

Simulation of monthly river flow using improved support vector machine regression model using gray wolf optimization algorithm

Article Info

Article type:
Research Article

Article history:

Keywords:

Monthly river flow, support vector regression, gray wolf optimization algorithm, water resources management


ABSTRACT

Measuring the flow of rivers is one of the most important issues in river management, that's why it is always tried to use accurate methods for its measurement. The aim of this study is to enhance the performance of Support Vector Regression (SVR) model using the Gray Wolf Optimization (GWO) algorithm for monthly river flow modeling. For this purpose, the monthly data of river flow, precipitation and temperature during 15 years (from 1400 to 2015) are used. The trial and error procedure is used to select the best input variables to the SVR and GWO-SVR models. Based on the results of this method, $Q(t-1)$, $R(t-1)$, $T(t-1)$ are the best independent variables for simulating the variable Q_t . 80% of all data are used for training and 20% for validating the SVR and GWO-SVR models. Also, R^2 , RMS and NSE indices are utilized to evaluate the efficiency of the models, linear (LKF), polynomial (PKF), radial basis function (RBF), and sigmoid (SKF) activation functions are used to develop the models. First, the trial and error procedure is used to determine the parameters of the activation functions. Based on the results of this study, the SVR model with the polynomial activation function has the best performance in the training and validation stage, and the worst performance with the linear activation function in the training and verification stages. Then, the GWO algorithm is used to determine the parameters of the activation functions. Based on the results, the SVR model performs better with the GWO algorithm. Therefore, to simulate the monthly flow of river using this model, it is better to use the GWO algorithm instead of the trial and error procedure.

Cite this article: Author, A. A., Author, B. B., & Author, C. C. (year). Article title. *Journal Title*,

© The Author(s).

Publisher: University of Tehran Press.

 <http://doi.org/0000000000000000000000>

مجله علمی و پژوهشی

شبیه سازی جریان ماهانه رودخانه با استفاده از مدل رگرسیون ماشین بردار پشتیبان بهبود یافته با استفاده از الگوریتم بهینه سازی گرگ خاکستری

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	اندازه گیری جریان رودخانه ها یکی از مهم ترین مسائل در مدیریت رودخانه است به همین دلیل همواره تلاش می شود از روش های دقیقی برای اندازه گیری آن استفاده شود. هدف این مطالعه بهبود کارایی مدل رگرسیون بردار پشتیبان (SVR) با استفاده از الگوریتم بهینه سازی گرگ خاکستری (GWO) برای مدل سازی جریان ماهانه رودخانه است. برای این کار از داده های ماهانه جریان ماهانه رودخانه، بارندگی و دما طی ۱۵ سال (از سال ۱۴۰۰ تا ۱۳۸۵) استفاده شد. برای انتخاب بهترین متغیرهای ورودی به مدل SVR و GWO-SVR از روش سعی و خطا استفاده شد. بر اساس نتایج حاصل از این روش $Q(t-1)$ $R(t-1)$ $T(t-1)$ بهترین متغیرهای مستقل برای شبیه سازی متغیر Q_t هستند. از ۸۰ درصد همه داده ها برای آموزش و ۲۰ درصد داده ها برای صحت سنجی مدل های SVR و GWO-SVR استفاده شد، از شاخص های R^2 ، RMS و NSE برای ارزیابی کارایی مدل ها استفاده شد. برای توسعه مدل ها از توابع فعال ساز خطی (LKF)، چند جمله ای (PKF)، تابع پایه شعاعی (RBF)، سیگموئید (SKF) استفاده شد. ابتدا از روش سعی و خطا برای تعیین پارامترهای توابع فعال ساز استفاده شد. بر اساس نتایج حاصل از این مطالعه مدل SVR با تابع فعال ساز چند جمله ای بهترین عملکرد را در مرحله آموزش و صحت سنجی دارد و با تابع فعال ساز خطی بدترین عملکرد را در مرحله آموزش و صحت سنجی دارد. سپس از الگوریتم GWO برای تعیین پارامترهای توابع فعال ساز استفاده شد. بر اساس نتایج حاصل مدل SVR با الگوریتم GWO عملکرد بهتری دارد. بنابراین برای شبیه سازی جریان ماهانه اب رودخانه با استفاده از این مدل بهتر است به جای روش سعی و خطا از الگوریتم GWO استفاده شود.

استناد: نام خانوادگی، نام؛ نام خانوادگی، نام؛ و نام خانوادگی، نام (سال). عنوان مقاله. عنوان مجله،

DOI:



© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

مجله علمی و فناوری

مقدمه

مدیریت منابع آب فرایندی بسیار پیچیده است زیرا از بخش‌های مختلفی تشکیل شده است و مدیریت هر یکی از این بخش‌ها مستلزم توجه به محدودیت‌های مختلفی است (Brierley & Fryirs, 2013). رودخانه یکی از مهم‌ترین بخش‌های یک سیستم منابع آبی هستند که توجه به پارامترهای کمی و کیفی آن‌ها نه تنها امری مهم است بلکه امری بسیار حیاتی است، دبی به معنای حجم آب عبوری از یک حجم مشخص و در زمان معین است، این پارامتر یکی از مهم‌ترین شاخص‌های موثر در مدیریت رودخانه است زیرا تغییرات آن در طول زمانی می‌تواند تاثیر مهمی بر اکوسیستم‌های طبیعی داشته باشد (Mazraeh et al., 2023). مثلا کاهش بیش از اندازه جریان رودخانه می‌تواند باعث نابودی بسیاری از ماهی‌ها شود، بر عکس افزایش بیش از اندازه جریان رودخانه می‌تواند باعث بروز سیلاب‌های محری شود. بنابراین همواره تلاش مشود از روش‌های دقیقی برای شبیه‌سازی جریان ماهانه رودخانه و پیشبینی آن در کوتاه مدت و بلندمدت استفاده شود (Goorani & Shabanlou, 2021). در گذشته عمدتا از مدل‌های فیزیکی برای این کار استفاده میشد، تهیه این مدل‌ها فرایند بسیار چالش برانگیز است و توسعه آن‌ها مستلزم صرف زمان بسیاری بود. با گذشته زمان و معرفی مدل‌های عددی امکان شبیه‌سازی دقیق تر جریان ماهانه رودخانه فراهم شد، این روش‌ها نسبت به مدل‌های فیزیکی دقیق تر بودند اما توسعه آن‌ها به داده‌های زیادی نیاز دارد (Mazraeh et al., 2024). سومین دسته از روش‌های استفاده شده برای شبیه‌سازی جریان ماهانه رودخانه روش‌های مبتنی بر هوش مصنوعی هستند، توسعه این روش‌ها نسبت به مدل‌های فیزیکی به زمان و هزینه کم تری نیاز دارند و نسبت به مدل‌های عددی به داده‌های کم تری نیاز دارند، شبکه‌های عصبی نوعی روش هوش مصنوعی الهام گرفته از سیستم عصبی انسان هستند که با استفاده از آن‌ها میتوان انواع سیستم‌های خطی و غیرخطی را مدل سازی کرد (Mazraeh et al., 2023). با توجه به این موارد استفاده از این مدل‌ها به ویژه در سال‌های اخیر برای شبیه‌سازی جریان ماهانه رودخانه بسیار افزایش پیدا کرده است، به عنوان مثال

(Mojaddadi et al., 2017) از روش نسبت فرکانس (FAR) و ماشین بردار پشتیبان (SVM) برای مدل‌سازی احتمال وقوع سیلاب استفاده کردند. آن‌ها برای توسعه مدل SVM ابتدا پارامترهای ورودی را با استفاده از روش FR وزن‌دهی کردند سپس این پارامترها را به ترتیب به عنوان ورودی به مدل SVM اضافه کردند. سپس بر اساس نتایج حاصل از مدل SVM نقشه ریسک سیلاب تهیه کردند. بر اساس نتایج حاصل، می‌توان از این روش به عنوان ابزاری مناسب برای شبیه‌سازی جریان رودخانه و تهیه نقشه احتمال وقوع سیلاب استفاده کرد.

