوعی می‌باشند به محبوبیت بیشتری دست پیدا کرده‌اند. مدل SVM یکی از روش‌های نوین و کارآمد هوش مصنوعی محسوب می‌شود که با رویکرد رگرسیون داده‌ها به پیش‌بینی و مدل‌سازی سری‌های

زمانی ورودی به مدل ترکیبی PSO-SVM عملکرد این مدل را خصوصاً در تخمین نقاط بیشینه ارتقاء داد. همانطور که از نتایج برمی‌آید مدل نهایی PSO-WT-SVM قادر است به شبیه‌سازی دقیق‌تر سری زمانی بارش-رواناب و تخمین مطلوب نقاط بیشینه منتج شود. دلیل این مهم این است که با اعمال عملیات پیش‌پردازش بر روی سری زمانی بارش-رواناب توسط تبدیل موجک، سری زمانی ورودی با ترکیبی از فرکانس‌های نوسانی پیچیده و غیرقابل فهم، به چندین زیرسری زمانی با فرکانس‌های زمانی مجزا و نسبتاً ساده تجزیه شده و عملیات شبیه‌سازی بطور جداگانه با استفاده از مدل PSO-WT-SVM بر روی سری‌های زمانی تجزیه شده صورت می‌پذیرد و در نهایت با انجام عکس عملیات تجزیه‌ی سری زمانی، سری زمانی بارش-رواناب نهایی شبیه‌سازی شده حاصل می‌آید که دقت بالای آن خصوصاً در تخمین نقاط بیشینه قابل ملاحظه است.

نتایج بدست آمده از این پژوهش با پژوهش‌های اخیر در رابطه با بهبود کارایی مدل‌های شبیه‌سازی قابل مقایسه است. به عنوان نمونه تیخاماراین و همکاران (۲۰۲۰) با ترکیب مدل‌های بهینه‌سازی PSO با مدل LSSVM^۱ به افزایش کارایی و دقت شبیه‌سازی فرآیند بارش-رواناب اهتمام ورزیدند. با وجود اینکه کارایی مدل ترکیبی پیشنهاد داده شده در پژوهش مذکور بطور قابل توجهی نسبت به مدل‌های غیر ترکیبی افزایش پیدا کرده بود اما نبود روشی برای پیش‌پردازش سری‌های زمانی هیدرولوژیکی ورودی به مدل موجب کمبود کارایی کافی مدل پیشنهادی خصوصاً در

² Haar

³ Morlet

⁴ Coiflet

¹ Least Squares Support Vector Machine

پردازش و تفکیک شده، هدف دیگر این پژوهش بود. نتایج بدست آمده از مدل سازی مدل های ترکیبی PSO-SVM و PSO-WT-SVM گویای برتری و کارایی مطلوب این مدل ها در مقایسه با مدل ساده SVM می باشد بطوریکه دقت مدل سازی برای مدل ترکیبی PSO-SVM و PSO-WT-SVM در مرحله صحت سنجی به ترتیب ۰/۷۲ و ۰/۸۹ بوده که ۱۵٪ و ۳۲٪ به ترتیب از دقت مدل سازی مدل ساده SVM بالاتر می باشد. همچنین مدل ترکیبی PSO-WT-SVM توانایی بسیار مطلوبی را در پیش بینی نقاط بیشینه ی سری زمانی رواناب نشان می دهد. استفاده از سایر الگوریتم های تکاملی مانند الگوریتم کلونی مورچه گان یا الگوریتم رقابت استعماری جهت بهینه سازی پارامترهای ثابت مدل SVM می تواند پیشنهاد مناسبی برای پژوهش های آتی باشد. همچنین بررسی عدم قطعیت های موجود در پارامترهای مدل های مورد نظر و همچنین عدم قطعیت سری زمانی بارش و رواناب در ناحیه ی با تحلیل داده های تاریخی فرآیند بارش رواناب طولانی مدت در ناحیه ی مطالعاتی می تواند به ارتقاء کاربردی بودن نتایج بدست آمده منجر شود.

