Shahid Chamran University of Ahvaz

Irrigation Sciences and Engineering (JISE)
Vol. 48, No. 3, Fall 2025, p. 75-93

Research Paper

Journal homepage: https://jise.scu.ac.ir

EXTENDED ABSTRACT

Suspended sediment load estimation using Support Vector Machine-Simulated Annealing algorithm and improved computational methods

H. Nozari[1*], F. Chodani[2], M. Kalantari[3] and A. Mehrabani Bashar[4]

1- Corresponding Author, Associate Professor, Dapartment of Water Sciences and Engineering, Bu-Ali Sina University, Hamedan, Iran (h.nozari@basu.ac.ir).*
2- M.Sc. graduated, Department of Water Sciences and Engineering, Bu-Ali Sina University, Hamedan, Iran.
3- Assistant Proffesor, Department of Statistics, Payame Noor University, Tehran, Iran.
4- M.Sc. graduated, Department of Water Sciences and Engineering, Bu-Ali Sina University, Hamedan, Iran.

ARTICLE INFO

Artlcle history:
Received: 07 October 2023
Revised: 19 October 2024
Accepted: 21 October 2024
Available online: 05 November 2025

Keywords:
Sediment Rating Curve, FAO Method, Generalized Reduced Gradient, Nonlinear Optimization.

TO CITE THIS ARTICLE:

Nozari, H., Chodani, F., Kalantari, M., Mehrabani Bashar, A. 2025. 'Suspended sediment load estimation using Support Vector Machine-Simulated Annealing algorithm and improved computational methods', *Irrigation Sciences and Engineering*, 48(3), pp. 75-93. doi: 10.22055/jise.2024.44894.2096.

Abstract

Studying and developing water resource systems requires an accurate prediction of river suspended sediment load. Since sediment load measurement is costly and time-consuming, the simulation methods based on the sediment load time series are usually restricted to sample numbers. This study used two different methods to forecast the monthly suspended sediment load. In the first method, the Support Vector Machine (SVM) algorithm was used to forecast sediment load based on a monthly time series of suspended sediment data. In this method, the hyperparameter coefficients of the SVM model were optimized using the Simulated Annealing (SA) algorithm. Additionally, this model was evaluated under single-input-single-output (SISO) and multiple-input-single-output (MISO) patterns. The suspended sediment load and flow data of the Yalfan River from 2007 to 2015 were the SISO's inputs and outputs, respectively. Moreover, the MISO's second input was a fixed number series. In the second method, the sediment rating curve and the FAO method forecast it. A %9.93-point increase in the Standard Error (SE) index was obtained by normalizing the SVM-SA's input data. Switching the input patterns from single input-single output (SISO) to multiple input-single output (MISO) resulted in a %1.03 improvement in SE. By optimizing the coefficients of the discharge-sediment variables in the rating curve and FAO method using the General Reduced Gradient (GRG) technique, the SE index improved by %10.13 and %73.19, respectively. The results showed that the SVM-SA model based on the normalized MISO approach is the best method for suspended sediment load forecasting.

Introduction

Sediment is one of the most significant non-point sources of river pollution (Shojaeezadeh et al., 2018) and its precise estimation is a key factor in hydro-environmental projects, such as the design and implementation of water structures (AlDahoul et al., 2021). Since direct sampling of sediment load is difficult and time-consuming, various physical, experimental and mathematical models are employed to estimate it (Ramezanipour et al., 2017). The Support Vector Machine (SVM) is a widely used model in hydrology for forecasting, classification, solving linear and non-linear regressions, and pattern

recognition (Samantary et al., 2020 ،Huang et al., 2021). This model's forecasting accuracy has been improved by Simulated Annealing (SA) algorithm in many studies. As sediment load data has statistical defects and its direct measurements are costly, the use of computational and classical methods such as rating curves and the FAO method is unavoidable (Shojaeezadeh et al., 2018). Many studies have shown that using optimization algorithms and modifying discharge-sediment relationships can improve the performance of computational and artificial intelligence methods. In the present study, two different methods are used to forecast the monthly suspended sediment load. The first method examines how the data patterns and the type of probability distribution affect the SVM-SA's performance, and the second method examines how the Generalized Reduced Gradient (GRG) optimization method affects the modified FAO and rating curve. Finally, computational and direct forecasting methods are compared, and the most accurate model for sediment load forecasting is introduced.