Zhang et al., 2018 برای شبیه‌سازی جریان روزانه رودخانه از مدل‌های شبکه عصبی مصنوعی (ANN)، برنامه‌ریزی ژنتیک (GP)، سیستم استنتاج عصبی-فازی سازگار (ANFIS)، رگرسیون خطی چندگانه (MLR)، ماشین بردار پشتیبان (LSSVM) استفاده کردند. آن‌ها برای بهبود کارایی این مدل‌ها، به جای روش سعی و خطا از الگوریتم‌های بهینه‌سازی ژنتیک (GA) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای تخمین پارامترهای این مدل‌ها استفاده کردند. علاوه بر این از روش تبدیل موجک (WD) برای تبدیل داده‌های ورودی استفاده کردند. بر اساس نتایج حاصل از این مطالعه الگوریتم‌های PSO و GA به تنهایی تاثیر چندانی در بهبود دقت مدل SVM ندارند اما استفاده از WD تاثیر قابل توجهی در بهبود دقت این مدل دارد.

-
- 1Frequency Ratio
 - 2Support Vector Machine
 - 3Artificial Neural Network
 - 4Genetic Programming
 - 5Adaptive Network-Based Fuzzy Inference System
 - 6Multiple Linear Regression
 - 7Squares Support Vector Machine
 - 8Genetic Algorithm
 - 9Particle Swarm Optimization
 - 10Wavelet decomposition

Fathian et al., (2019) از یک مدل هیبریدی برای شبیه‌سازی جریان ماهانه رودخانه استفاده کردند. آن‌ها برای این کار ابتدا از مدل $MARS \setminus RF \setminus ANN$ ، سپس از نتایج حاصل از این مدل‌ها برای توسعه یک مدل هیبریدی استفاده کردند. بر اساس نتایج حاصل از مدل SETAR نسبت به مدل GARCH عملکرد بهتری دارد و مدل RF and MARS نسبت به مدل ANN عملکرد بهتری دارند و مدل هیبریدی RF-SETAR نسبت به همه مدل‌ها عملکرد بهتری دارد.

Cui et al., (2020) عملکرد مدل‌های $ENN \setminus RVM \setminus MARS$ را برای شبیه‌سازی جریان ساعتی رودخانه ارزیابی کردند. آن‌ها برای این کار از اطلاعات ماهانه جریان رودخانه برای یک دوره چهار ساله استفاده کردند. بر اساس نتایج حاصل از این مطالعه مدل ENN نسبت به همه مدل‌ها عملکرد بهتری دارد و مدل MARS نسبت به همه مدل‌ها عملکرد ضعیف‌تری دارد.

فلاحی و همکاران (۱۳۹۹) برای شبیه‌سازی بلندمدت بارش در شهر رشت از ترکیب مدل GEP و WD و توسعه یک مدل جدید (WDGEP) استفاده کردند. سپس نتایج مدل‌های GEP و WDGWP را با یکدیگر مقایسه کردند. آن‌ها برای انتخاب بهترین متغیرهای ورودی از روش سعی و خطا استفاده نمودند. بر این اساس $t-1$, $t-2$, $t-3$, $t-12$ مؤثرترین تأخیرها در پیش‌بینی بارش با استفاده از این مدل‌ها هستند. آن‌ها برای مقایسه نتایج حاصل از این مدل‌ها از شاخص عملکرد (VAF) ضریب همبستگی (R) و شاخص پراکندگی (SI) استفاده نمودند. بر اساس نتایج حاصل از این مطالعه برای شبیه‌سازی بلندمدت بارش مدل WDGEP نسبت به مدل GEP عملکرد بهتری دارد. از دیگر تحقیقات جدید در خصوص کاربرد استفاده از الگوریتم بهینه‌سازی گرگ خاکستری بردار پشتیبان در علوم آب می‌توان به ترابی و همکاران (۲۰۲۴) و جلیلی و همکاران (۲۰۲۳) اشاره کرد.

روش تحقیق

ماشین بردار پشتیبان

مدل ماشین بردار پشتیبان برای رگرسیون (Support Vector Regression) یا SVR یک تکنیک یادگیری ماشین نظارت‌شده است که برای حل مسائل رگرسیون استفاده می‌شود. در مدل SVR، مشابه با ماشین‌های بردار پشتیبان (SVM) در مسائل طبقه‌بندی، هدف یافتن یک تابع خطی یا غیرخطی است که بتواند داده‌ها را با خطای کم و دقت بالا مدل‌سازی کند. برخلاف روش‌های مرسوم رگرسیون که به حداقل‌سازی خطای کلی تمرکز دارند، SVR تلاش می‌کند تا تابعی بیابد که حداکثر داده‌ها را در یک نوار خطی ϵ در اطراف تابع نگه دارد و تنها خطاهایی که خارج از این نوار رخ می‌دهند را به حداقل برساند. این رویکرد باعث می‌شود مدل نسبت به داده‌های پرت حساسیت کمتری داشته باشد و به دلیل استفاده از بردارهای پشتیبان (یعنی نقاط کلیدی داده‌ها که بر تابع نهایی تأثیر می‌گذارند)، به مدل بهینه‌تری دست یابد (Suthaharan & Suthaharan, 2016). یکی از ویژگی‌های منحصر به فرد SVR استفاده از کرنل‌ها برای مدل‌سازی روابط غیرخطی بین داده‌ها است. به کمک توابع کرنل مانند کرنل خطی، کرنل چندجمله‌ای و کرنل شعاعی پایه (RBF)، می‌توان داده‌های ورودی را به فضای ویژگی با ابعاد بالاتر نگاشت کرد، به طوری که در آن فضا رابطه خطی بین داده‌ها قابل مشاهده باشد. این ویژگی به مدل SVR اجازه می‌دهد که مسائل رگرسیونی غیرخطی و پیچیده را با دقت بالاتری حل کند. به عبارت دیگر، SVR قادر است روابط پیچیده بین ویژگی‌های ورودی و متغیرهای هدف را شناسایی کند و در عین حال با استفاده از بردارهای پشتیبان، از استفاده بی‌رویه از داده‌های پرت جلوگیری کند (Awad et al., 2015). SVR علاوه بر دقت بالا، به دلیل کنترل پارامترهایی مانند پارامتر جریمه (C) و نوار خطی ϵ ، امکان کنترل پیچیدگی مدل و انعطاف‌پذیری در تنظیم دقت و حساسیت به خطاها را فراهم می‌کند. پارامتر C تعیین‌کننده تعادل بین به حداقل رساندن خطا و یافتن تابع ساده‌تر است، در حالی که پارامتر ϵ اندازه نوار خطا

را کنترل می‌کند. این تنظیمات SVR را برای کاربردهایی مانند پیش‌بینی سری‌های زمانی، مدل‌سازی مالی، پیش‌بینی‌های آب‌وهوا و سایر مسائل رگرسیونی که نیاز به دقت بالا و مقاومت در برابر نوسانات داده‌ها دارند، مناسب می‌سازد. به‌طور کلی، SVR به دلیل دقت بالا، انعطاف‌پذیری و کارایی در مواجهه با داده‌های پیچیده و غیرخطی به‌عنوان یکی از مدل‌های قدرتمند رگرسیونی مورد استفاده قرار می‌گیرد معادله استفاده شده توسط مدل SVR را می‌توان به صورت زیر نوشت (Smola & Schölkopf, 2004).

$$f(x) = w \cdot \phi(x) + b \quad (1)$$

که در آن x بردار متغیرهای ورودی است، w بردار وزن‌ها است، b بردار بایاس است، ϕ نوعی تابع غیرخطی برای map کردن متغیرهای ورودی به فضای جدید با ابعاد بالاتر است. با در نظر گرفتن فرضیات مختلف می‌توان نوعی مسئله بهینه‌سازی محدب را برای حل این معادله و محاسبه مقادیر بهینه وزن‌ها معرفی کرد.