زمانی می پردازد. در پژوهش حاضر هدف، مدل سازی و پیش بینی سری زمانی فرآیند بارش رواناب دشت سیلاخور با استفاده از مدل SVM و رفع اشکالات این مدل با طرح دو مدل تکمیلی ترکیبی می باشد. در ساختار الگوریتم مدل SVM دو پارامتر ثابت C و KP موجود است که می بایست ابتدا توسط کاربر مقداردهی گردد. اختصاص مقادیر نامناسب به این دو پارامتر می تواند موجب کاهش کارایی و کاهش دقت مدل سازی گردد. از این رو، در این پژوهش با پیشنهاد الگوریتم تکاملی - بهینه سازی PSO و معرفی مدل ترکیبی PSO-SVM، مقادیر دو پارامتر C و KP توسط الگوریتم PSO بهینه سازی شده و به مدل SVM معرفی می گردد تا این مدل فرآیند مدل سازی را با مقادیر بهینه و مناسب این دو پارامتر ثابت انجام دهد. معیار بهینه سازی الگوریتم PSO، تابع هدف RMSE می باشد که در طول اجرای مدل PSO با انتخاب مقادیر بهینه دو پارامتر مورد نظر، به کمترین مقدار خود دست پیدا می کند. از سویی با توجه به پیچیدگی سری های زمانی هیدرولوژیکی، استفاده از مدل ترکیبی PSO-WT-SVM جهت مدل سازی و پیش بینی سری زمانی فرآیند بارش رواناب پیش-

منابع مورد استفاده

- Asefa T, Kemblowski M, McKee M and Khalil A, 2006. Multi-time scale stream flow predictions: the support vector machines approach. *Journal of Hydrology* 318(1):7-16.
- Behzad M, Asghari K, Eazi M and Palhang M, 2009. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications* 36(4):7624-7629.
- Bouallègue S, Haggège J and Benrejeb M, 2012. A new method for tuning PID-type fuzzy controllers using particle swarm optimization. Pp.140-159, In: *Fuzzy Controllers-Recent Advances in Theory and Applications*.
- Choy KY and Chan CW, 2003. Modeling of river discharges and rainfall using radial basis function networks based on support vector regression. *International Journal of Systems Science* 34(14-15):763-773.
- Dibike YB, Velickov S, Solomatine D and Abbott MB, 2001. Model induction with support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering* 15 (3):208-216.
- Feng ZK, Niu WJ, Tang ZY, Jiang ZQ, Xu Y, Liu Y and Zhang HR, 2020. Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization. *Journal of Hydrology* 583: 124627.
- Han D, Chan L and Zhu N, 2007. Flood forecasting using support vector machines. *Journal of Hydroinformatics* 9(4):267-276.

- Hsu KL, Gupta HV and Sorooshian S, 1995. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research* 31(10):2517-2530.
- Kennedy J and Eberhart RC, 1995. Particle swarm optimization. Pp.1942-1948, Proceedings of IEEE International Conference on Neural Networks IV, Piscataway, NJ: IEEE Press.
- Komasi M and Sharghi S, 2014. Flood forecasting with artificial neural network wavelet multi-scale hybrid model. The Second National Conference on Management and Engineering Flood. 30 September-1 October, Tehran, Iran. (In Persian with English abstract).
- Komasi M and Sharghi S, 2016. Hybrid wavelet-support vector machine approach for modeling rainfall-runoff process. *Water Science and Technology* 73(8):1937-1953.
- Komasi M, Sharghi S and Safavi HR, 2018. Wavelet and cuckoo search-support vector machine conjugation for drought forecasting using standardized precipitation index (Case study: Urmia Lake, Iran). *Journal of Hydroinformatics* 20(4): 975-988.
- Lin GF, Chen GR, Huang PY and Chou YC, 2009. Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods. *Journal of Hydrology* 372(1):17-29.
- Mallat SG, 1998. *A Wavelet Tour of Signal Processing*. Second ed. Academic Press. San Diego.
- Minns AW and Hall MJ, 1996. Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal* 41(3):399-417.
- Savic DA, Walters GA and Davidson JW, 1999. A genetic programming approach to rainfall-runoff modelling. *Water Resources Management* 13(3):219-231.
- Shamseldin AY, 1997. Application of a neural network technique to rainfall-runoff modelling. *Journal of Hydrology* 199(3-4):272-294.
- Smith J and Eli RN, 1995. Neural-network models of rainfall-runoff process. *Journal of Water Resources Planning and Management* 121(6):499-508.
- Tikhmarine Y, Souag-Gamane D, Ahmed AN, Sammen SS, Kisi O, Huang YF and El-Shafie A, 2020. Rainfall-runoff modelling using improved machine learning methods: Harris hawks optimizer vs. particle swarm optimization. *Journal of Hydrology* 589: 125133.
- Van den Bergh F and Engelbrecht AP, 2006. A study of particle swarm optimization particle trajectories. *Information Sciences* 176(8):937-971.
- Vapnik V and Cortes C, 1995. Support vector networks. *Machine Learning* 20(3):273-297.
- Vapnik VN, 1995. *The Nature of Statistical Learning Theory*. Springer, New York.
- Wang W, Men C and Lu W, 2008. Online prediction model based on support vector machine. *Neurocomputing* 71(4):550-558.