Methodology

The SVM model is a statistical machine learning system, which finds the optimal hyperplane to categorize the data based on a binary classification. An important factor affecting the performance of this model is parameter adjustment (Sedighkia and Datta., 2023). Traditional SVM models use trial and error to determine parameters; however, in this study, the SA optimization algorithm chooses them. This algorithm is a local search method, which tries to find the global optimum solution. In the hybrid SVM-SA model, the initial values of the SVM's parameters are first set manually based on the previous studies' suggestions; then, the SA algorithm calculates the parameters' optimal values, and the model will be executed (Mehrabani Bashar et al., 2023). So, the modeling process will be faster and more accurate without the need for repetitive trial and error (Azadi et al., 2022). This study compares the performance of the SVM-SA model based on the SISO and the MISO approaches and evaluates the effect of input data normalization on their performance.

Most sediment load time series contain missing values, so understanding and quantifying the nonlinear interactions between the historical sediment load and discharge flow data is essential. In the sediment rating curve method, sediment load and flow data are plotted against each other on a logarithmic scale, and a power line is fitted (Azadi et al., 2020). The sediment discharge is calculated using this line's equation:

$$Q_s = aQ_w^b \quad (1)$$

Where Qs = suspended sediment discharge (ton/month); Qw = flow discharge (m3/s); a and b = regression coefficients.

To bring the sediment load values estimated by the rating curve closer to the observational data, the FAO method modifies the drainage coefficient and uses the following equation instead:

$$Q_s = (\overline{Q}_S / \overline{Q}_w^{\ b})Q_w^b \quad (2)$$

Where $\overline{Q}_S$ = average sediment load: and $\overline{Q}_W$ = average discharge.

In this study, the discharge-sediment equations were optimized by the GRG method. The coefficients of the discharge-sediment variables were considered decision variables, and the objective function was minimizing the difference between the estimated and the observed data.

Results and Discussion

According to Figure (1), all methods except the FAO method perform similarly and are within the range of RMSE=500. The performance of the FAO method was significantly improved by GRG optimization. Normalizing the SVM-SA's input data improved both the SISO and MISO approaches.

The SVM-SA model based on the normalized MISO approach has the lowest RMSE and the highest correlation and also is closer to the observational data, which indicates its superiority.

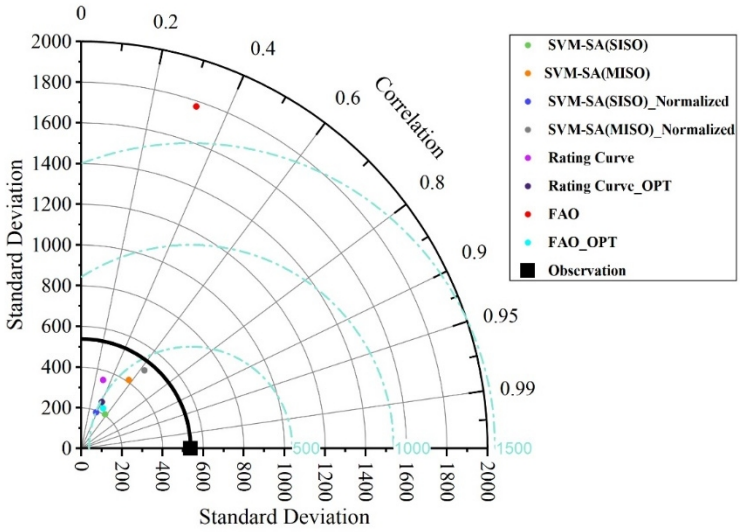


Fig. 1- Taylor diagram for the performance of the sediment load estimation methods

Conclusions

The performance of both original and normalized modeling was improved by separating and modifying the SVM-SA's input data from SISO to MISO patterns. Also, data normalization improved both the SISO and MISO approaches. The GRG optimization algorithm improved the performance of the mentioned computational methods by selecting coefficients of discharge-sediment variables, making these methods competitive with direct forecasting models. The results showed that the SVM-SA model based on the normalized MISO approach is the best method for suspended sediment load forecasting.

Acknowledgements

This manuscript was financially supported by the Regional Water Company of Hamedan, and the authors would like to express their gratitude.

Conflict of Interest

The authors declared no potential conflicts of interest concerning the research, authorship, and publication of this article. Confirmation.

Funding

This study was conducted with financial support from the Hamedan Regional Water Company. The authors wish to express their sincere gratitude for this assistance. Additionally, the authors extend their appreciation to Bu-Ali Sina University of Hamadan for providing the necessary facilities to facilitate this research.