$$\min_{w, b, \xi_i, \xi_i^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (2)$$

$$S. t. \begin{cases} w \cdot \phi(x_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - w \cdot \phi(x_i) - b \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0; i = 1, 2, 3 \dots m \end{cases}$$

که در آن ξ_i, ξ_i^* متغیرهای کمبود هستند، C یک عدد مثبت با مقدار مشخص برای جلوگیری بیش‌برازش شدند مدل است، این مسئله بهینه‌سازی را می‌توان با استفاده تئوری دوگانگی^۷ حل کرد، بر این اساس Eq. (2) را می‌توان به صورت زیر نوشت.

$$f(x, \beta_i, \beta_i^*) = \sum_{i=1}^n (\beta_i - \beta_i^*) k(x_i, x_j) + b \quad (3)$$

که در آن $k(x_i, x_j)$ تابع فعال ساز است که برابر است با $\phi(x_i)\phi(x_j)$. توابع فعال‌ساز از مهمترین بخش‌های مدل SVR است، به همین دلیل همواره تلاش می‌شود از توابع مناسبی برای این کار استفاده شود، در این مطالعه از تابع خطی^۸ $k(x_i, x_j) = (x_i, x_j)$ و تابع شعاعی پایه^۹ $K(x_i, x_j) = \exp(-\gamma \|x - y\|^2 + C)$ و تابع سیگموئید^{۱۰} $k(x_i, x_j) = \tanh(\alpha x^T y + C)$ و تابع سیگموئید^{۱۱} $k(x_i, x_j) = (\gamma(x_i, x_j) + r)$ استفاده شد. هر یکی از این توابع پارامترهایی دارند که تعیین مقدار دقیق آن‌ها تاثیر چشمگیری در دقت مدل SVM دارد، به همین دلیل همیشه سعی می‌شود از روش‌های دقیقی برای تعیین مقدار این پارامترها استفاده کرد، الگوریتم‌های بهینه‌سازی فرا ابتکاری یکی از بهترین روش‌ها برای تعیین مقدار دقیق این پارامترها هستند، به همین دلیل در این مطالعه کارایی الگوریتم^{۱۲} GWO برای تعیین مقدار بهینه پارامترهای γ, C, r, d ، پارامترهای فعال ساز RBF، پارامتر C تابع فعال ساز SKF، پارامترهای فعال ساز PKF بررسی شد.

الگوریتم بهینه‌سازی گرگ خاکستری

^۱Duality Theory
^۲Linear Kernel Function (LKF)
^۳Radial Basis Function (RBF)
^۴Sigmoid Kernel Function (SKF)
^۵Polynomial function (PKF)
^۶Grey Wolf Optimization (GWO) algorithm

GWO یکی از بهترین الگوریتم‌های فرا ابتکاری مبتنی بر رفتار گروهی جمعیت است، این الگوریتم اولین بار در سال 2014 توسط (Mirjalili et al., 2014) و با الهام از رفتار گروهی گون‌های از گرگ‌ها به نام گرگ‌های خاکستری هنگام شکار طعمه توسعه داده شد. از این الگوریتم می‌توان برای حل انواع مسایل بهینه‌سازی خطی و غیرخطی دارای یک یا چند تابع هدف استفاده کرد (Faris et al., 2018). برای آشنایی با این الگوریتم و فرایند حل مسئله با استفاده از آن ابتدا باید با رفتار این نوع گرگ‌ها هنگام شکار آشنا شد. گرگ‌های خاکستری موجوداتی اجتماعی هستند که معمولاً به صورت گروهی شکار میکنند (Teng et al., 2019). این گرگ‌ها را میتوان به چهار دسته $\alpha, \beta, \delta, \omega$ تقسیم کرد. گرگ‌های گروه α رهبران گروه و موسوی تصمیم‌گیری درباره فرایند شکار هستند، گرگ‌های گروه β از نظر اهمیت و تاثیر پذیری بعد از گرگ‌های گروه α در جایگاه دوم قرار دارند، این گرگ‌ها به گرگ‌ها مطیع گرگ‌های گروه α هستند و در تصمیم‌گیری به آن‌ها کمک میکنند. از نظر اهمیت گرگ‌های گروه ω نسبت به همه گرگ‌ها در رتبه پایین‌تری قرار دارند، این گرگ‌های تابع دستورات گرگ‌های گروه‌های α, β, δ هستند. بر اساس رفتار این گرگ‌ها هنگام شکار میتوان مدلی را برای شبیه‌سازی مسایل بهینه‌سازی کرد (Mirjalili et al., 2014).

زمانی که گرگ‌ها دور طعمه حلقه می‌زنند موقعیت بعدی هر گرگ را می‌توان با استفاده از رابطه ۴ محاسبه کرد.

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (4)$$

که در آن، $\vec{X}^*(t)$ موقعیت کرکر بهینه در تکرار t است، $\vec{X}(t+1)$ موقعیت گرگ در تکرار جدید است. $\vec{A}, \vec{C}, \vec{D} = \pi r^2$ نیز با استفاده از رابطه ۵ تا ۷ محاسبه می‌شوند.

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (5)$$

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (6)$$

$$\vec{C} = 2\vec{a} \cdot \vec{r}_2 - \vec{a} \quad (7)$$

که در آن \vec{r}_1 و \vec{r}_2 اعداد تصادفی در بازه صفر و یک هستند. \vec{a} ضربی است که مقدار آن با افزایش تعداد تکرارها از ۲ به صفر کاهش پیدا می‌کند. با توجه به برتری گرگ‌های گروه‌های α, β, δ نسبت به سایر گرگ‌ها در هر تکرار موقعیت هر گرگ بر اساس موقعیت بهترین گرگ‌های این سه گروه به روز می‌شود (رابطه ۸ تا ۱۰).

$$\vec{X}_1 = \vec{X}_\alpha(t) - \vec{A}_1 \cdot \vec{D}_\alpha \quad (8)$$

$$\vec{X}_2 = \vec{X}_\beta(t) - \vec{A}_2 \cdot \vec{D}_\beta \quad (9)$$

$$\vec{X}_3 = \vec{X}_\omega(t) - \vec{A}_3 \cdot \vec{D}_\omega \quad (10)$$

در نهایت موقعیت نهایی هر گرگ بر اساس رابطه ۱۱ محاسبه می‌شود.

$$\vec{X}_{(t+1)} = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (11)$$

معیار ارزیابی مدل

بعد از توسعه مدل‌های GWO-SVR and GOA-SVR با استفاده از داده‌های آموزشی و آزمایشی از ضریب تعیین $(R^2)^3$ ، ضریب NSE^4 ، خطای جذر میانگین مربعات $(RMSE)^5$ برای ارزیابی مدل‌ها استفاده شد. هرچه مقدار شاخص‌های RMSE به

³Efficient of determination
⁴Nash-Sutcliffe efficiency
⁵Root-mean-square deviation

صفر نزدیکتر باشد و مقدار شاخص های R^2 و NSE به ترتیب به ۱۰۰ و یک نزدیکتر باشد به این معنی است که مدل کارایی بهتری دارد، اما هرچه مقدار $RMSE$ بیشتر باشد و مقدار R^2 به صفر نزدیک تر باشد و همچنین مقدار NSE به صفر نزدیک تر باشد به این معنی است که مدل کارایی مناسبی ندارد (رابطه ۱۲ تا ۱۴).

$$RMSE = \left[N^{-1} \sum_{i=1}^N (y_i - O_i)^2 \right]^{\frac{1}{2}} \quad (12)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (O_i - y_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (13)$$

$$R^2 = \left[\sum_{i=1}^N (F_i - \bar{y})(O_i - \bar{O}) \right]^2 \left[\sum_{i=1}^N (y_i - \bar{y})^2 (O_i - \bar{O})^2 \right]^{-1} \quad (14)$$

در این رابطه N تعداد مشاهده‌ها است، y_i مقدار پیش‌بینی شده است، O_i مقدار مشاهده‌ای است و \bar{y} و \bar{O} به ترتیب متوسط مقادیر O_i و y_i هستند.

منطقه مطالعاتی

محدوده حوضه گاماسیاب در غرب ایران و به‌عنوان بخشی از استان کرمانشاه بین طول‌های $47^{\circ}04'$ تا $49^{\circ}15'$ و عرض‌های $33^{\circ}45'$ تا $35^{\circ}00'$ قرار دارد (شکل ۱). مساحت این حوضه 11456 کیلومتر مربع است و شیب 48 درصد از زمین‌های آن کمتر از 10 درصد است و شیب 52 درصد از زمین‌های این منطقه بیش از 10 درصد است. مرتفع‌ترین نقطه این دشت نسبت به سطح دریا 3645 ارتفاع دارد و متوسط ارتفاع این حوضه از سطح دریا 1889 است. گاماسیاب یکی از مهم‌ترین رودخان‌های ایران و این حوضه آبریز است که از ارتفاعات کوه‌های زاگرس به‌عنوان یکی از بلندترین رشته‌های کوه‌های ایران سرچشمه می‌گیرد. بررسی اطلاعات 15 سال ایستگاه‌های هواشناسی واقع در این منطقه نشان می‌دهد که متوسط میزان باندگی در این منطقه 532 میلی‌متر است، همچنین حداقل میزان بارندگی 236 میلی‌متر و حداکثر مقدار آن 1022 میلی‌متر است. در این مطالعه از اطلاعات ثبت شده در ایستگاه هیدرومتری پل چهر به‌عنوان یکی از ایستگاه‌های موجود در رودخانه گاماسیاب استفاده شد. این ایستگاه در مختصات جغرافیایی $34^{\circ}20'28''$ تا $34^{\circ}10'40''$ عرض شمالی و $47^{\circ}25'37''$ تا $47^{\circ}20'48''$ طول شرقی قرار دارد. برای این مطالعه از اطلاعات جریان روزانه رودخانه برای یک دوره 21 ساله از سال 2000 تا 2021 استفاده شد. ابتدا از این داده‌ها بای محاسبه جریان ماهانه رودخانه استفاده شد سپس از این داده‌ها برای توسعه مدل‌های $GWO-SVR$, $GWO-SVR$ and GOA استفاده شد.

نتایج و بحث

تحلیل نتایج حاصل از مدل SVR





برای توسعه مدل $GWO-SVR$ ابتدا متغیرهای مستقل $(Q_{t-1}, Q_{t-2}, Q_{t-3}, R_t, R_{t-1}, R_{t-2}, T_t, T_{t-1}, T_{t-2})$ برای شبیه‌سازی متغیر وابسته (Q_t) مشخص شدند. برای آموزش مدل SVR و تعیین دقیق مقدار پارامتر C تابع فعال ساز LKF ، مقدار C و γ تابع فعال ساز RBF ، مقدار C تابع فعال ساز SKF ، مقدار C و d تابع فعال ساز PKF از دو روش مختلف سعی و خطا و روش استفاده از الگوریتم بهینه‌سازی GWO استفاده شد. برای توسعه این مدل از 80 درصد داده‌ها برای آموزش و از 20 درصد کل داده‌ها برای صحت‌سنجی مدل استفاده شد. همچنین بهترین متغیرهای ورودی به مدل با استفاده از روش سعی و خطا تعیین شدند. بعد از چندین بار اجرای مدل و ارزیابی شاخص‌های خطا مشخص شد که Q_{t-1}, R_t, T_t بهترین متغیرهای مستقل برای شبیه‌سازی جریان ماهانه رودخانه هستند. در

ادامه ابتدا از روش سعی و خطا برای آموزش مدل SVR استفاده شد. بر اساس نتایج، این مدل با تابع فعال ساز PKF بهترین عملکرد را در مرحله آموزش و صحت‌سنجی دارد ($R^2: 0/8939$ ، $NSE: 0/8641$ ، $RMSE: 0/2147$ Train و $R^2: 0/8949$ ، $NSE: 0/8690$ ، $RMSE: 0/2119$ Test). در این حالت مقدار بهینه پارامتر D و C به ترتیب ۰/۰۰۳۵ و ۰/۰۰۳۵ در نظر گرفته شدند. همچنین این مدل با تابع فعال ساز SKF در جایگاه دوم قرار دارد ($R^2: 0/8897$ ، $NSE: 0/8501$ ، $RMSE: 0/2243$ Train و $R^2: 0/8898$ ، $NSE: 0/8561$ ، $RMSE: 0/2187$ Test). در این حالت نیز مقدار بهینه C برابر ۰/۰۰۶۵ در نظر گرفته شد. همچنین این مدل با تابع فعال ساز RBF در جایگاه سوم قرار دارد ($R^2: 0/8881$ ، $NSE: 0/8367$ ، $RMSE: 0/2399$ Train و $R^2: 0/8884$ ، $NSE: 0/8470$ ، $RMSE: 0/2351$ Test). در این حالت مقدار بهینه γ و C تابع فعال‌ساز به ترتیب ۰/۰۰۷۳ و ۰/۰۰۸۲ در نظر گرفته شد. نهایتاً این مدل با تابع فعال‌ساز LKF بدترین عملکرد را در مرحله آموزش و صحت‌سنجی دارد ($R^2: 0/8865$ ، $NSE: 0/8265$ ، $RMSE: 0/2552$ Train و $R^2: 0/8871$ ، $NSE: 0/8333$ ، $RMSE: 0/2467$ Test). در این حالت نیز مقدار بهینه C برابر ۰/۰۰۹۶ در نظر گرفته شد. در جدول (۱) نتایج حاصل از مدل SVR با توابع کرنل مختلف در مرحله آموزش و صحت‌سنجی نشان داده شده است، همچنین در شکل‌های (۲) تا (۵) مقدار جریانان ماهانه مشاهده‌ای و محاسبه شده رودخانه با استفاده از مدل SVR نشان داده شده است.





تحلیل دقیق متغیرهای مستقل در مدل GWO-SVR، به‌ویژه در زمینه منابع آب، اهمیت زیادی دارد. با شناسایی Q_{t-1} ، R_t ، T_t به‌عنوان بهترین متغیرهای مستقل، مشخص شد که تغییرات در جریان قبلی، بارش و دما تأثیر قابل‌توجهی بر پیش‌بینی‌های جریان ماهانه دارند. این یافته‌ها نه تنها درک عمیق‌تری از عوامل مؤثر بر جریان آب فراهم می‌آورد بلکه به تصمیم‌گیران کمک می‌کند تا بر اساس این متغیرها، استراتژی‌های مدیریت منابع آب را بهبود بخشند. به‌ویژه در مناطق تحت تأثیر تغییرات اقلیمی، توجه به این متغیرها می‌تواند در بهبود پیش‌بینی‌ها و کاهش ریسک‌های مرتبط با مدیریت منابع آب مؤثر باشد. علاوه بر این، استفاده از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) در کنار روش سعی و خطا، به‌ویژه در تعیین پارامترهای مدل SVR، به کاهش خطاهای پیش‌بینی کمک شایانی کرده است. این روش به‌ویژه در شبیه‌سازی‌های غیرخطی که در سیستم‌های هیدرولوژیکی رایج هستند، بهینه‌سازی دقیقی را ارائه می‌دهد. نتایج به‌دست‌آمده حاکی از آن است که استفاده از GWO می‌تواند به‌عنوان یک ابزار مؤثر در فرایند آموزش مدل‌های یادگیری ماشین در حوزه هیدرولوژی مورد توجه قرار گیرد. این مهم می‌تواند به پژوهشگران و مهندسان در پیش‌بینی دقیق‌تر و بهینه‌سازی مدل‌های موجود کمک کند.