Data Availability Statements

The datasets generated and/or analyzed during the current study are available from the corresponding author on reasonable request.

Authors' contribution

First Author: Hamed Nozari, was responsible for planning the project, developing the main conceptual ideas, and analyzing the data

Second Author: Fatemeh Chodani, conducted the calculations, analyzed the data, and authored the manuscript.

Third Author: Mahdi Kalantari, was responsible for developing the main conceptual ideas, establishing the computational framework

Fourth Author: Alireza Mehrabani, Bashar conducted the calculations, analyzed the data, and authored the manuscript.

References

1- AlDahoul, N., Essam, Y., Kumar, P., Ahmed, A. N., Sherif, M., Sefelnasr, A., and Elshafie, A. 2021. Suspended sediment load prediction using long short-term memory neural network. Scientific Reports, 11(1): 1-22. DOI: 10.1038/s41598-021-87415-4.

2- Azadi, S., Nozari, H., and Godarzi, E. 2020. Predicting sediment load using stochastic model and rating curves in a hydrological station. *Journal of Hydrologic Engineering*, 25(8): 05020017. DOI: 10.1061/(ASCE)HE.1943-5584.0001967.

3- Azadi, S., Vafaee, M., and Nozari, H. 2022. Estimation of precipitation using the combined method of Support Vector Machine-Simulated Annealing algorithm (case study: Gorgan synoptic station). *Advanced Technologies in Water Efficiency*, 2(3), 14-34. (In Persian). DOI: 10.22126/ATWE.2022.8393.1028.

4- Huang, C. C., Chang, M. J., Lin, G. F., Wu, M. C., and Wang, P. H. 2021. Real-Time forecasting of suspended sediment concentrations reservoirs by the optimal integration of multiple machine learning techniques. *Journal of Hydrology*, 34: 100804. DOI: 10.1016/j.ejrh.2021.100804.

5- Mehrabani Bashar, A., Nozari, H., Marofi, S., Mohamadi, M., and Ahadiiman, A. 2023. Investigation of factors affecting rural drinking water consumption using intelligent hybrid models. *Water Science and Engineering*, 16(2), 175-183. DOI: 10.1016/j.wse.2022.12.002.

6- Ramezanipour, E., Mosaedi, A., and Mesdaghi, M. 2017. Determination of the Best Model for Estimation of Suspended Sediment by using Statistical Error Criteria (Case Stude: Some Sub-Watersheds of Kashafroud). *Journal of Watershed Management Research*, 8(15): 112-124. (In Persian). DOI: 10.29252/jwmr.8.15.112.

7- Samantary, S., Sahoo, A., and Ghose, D. K. 2020. Assessment of Sediment Load Concentration Using SVM, SVM-FFA and PSR-SVM-FFA in Air Watershed, India: A Case Study. *KSCE Journal of Civil Engineering*, 24, 1944-1957. DOI: 10.1007/s12205-020-1889-x.

8- Sedighkia, M., and Datta, B. 2023. Linking SVM based habitat model and evolutionary optimization for managing environmental impacts of hydropower plants. *River Research and Applications*, 39, 897-910. DOI: 10.1002/rra.4121.

9- Shojaeezadeh, S. A., Nikoo, M. R., McNamara, J. P., AghaKouchak, A., and Sadegh, M. 2018. Stochastic modeling of suspended sediment load in alluvial rivers. *Advances in Water Resources*, *119*: 188–196. DOI: 10.1016/j.advwatres.2018.06.006.

© 2025 The Author(s). Published by Shahid Chamran University of Ahvaz. This is an open-access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/by/4.0), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

علوم و مهندسی آبیاری جلد ٤٨، شماره‌ی۳، پاییز ١٤٠٤، مقاله پژوهشی، ص. ۹۳-۷۵

پیش‌بینی بار رسوب معلق رودخانه با استفاده از مدل ماشین بردار پشتیبان و روش‌های محاسباتی بهبودیافته

حامد نوذری[1*]، فاطمه چدنی[2]، مهدی کلانتری[3] و علیرضا مهربانی بشار[4]

۱*- نویسنده مسئول، دانشیار گروه علوم و مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران (h.nozari@basu.ac.ir).

۲- دانش‌آموخته کارشناسی ارشد، گروه علوم و مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران.

۳- استادیار گروه آمار، دانشگاه پیام نور، تهران، ایران.