جدول (۱). نتایج حاصل از مدل SVR در مراحل آموزش و صحت‌سنجی.





مدل	آموزش			صحت‌سنجی		
	RMSE	NSE	R^2	RMSE	NSE	R^2
GWO-SVR(PKF)	۰/۲۱۴۷	۰/۸۶۴۱	۰/۸۹۳۹	۰/۲۱۱۹	۰/۸۶۹۰	۰/۸۹۴۹
GWO-SVR(SKF)	۰/۲۲۴۳	۰/۸۵۰۱	۰/۸۸۹۷	۰/۲۱۸۷	۰/۸۵۶۱	۰/۸۸۹۸
GWO-SVR(RBF)	۰/۲۳۹۹	۰/۸۳۶۷	۰/۸۸۸۱	۰/۲۳۵۱	۰/۸۴۷۰	۰/۸۸۸۴
GWO-SVR(LKF)	۰/۲۵۵۲	۰/۸۲۶۵	۰/۸۸۶۵	۰/۲۴۶۷	۰/۸۳۳۳	۰/۸۸۷۱



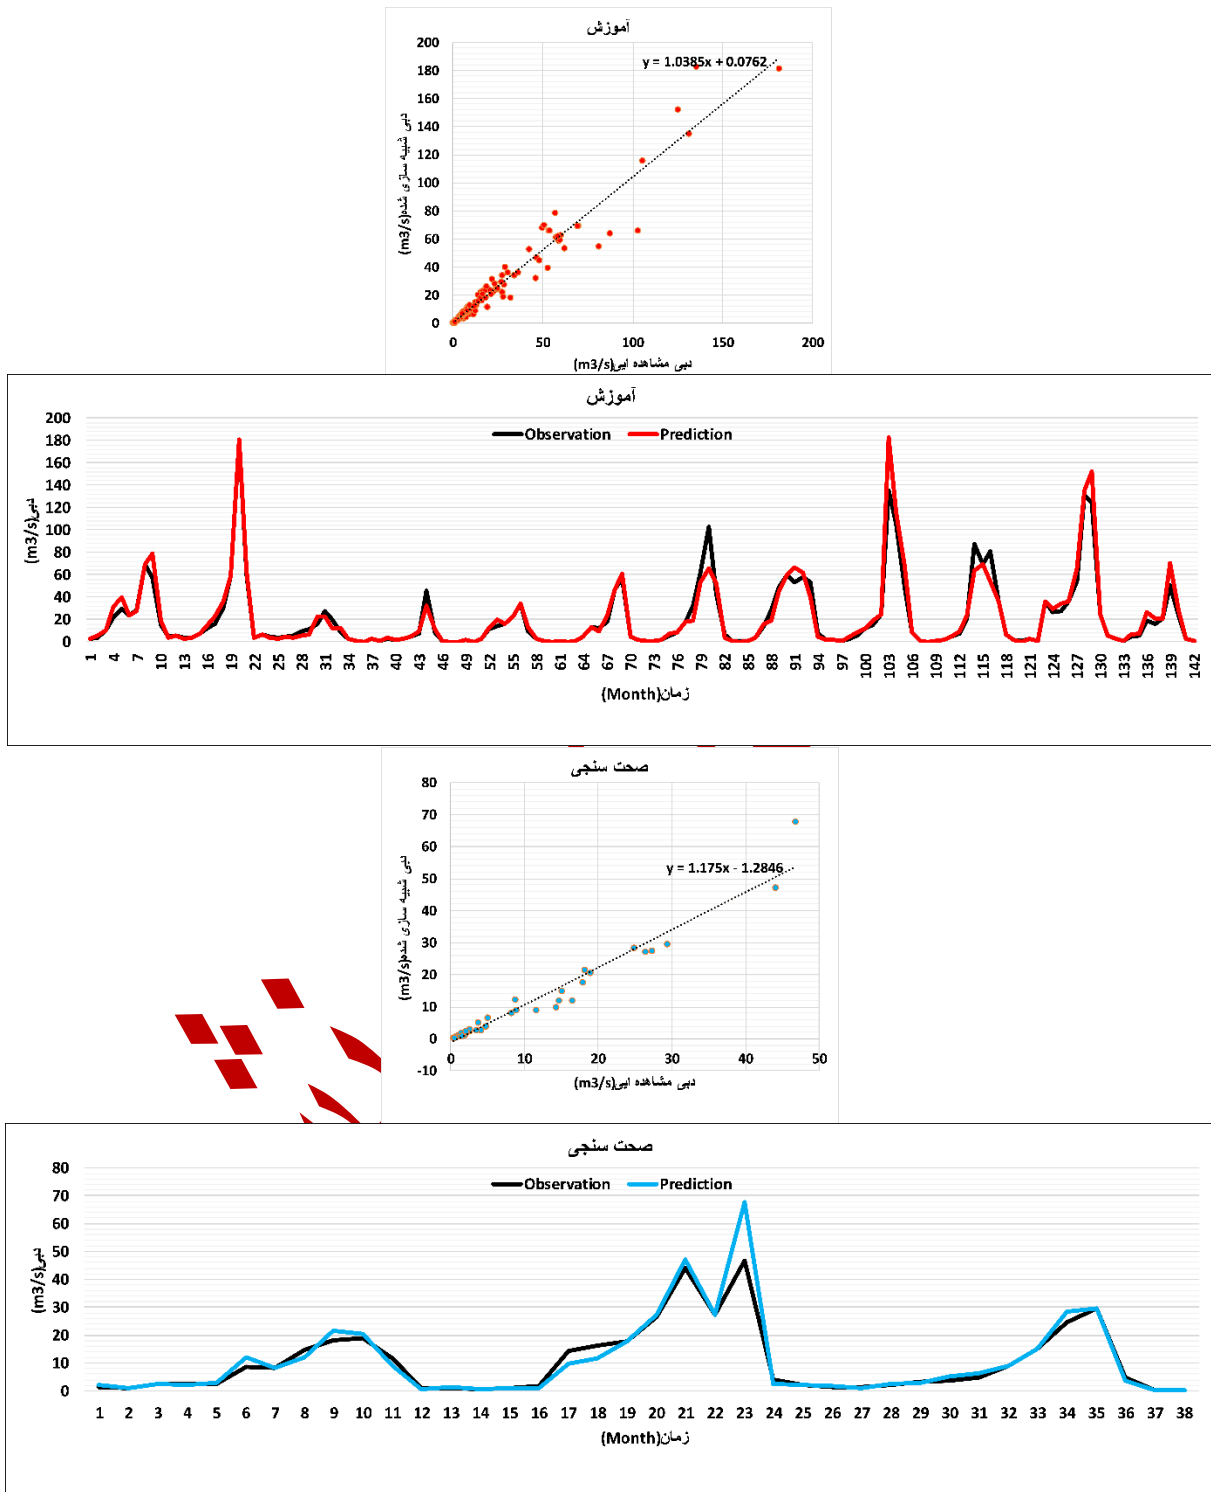
شکل ۲. نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل SVR و با تابع فعال سازی PKF در مرحله آموزش و صحت سنجی.



شکل ۳- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل SVR و با تابع فعال ساز SKF در مرحله آموزش و صحت سنجی.



شکل ۴- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل SVR و با تابع فعال ساز RBF در مرحله آموزش و صحت سنجی.



شکل ۵- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل SVR و با تابع فعال ساز LKF در مرحله آموزش و صحت سنجی.

تحلیل نتایج حاصل از مدل HH-SVR

در مرحله بعد از الگوریتم GWO برای آموزش مدل SVR استفاده شد (GWO-SVR). برای توسعه این مدل ابتدا مقدار اولیه پارامترهای مدل GWO تعیین شدند، سپس از این الگوریتم برای آموزش مدل SVR استفاده شد. به این ترتیب حداکثر تعداد تکرار^{۲۶} و حداکثر تعداد جمعیت الگوریتم GWO به ترتیب ۱۰۰۰ و ۵۰۰ در نظر گرفته شدند. سپس مدل GWO-SVR هر بار با ترکیب مختلفی از این متغیرها توسعه داده شد و شاخص‌های خطا مدل مورد نظر ذخیره شد، بر این اساس و با مقایسه شاخص‌های خطای مدل‌های مختلف مشخص شد که $Q_{t-1}R_t, T_t$ بهترین متغیرها برای شبیه سازی Q_t هستند. برای توسعه این مدل از ۸۰ درصد داده‌ها برای آموزش و از ۲۰ درصد کل داده‌ها برای صحت سنجی مدل استفاده شد. به این ترتیب ابتدا مقدار اولیه پارامترهای الگوریتم GWO مشخص شدند، مقدار پارامترهای NSA و MNI^۲ به ترتیب برابر ۱۰۰ و ۱۰۰۰ تعیین شد. همچنین تعداد متغیرهایی که باید مقدار آنها بهینه شود با توجه به نوع تابع فعال ساز تعیین گردید، برای توابع فعال ساز PKF، SKF، RBF و LKF مقدار این پارامتر به ترتیب ۲، ۱ و ۲ تعیین شد. همچنین حداقل و حداکثر مقدار همه پارامترها به جز d که مقدار آن باید یک عدد صحیح باشد برابر ۱ و ۱ در نظر گرفته شد. بعد از مشخص شدن مقدار اولیه همه پارامترها فرایند آموزش مدل GWO-SVR با توابع فعال ساز مختلف انجام گردید. ابتدا عملکرد مدل GWO-SVR با تابع فعال ساز PKF ارزیابی شد ($R^2: 0/90.27$ ، $NSE: 0/90.32$ ، $Train: RMSE: 0/1647$ و $Test: RMSE: 0/1575$ ، $NSE: 0/90.87$ ، $R^2: 0/90.54$). در این حالت مقدار بهینه پارامتر C برابر ۰/۰۰۳۸ در نظر گرفته شد. سپس عملکرد این مدل با تابع فعال ساز SKF ارزیابی گردید ($R^2: 0/89.86$ ، $NSE: 0/89.56$ ، $Train: RMSE: 0/1863$ و $Test: RMSE: 0/1809$ ، $NSE: 0/89.99$ ، $R^2: 0/89.88$). در این حالت مقدار پارامترهای C, γ توسط GWO برابر ۰/۰۰۳۴۳ و ۰/۰۹۰۳ در نظر گرفته شد. سپس عملکرد مدل GWO-SVR با تابع فعال ساز RBF ارزیابی گردید ($R^2: 0/89.73$ ، $NSE: 0/88.61$ ، $Train: RMSE: 0/1951$ و $Test: RMSE: 0/1921$ ، $NSE: 0/88.61$ ، $R^2: 0/89.21$). بر اساس نتایج حاصل از توسعه این مدل مقدار بهینه پارامتر C برابر ۰/۰۰۳۲ است، در نهایت عملکرد مدل با تابع LKF ارزیابی شد ($R^2: 0/89.49$ ، $NSE: 0/87.61$ ، $Train: RMSE: 0/2067$ ، $NSE: 0/87.61$ ، $R^2: 0/89.59$ و $Test: RMSE: 0/2029$ ، $NSE: 0/87.61$ ، $R^2: 0/89.59$). در این حالت نیز مقدار بهینه پارامترهای C, γ, r, d به ترتیب برابر ۳، ۰/۰۰۴۵، ۰/۰۰۲۵۴ و ۰/۰۰۴۸ در نظر گرفته شد. بر اساس نتایج حاصل از توسعه مدل GWO-SVR با توابع فعال ساز مختلف، این مدل با تابع فعال ساز PKF بهترین عملکرد را دارد و با تابع فعال ساز LKF بدترین عملکرد را دارد. بعد از توسعه مدل‌های مختلف آنالیز حساسیت انجام گرفت. بر اساس نتایج حاصل مدل GWO-SVR نسبت به متغیر Q_{t-1} بیشترین حساسیت و نسبت به متغیر T_{t-1} کمترین حساسیت را دارد. در جدول (۲) نتایج حاصل از مدل SVR با توابع کرنل مختلف در مرحله آموزش و صحت سنجی نشان داده شده است. همچنین در شکل‌های (۶) تا (۹) مقدار جریان ماهانه مشاهده‌ای و محاسبه شده رودخانه با استفاده از مدل SVR نشان داده شده است. استفاده از الگوریتم بهینه سازی گرگ خاکستری (GWO) به عنوان یک روش مؤثر در آموزش مدل (GWO-SVR) SVR نشان‌دهنده یک رویکرد نوآورانه برای بهبود دقت پیش‌بینی در حوزه‌های هیدرولوژیکی است. تعیین مقدار بهینه پارامترهای الگوریتم، به‌ویژه حداکثر تعداد تکرار و جمعیت، به عنوان گام‌های کلیدی در این فرایند معرفی شده‌اند. تنظیم بهینه این پارامترها می‌تواند تأثیر مستقیم و مثبتی بر کارایی مدل داشته باشد و با توجه به نتایج مطلوبی که از ترکیب متغیرها حاصل شده، به نظر می‌رسد که با استفاده از این روش به‌خوبی می‌توان جریان رودخانه را شبیه سازی کرد. علاوه بر این، تجزیه و تحلیل نتایج نشان می‌دهد که تابع فعال ساز PKF با دستیابی به بهترین نتایج در مراحل آموزش و صحت‌سنجی، به عنوان یک گزینه برجسته در مقایسه با دیگر توابع فعال ساز معرفی می‌شود. این موضوع می‌تواند به محققان این حوزه کمک کند تا در انتخاب توابع فعال ساز مناسب برای مدل‌های SVR، توجه بیشتری داشته باشند. نتایج تحلیل حساسیت مدل GWO-SVR نسبت به متغیرهای مختلف نیز جالب توجه است. به‌طور خاص، حساسیت بیشتر به متغیر $Q_{t-1}R_t, T_t$ نشان می‌دهد که این متغیر نقش کلیدی در پیش‌بینی جریان آب دارد و به نظر می‌رسد که تأثیر آن بر نتایج پیش‌بینی غیرقابل انکار




² Maximum number of iterations (MNI)


² Number of search agents (NSA)

است. در مقابل، حساسیت کمتر نسبت به سایر متغیرها می‌تواند به پژوهشگران این حوزه کمک کند تا در صورت نیاز، بهینه‌سازی‌های بیشتری را بر روی متغیرهای کم‌اثر انجام دهند.




جدول (۱). نتایج حاصل از مدل GWO-SVR در مراحل آموزش و صحت سنجی.


مدل	آموزش			صحت سنجی		
	RMSE	NSE	R ²	RMSE	NSE	R ²
GWO-SVR(PKF)	۰/۱۶۴۷	۰/۹۰۳۲	۰/۹۰۲۷	۰/۱۵۷۵	۰/۹۰۸۷	۰/۹۰۵۴
GWO-SVR(SKF)	۰/۱۸۶۳	۰/۸۹۵۶	۰/۸۹۸۶	۰/۱۸۰۹	۰/۸۹۹۹	۰/۸۹۸۸
GWO-SVR(RBF)	۰/۱۹۵۱	۰/۸۸۶۱	۰/۸۹۷۳	۰/۱۹۲۱	۰/۸۸۷۹	۰/۸۹۷۹
GWO-SVR(LKF)	۰/۲۰۶۷	۰/۸۷۶۱	۰/۸۹۵۹	۰/۲۰۲۹	۰/۸۷۸۹	۰/۸۹۶۷









شکل ۶- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل GWO-SVR و با تابع فعال سازی PKF در مرحله آموزش و صحت سنجی.