۴- دانش‌آموخته کارشناسی ارشد، گروه علوم و مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران.

دریافت: ۱۴۰۲/۰۷/۱۵ بازنگری: ۱۴۰۳/۰۷/۲۸ پذیرش: ۱۴۰۳/۰۷/۳۰ انتشار: ۱۴۰۴/۰۸/۱۴

چکیده

برآورد دقیق بار رسوب معلق رودخانه، امری ضروری در مطالعه و توسعه سیستم‌های منابع آب است. اندازه‌گیری مستقیم بار رسوبی، پرهزینه و زمان‌بر است، لذا توسعه مدلی جایگزین نظیر منحنی سنجه و یا مدل‌های شبیه‌سازی توصیه می‌شود. در این مطالعه از دو روش مختلف برای پیش‌بینی بار رسوب معلق رودخانه استفاده شد. در روش اول میزان بار رسوبی با استفاده از مدل ماشین بردار پشتیبان (SVM) پیش‌بینی شد. در این روش، ضرایب هایپر پارامترهای مدل SVM با الگوریتم تبرید (SA) بهینه شدند. همچنین به مقایسه عملکرد این مدل تحت الگوهای تک ورودی-تک خروجی (SISO) و چند ورودی-تک خروجی (MISO) نیز پرداخته شد. سری آبدهی و بار رسوب معلق رودخانه یلفان طی دوره ۱۳۹٤-۱۳۸٦ به‌ترتیب به‌عنوان ورودی و خروجی مدل معرفی شدند. در روش دوم نیز، از منحنی سنجه و روش رسوب‌سنجی اصلاحی FAO استفاده شد. نرمال‌سازی داده‌های ورودی به مدل SVM، باعث بهبود ۹/۹۳ درصدی شاخص خطای استاندارد (SE) در بخش آزمون مدل‌سازی شد، همچنین اصلاح الگوی ورودی به این مدل از الگوی SISO به MISO باعث بهبود ۱/۰۳ درصدی در این شاخص شد. پس از بهینه‌سازی ضرایب منحنی سنجه و روش اصلاحی FAO با استفاده از گرادیان کاهش‌یافته عمومی (GRG) نیز، شاخص SE به‌ترتیب ۱۰/۱۳ و ۷۳/۱۹ درصد بهبود یافت. از میان روش‌های بررسی شده، مدل SVM مبتنی بر الگوی چند ورودی-تک خروجی نرمال شده، به‌عنوان بهترین روش معرفی و به‌منظور پیش‌بینی بار رسوب معلق رودخانه پیشنهاد می‌گردد.

کلید واژه‌ها: منحنی سنجه رسوب، رسوب‌سنجی اصلاحی FAO، گرادیان کاهش‌یافته عمومی، بهینه‌سازی غیرخطی.

مقدمه

رسوب از منابع اصلی آلودگی غیرنقطه‌ای در رودخانه‌ها است. کاهش عمر مفید و ظرفیت ذخیره سدها، انتقال آلودگی، ایجاد جزایر رسوبی در مسیر رودخانه، کاهش ظرفیت انتقال جریان‌های سیلابی، خسارات به ابنیه و مزارع و حتی خسارات جانی، از پیامدهای فرآیند فرسایش و از اثرات نامطلوب رسوب‌گذاری هستند (Shojaeezadeh et al., 2018). لذا برآورد دقیق رسوب حمل شده توسط رودخانه‌ها در حوزه‌های بسیاری نظیر طراحی و ساخت سازه‌های آبی، آبخیزداری، حفاظت خاک، محیط‌زیست، کشاورزی و مدیریت منابع آب امری ضروری است (AlDahoul et al., 2021). از مرسوم‌ترین روش‌های اندازه‌گیری بار رسوب معلق، نمونه‌برداری مستقیم از مقاطع و اعماق مختلف رودخانه و سپس محاسبات و اندازه‌گیری‌های آزمایشگاهی است، اما بر اساس نظر Ramezanipour et al (2017) تجهیز کردن تمام ایستگاه‌های هیدرومتری به وسایل اندازه‌گیری و برداشت نمونه، مستلزم صرف هزینه و زمان زیادی است که سبب شده اطلاعات محدودی از بار رسوبی در دسترس باشد (Azadi et al., 2020). از این رو مدل‌های مختلفی از جمله مدل‌های فیزیکی، تجربی و مدل‌های ریاضی به‌منظور برآورد بار رسوبی رودخانه استفاده می‌شوند.