شکل ۷- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل GWO-SVR و با تابع فعال ساز SKF در مرحله آموزش و صحت سنجی.





شکل ۸- نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل GWO-SVR و با تابع فعال ساز RBF در مرحله آموزش و صحت‌سنجی.





شکل ۹. نمودار پراکنش مقادیر مشاهداتی و محاسباتی و نمودار مقایسه مقادیر جریان مشاهده شده و مقادیر شبیه سازی شده به وسیله مدل GWO-SVR و با تابع فعال ساز LKF در مرحله آموزش و صحت سنجی.

نتیجه گیری

بعد از توسعه مدل SVR با توابع فعال ساز مختلف نتایج این مدل‌ها با یکدیگر مقایسه شدند. بر اساس نتایج حاصل از آن مطالعه مدل GWO-SVR(LKF) نسبت به مدل SVR(LKF) عملکرد بهتری دارد. همچنین مدل GWO-SVR(RBF) نسبت به مدل SVR(RBF) نیز عملکرد بهتری دارد. مدل GWO-SVR(SKF) نیز نسبت به مدل SVR(SKF) عملکرد بهتری دارد. مانند سایر مدل‌ها مدل GWO-SVR(PKF) نیز نسبت به مدل SVR(PKF) عملکرد بهتری دارد. همچنین بر اساس مقایسه شاخص‌های خطا مدل‌های مختلف مدل GWO-SVR(PKF) نسبت به همه مدل‌ها در مرحله آموزش و صحت سنجی عملکرد بهتری دارد و مدل SVR(LKF) بدترین عملکرد را دارد. بعد از پایان فرایند آموزش و تست مدل‌های مختلف حساسیت آن‌ها نسبت به متغیرهای مختلف ارزیابی شد. بر اساس نتایج حاصل از آنالیز حساسیت همه مدل‌ها نسبت به متغیر Q_{t-1} بیشترین حساسیت را دارند و نسبت به متغیر E کمترین حساسیت را دارند.

دانشمندان همیشه تلاش می‌کنند از روش‌های دقیقی برای اندازه‌گیری جریان ماهانه رودخانه و مدل‌سازی سری زمانی آن استفاده کنند. روش‌های مبتنی بر هوش مصنوعی یکی از بهترین و دقیق‌ترین ابزارها برای این کار هستند، از میان روش‌های مختلف هوش مصنوعی، SVR یکی از کاربردی‌ترین روش‌ها برای مدل‌سازی جریان ماهانه رودخانه است. یکی از مهم‌ترین بخش‌های این مدل تابع فعال ساز است. می‌توان از توابع فعال ساز مختلفی برای توسعه این مدل استفاده کرد. هر تابع فعال ساز یک یا چندین پارامتر دارد. تعیین مقدار بهینه این پارامترها از مهم‌ترین بخش‌های توسعه هر مدل SVR است. هدف این مطالعه ارزیابی کارایی الگوریتم بهینه‌سازی گرگ خاکستری برای شبیه‌سازی پارامترهای توابع فعال ساز مدل SVR و در نتیجه بهبود دقت شبیه‌سازی جریان ماهانه رودخانه با استفاده از این مدل است. برای این کار از اطلاعات ماهانه جریان رودخانه، دما و بارندگی برای یک دوره ۱۵ ساله استفاده شد (۱۳۸۵ تا ۱۴۰۰). بهترین متغیرهای ورودی به مدل یا استفاده از روش سعی و خطا انتخاب شدند. بر این اساس از متغیرهای Q_{t-1}, R_t, T_t برای توسعه همه مدل‌ها استفاده شد. بعد از مشخص شدن بهترین متغیرها برای شبیه‌سازی جریان ماهانه رودخانه برای جلوگیری از بایاس شدن مدل همه اطلاعات در بازه صفر و یک نرمال شدند. سپس از ۸۰ درصد داده‌ها برای آموزش مدل‌های SVR و GWO-SVR استفاده شد و از سایر داده‌ها برای ارزیابی مدل‌ها استفاده گردید. در این مطالعه برای آموزش مدل SVR از توابع فعال ساز خطی، پایه شعاعی، سیم‌گوبید و چند جمله‌ای استفاده شد. به این ترتیب کارایی هر یک از مدل‌های SVR و GWO-SVR با هر یک از این توابع فعال ساز ارزیابی شد. در نهایت برای ارزیابی مدل‌های مختلف و مقایسه نتایج آن‌ها از شاخص‌های R^2 , RMSE و NSE استفاده شد. بر اساس نتایج حاصل حاصل مدل‌های SVR و GWO-SVR با تابع فعال ساز چندجمله‌ای بهترین عملکرد و با تابع فعال ساز خطی بدترین عملکرد را در مرحله آموزش و صحت سنجی دارند. همچنین به طور دقیق‌تر از میان مدل‌های مختلف مدل GWO-SVR با تابع فعال ساز چندجمله‌ای بهترین عملکرد و مدل SVR با

تابع فعال ساز خطی بدترین عملکرد را دارد. بر اساس نتایج حاصل از این مطالعه الگوریتم GWO نسبت به روش سعی و خطا ابزار مناسب تری برای شبیه سازی جریان ماهانه رودخانه با استفاده از مدل SVR است.

مراجع

فلاحی، محمد معین؛ یعقوبی، بهروز؛ یوسفوند، فریبرز و شعبانلو، سعید (۱۳۹۹). بهبود عملکرد مدل برنامه‌نویسی بیان ژن با استفاده از تبدیل موجک برای تخمین بارش درازمدت شهر رشت. علوم آب و خاک، ۲۴ (۳)، ۱-۱۶.

Abualigah, L., & Diabat, A. (2020). A comprehensive survey of the Grasshopper optimization algorithm: results, variants, and applications. *Neural computing and applications*, 32(19), 15533-15556.

Awad, M., Khanna, R., Awad, M., & Khanna, R. (2015). Support vector regression. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67-80.

Brierley, G. J., & Fryirs, K. A. (2013). *Geomorphology and river management: applications of the river styles framework*. John Wiley & Sons.

Cui, F., Salih, S. Q., Choubin, B., Bhagat, S. K., Samui, P., & Yaseen, Z. M. (2020). Newly explored machine learning model for river flow time series forecasting at Mary River, Australia. *Environmental Monitoring and Assessment*, 192, 1-15.

Fallahi, M.M., Yaghoubi, B., Yosefvand, F., Shabanlou, S. (2020). Improvement of Gene Expression Programming Model Performance using Wavelet Transform for the Estimation of Long-Term Rainfall in Rasht City. *Jwss*, 24(3), 1-16. (in Persian)

Faris, H., Aljarah, I., Al-Betar, M. A., & Mirjalili, S. (2018). Grey wolf optimizer: a review of recent variants and applications. *Neural computing and applications*, 30, 413-435.

Fathian, F., Mehdizadeh, S., Sales, A. K., & Safari, M. J. S. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models. *Journal of Hydrology*, 575, 1200-1213.

Goorani, Z., & Shabanlou, S. (2021). Multi-objective optimization of quantitative-qualitative operation of water resources systems with approach of supplying environmental demands of Shadegan Wetland. *Journal of Environmental Management*, 292, 112769.

Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., & Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4), 18-28.

Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872.

Jalili, A.A., Najarchi, M., Shabanlou, S. et al. Multi-objective Optimization of water resources in real time based on integration of NSGA-II and support vector machines. *Environ Sci Pollut Res* 30, 16464–16475 (2023). <https://doi.org/10.1007/s11356-022-22723-4>

Kamboj, V. K., Nandi, A., Bhadoria, A., & Sehgal, S. (2020). An intensify Harris Hawks optimizer for numerical and engineering optimization problems. *Applied Soft Computing*, 89, 106018.

Marlia, M., Syaharuddin, S., Handy, M. R. N., Subiyakto, B., & Ilhami, M. R. (2022). Changes in the Behavior of the Riverside Community of Banua Anyar Village towards River Management Policies. *The Kalimantan Social Studies Journal*, 4(1), 48-55.

Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmad, R. (2023). A Hybrid Machine Learning Model for Modeling Nitrate Concentration in Water Sources. *Water, Air, & Soil Pollution*, 234(11), 1-22.

Mazraeh, A., Bagherifar, M., Shabanlou, S., & Ekhlasmad, R. (2024). A novel committee-based framework for modeling groundwater level fluctuations: A combination of mathematical and machine learning models using the weighted multi-model ensemble mean algorithm. *Groundwater for Sustainable Development*, 24, 101062.

Meraihi, Y., Gabis, A. B., Mirjalili, S., & Ramdane-Cherif, A. (2021). Grasshopper optimization algorithm: theory, variants, and applications. *Ieee Access*, 9, 50001-50024.

Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.

- Mojaddadi, H., Pradhan, B., Nampak, H., Ahmad, N., & Ghazali, A. H. b. (2017). Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS. *Geomatics, Natural Hazards and Risk*, 8(2), 1080-1102.
- Siddiqi, T. A., Ashraf, S., Khan, S. A., & Iqbal, M. J. (2021). Estimation of data-driven streamflow predicting models using machine learning methods. *Arabian Journal of Geosciences*, 14(11), 1058.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Suthaharan, S., & Suthaharan, S. (2016). Support vector machine. *Machine learning models and algorithms for big data classification: thinking with examples for effective learning*, 207-235.
- Teng, Z.-j., Lv, J.-l., & Guo, L.-w. (2019). An improved hybrid grey wolf optimization algorithm. *Soft computing*, 23, 6617-6631.
- Torabi, A., Yosefvand, F., Shabanlou, S. et al. Optimization of Integrated Operation of Surface and Groundwater Resources using Multi-Objective Grey Wolf Optimizer (MOGWO) Algorithm. *Water Resour Manage* 38, 2079–2099 (2024). <https://doi.org/10.1007/s11269-024-03744-9>
- Yildiz, B. S., Pholdee, N., Bureerat, S., Yildiz, A. R., & Sait, S. M. (2022). Enhanced grasshopper optimization algorithm using elite opposition-based learning for solving real-world engineering problems. *Engineering with Computers*, 38(5), 4207-4219.
- Zhang, Z., Zhang, Q., Singh, V. P., & Shi, P. (2018). River flow modelling: comparison of performance and evaluation of uncertainty using data-driven models and conceptual hydrological model. *Stochastic environmental research and risk assessment*, 32, 2667-2682.

مكتبة
الجامعة
الاسلامية

Simulation of monthly river flow using improved support vector machine regression model using gray wolf optimization algorithm

Safoura Pirouzmehr¹ | Saeid Shabanlou² | Fariborz Yosefvand³ | Behrouz Yaghoubi⁴ | Ahmad Rajabi⁵ | Mohammad Ali Izadbakhsh⁶

1. Ph.D. Candidate, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran, E-mail: s.pirouzmehr@gmail.com
2. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: saeid.shabanlou@gmail.com
3. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: fariborzosefvand@gmail.com
4. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: byaghubi@gmail.com
5. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: ahmad.rajabi1974@gmail.com
6. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran. E-mail: izadbakhsh.mohammad.ali@gmail.com

Introduction

Scientists are always trying to use accurate methods to measure monthly river flow and model its time series. Artificial intelligence-based methods are one of the best and most accurate tools for this work, among various artificial intelligence methods, SVR is one of the most useful methods for modeling monthly river flow. One of the most important parts of this model is the activator function. Different activation functions can be used to develop this model. Each activator function has one or more parameters. Determining the optimal value of these parameters is one of the most important parts of developing any SVR model. The aim of this study is to evaluate the efficiency of the gray wolf optimization algorithm for simulating the parameters of the SVR model's activation functions and, as a result, to improve the accuracy of the monthly river flow simulation using this model.

Methods and Materials

For this purpose, the monthly information of monthly river flow, temperature and rainfall was used for a 15-year period (1385 to 1400). The best input variables to the model were selected using the trial and error method. Therefore, variables Q_{t-1} , R_t , T_t were used to develop all models. After determining the best variables for simulating the monthly flow of the river, all information was normalized between zero and one to avoid model bias. Then, 80% of all data were used to train SVR and GWO-SVR models, and other data were used to evaluate the models. In this study, linear, radial base, sigmoid and polynomial activator functions were used to train the SVR model. In this way, the efficiency of each of the SVR and GWO-SVR models was evaluated with each of these activation functions. Finally, RMSE, R^2 and NSE indicators were used to evaluate different models and compare their results. According to the results, SVR and GWO-SVR models with polynomial activation function have the best performance and linear activation function have the worst performance in the training and validation stage. Also, more precisely, among the various models, the GWO-SVR model with the polynomial activation function has the best performance and the SVR model with the linear activation function has the worst performance. Based on the results of this study, the GWO algorithm is a more suitable tool than the trial and error method for simulating the monthly river flow using the SVR model.

Results and Discussion

Based on the results of this study, the SVR model with polynomial activation function has the best performance in the training and validation phase, and with the linear activation function, it has the worst performance in the training and validation phase. Next, the GWO algorithm was used to determine the parameters of the activator functions. Based on the final results, the SVR model performs better with the GWO algorithm. Therefore, to simulate the monthly flow of river water using this model, it is better to use the GWO algorithm instead of the trial and error method.

Conclusion

After developing the SVR model with different activator functions, the results of these models were compared with each other. Based on the results of that study, the GWO-SVR(LKF) model performs better than the SVR(LKF) model. Also, the GWO-SVR(RBF) model has a better performance than the SVR(RBF) model. The GWO-SVR(SKF) model also performs better than the SVR(SKF) model. Like other models, the GWO-SVR(PKF) model also performs better than the SVR(PKF) model. Also, based on the comparison of the error indices of different models, the GWO-SVR(PKF) model performs better than all models in the training and validation stage, and the SVR(LKF) model has the worst performance. After the end of the training and testing process of different models, their sensitivity to different variables was evaluated. Based on the results of the sensitivity analysis, all models have the most sensitivity to the variable Q_{t-1} and the least sensitivity to the variable E.

Keywords: Monthly river flow, support vector regression, gray wolf optimization algorithm, water resources management

Author Contributions:

For research articles with several authors, a short paragraph specifying their individual contributions must be provided. The following statements should be used “Conceptualization, Safora Pirouzmehr and Saeid Shabanlou; methodology, Safora Pirouzmehr and Saeid Shabanlou; software, Safora Pirouzmehr and Saeid Shabanlou and Fariborz yosefvand and Behrouz Yaghoubi and Ahmad Rajabi and Mohammad ali Izadbakhsh; validation, Safora Pirouzmehr and Saeid Shabanlou; formal analysis, Safora Pirouzmehr and Saeid Shabanlou; investigation, Safora Pirouzmehr and Saeid Shabanlou; resources, Safora Pirouzmehr and Saeid Shabanlou; data curation, Safora Pirouzmehr and Saeid Shabanlou; writing—original draft preparation, Safora Pirouzmehr and Saeid Shabanlou; writing—review and editing, Safora Pirouzmehr and Saeid Shabanlou and Fariborz yosefvand and Behrouz Yaghoubi and Ahmad Rajabi and Mohammad ali Izadbakhsh; visualization, Saeid Shabanlou; supervision, Saeid Shabanlou; project administration, Saeid Shabanlou; All authors have read and agreed to the published version of the manuscript.” Please turn to the CRediT taxonomy for the term explanation. Authorship must be limited to those who have contributed substantially to the work re-ported.

Data Availability Statement: Data available on request from the authors

Conflict of interest: The author declares no conflict of interest

مجله علمی پژوهشی
فصلنامه علمی پژوهشی
پژوهش‌های علمی