به‌طور کلی مدل‌های پیش‌بینی به دو دسته تقسیم می‌شوند: مدل‌های دانش محور و مدل‌های داده محور. در مدل‌های دانش محور، پارامترها بر اساس روابط و فرمول‌ها محاسبه می‌شوند، که به درک فرآیند فیزیکی سیستم وابسته است. اما فرآیندهای هیدرولوژیکی اکثرا پیچیده‌اند، توصیف آن‌ها برای مدل آسان نیست و حتی درصورت دست‌یابی به روابط، عموماً تعمیم‌پذیر نخواهند بود. در مدل‌های داده محور، آینده تابعی از گذشته است و پیش‌بینی براساس آنالیز آماری داده‌های تاریخی انجام می‌شود، که به اطلاعات جانبی دیگری نیاز ندارد. لذا برای برآورد و پیش‌بینی بار رسوب معلق رودخانه، استفاده از سری‌های زمانی توصیه می‌شود (Ba et al., 2018). در این راستا، مدل‌های تصادفی مختلف، بر سری زمانی برازش داده می‌شوند و پس از بررسی خواص داده‌ها، مدل مناسب انتخاب و در نهایت پیش‌بینی انجام می‌گردد. روش‌های مدل‌سازی سری‌های زمانی در دو دسته روش‌های آماری و روش‌های هوش مصنوعی طبقه‌بندی می‌شوند. مدل‌های خودهمبسته (Autoregressive)، میانگین متحرک (Moving

DOI: 10.22055/jise.2024.44894.2096

Average) و انواع مدل‌های میانگین متحرک خودهمبسته یکپارچه (Autoregressive Integrated Moving Average) از پرکاربردترین روش‌های آماری و همچنین مدل‌های شبکه عصبی مصنوعی (Artificial Neural Network)، الگوریتم ژنتیک (Genetic Algorithm)، برنامه‌ریزی ژنتیک (Genetic Programming) و ماشین بردار پشتیبان (Support Vector Machine) نیز از مؤثرترین روش‌های هوش مصنوعی برای مدل‌سازی سری‌های زمانی هستند (AlDahoul et al., 2021).

مدل SVM توسط Cortes و Vapnik (1995) معرفی شد، که ابزاری قدرتمند برای طبقه‌بندی داده‌ها و حل مسائل رگرسیونی خطی و غیرخطی است (Huang et al., 2021). این روش که بر اساس تئوری یادگیری آماری استوار است، با اعمال محدودیت‌های تصمیم‌گیری به طبقه‌بندی بهینه داده‌ها می‌پردازد (Samantary et al., 2020). مدل‌های SVM توانایی کشف روابط ناشناخته بین متغیرهای ورودی و خروجی یک سیستم را دارند و برای سری‌های با داده‌های کم و پراکنده نیز قابل اجرا هستند (Deka, 2014). توانایی طبقه‌بندی همزمان مسائل خطی و غیرخطی، تطبیق‌پذیری با داده‌های بزرگ مقیاس و انعطاف‌پذیری از طریق ارائه توابع کرنل مختلف، از مزایای این مدل‌ها هستند (Huang et al., 2021). از آنجا که مدل SVM بر اصول کمینه‌سازی ریسک ساختاری (Structural Risk Minimization) استوار است، در حوزه‌های مختلفی مانند هیدرولوژی کاربرد گسترده‌ای دارد، که از جمله آن می‌توان به تخمین رطوبت خاک، ارزیابی کیفیت و پیش‌بینی سطح آب زیرزمینی، پیش‌بینی بارش و رواناب، تبخیر و تعرق، سطح آب دریاچه‌ها و مخازن، سیل و خشکسالی، جریان آبدهی و بار رسوبی رودخانه اشاره کرد (Deka, 2014). Lin et al (2006) برای پیش‌بینی آبدهی بلندمدت از مدل‌های SVM، ARIMA و ANN استفاده کردند. نتایج این مطالعه نشان داد، مدل SVM در مقایسه با مدل‌های دیگر عملکرد بهتری داشته و قادر به کشف ویژگی‌های غیرخطی سری زمانی است. Huang et al (2021) برای پیش‌بینی غلظت رسوب معلق وارد شده به یک مخزن ذخیره‌سازی، مدل‌های یادگیری ماشین پرسپترون چندلایه (Multilayer Perceptron)، جنگل تصادفی (Random Forest)، SVM، شبکه عصبی عمیق (Deep Neural Networks)، شبکه عصبی بازگشتی (Recurrent Neural Networks)، حافظه طولانی کوتاه‌مدت (Long Short-Term Memory) و شبکه عصبی واحد بازگشتی دروازه‌دار (Gated Recurrent Units) را مقایسه کردند. نتایج این مطالعه نشان داد، مدل‌های SVM و LSTM در مقایسه با مدل‌های دیگر، عملکرد بهتری در پیش‌بینی غلظت رسوب معلق دارند. Nozari و Tavakoli (2018) برای پیش‌بینی بارش ماهانه در تغییرات اقلیم استان همدان، به مقایسه مدل‌های SVM، ARMAX، ARIMA و مدل ترکیبی ماشین بردار پشتیبان–تبدیل موجک (Wavelet - Support Vector Machines) پرداختند. نتایج این مطالعه نشان داد، مدل سنتی SVM پارامترهای قابل تنظیم کمتری دارد و با سهولت بیشتر و در زمان کمتری بارش ماهانه را پیش‌بینی می‌کند.

همچنین در مطالعه‌های بسیاری، اثر الگوریتم بهینه‌سازی تبرید (Simulated Annealing Algorithm) را بر دقت پیش‌بینی مدل SVM بررسی کردند. Mohammadi و Heidarpour (2019) برای تخمین دمای خاک، از الگوریتم شبیه‌سازی تبرید بر پایه ماشین بردار پشتیبان (SVM-SA) استفاده کردند. نتایج این مطالعه نشان داد، تلفیق SA و SVM باعث کمینه شدن خطای پیش‌بینی و بهبود نتایج شبیه‌سازی می‌شود. در مطالعه‌ای دیگر، Sedighkia و Datta (2023) برای طبقه‌بندی و شبیه‌سازی اثرات تولید نیروی برق آبی بر کیفیت زیستگاه پایین دست رودخانه تجن در ایران، از مدل SVM-SA استفاده کردند و نشان دادند، تنظیم پارامترهای مدل SVM با استفاده از الگوریتم SA، باعث کاهش اختلاف بین مقادیر پیش‌بینی شده و داده‌های مشاهده‌ای می‌شود. Mehrabani Bashar et al (2023) برای بررسی عوامل مؤثر بر مصرف آب شرب روستایی استان همدان، به مقایسه مدل‌های سیستم استنتاجی فازی عصبی (Adaptive Neuro-Fuzzy Inference System)، SVM-SA، ANFIS-GA و ANFIS ترکیب شده با الگوریتم بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization) پرداختند. نتایج این مطالعه نشان داد، مدل SVM-SA در مقایسه با سایر مدل‌های بررسی شده از دقت بیشتری برخوردار است. در مطالعه‌ای دیگر، Azadi et al (2022) برای برآورد بارندگی ایستگاه سینوپتیک گرگان از الگوریتم SVM-SA استفاده کردند. نتایج این مطالعه نشان داد، الگوریتم ترکیبی SVM-SA دقت بالایی در شبیه‌سازی تغییرات بارندگی دارد و به عنوان الگوریتم هیبریدی جدید در حوزه علوم و مهندسی معرفی می‌شود.

عدم قطعیت در پدیده‌ی رسوب‌گذاری، روابط غیرخطی و همچنین دسترسی به اطلاعات محدودی از فرسایش و رسوب انتقال یافته، باعث بروز اختلاف زیادی بین بار رسوبی مشاهده‌ای و برآوردهای صورت گرفته شده است. لذا تعیین روابط تجربی بین آبدهی و بار رسوبی نظیر، به‌عنوان راه حل جایگزین پیشنهاد می‌شود (Shojaeezadeh et al., 2018). درصورت وجود اندازه‌گیری‌های پیوسته و کافی در ایستگاه‌های هیدرولوژی و با برقراری رابطه بین دبی اندازه‌گیری شده و رسوب نظیر آن، می‌توان به سایر مقادیر بار رسوبی رسید. در این راستا، روش‌های محاسباتی نظیر منحنی‌های سنجه، جایگزین مناسبی برای اندازه‌گیری مستقیم بار رسوب معلق رودخانه هستند (Azadi et

Barzegari Bonadkohi و Armin (2016) خاصیت لگاریتمی محورها و عمل برون‌یابی برای برآورد بار رسوبی، خروجی منحنی سنجه را با اریب همراه می‌کند که سبب شده این روش به ازای مقادیر بالای آبدهی دچار کم‌برآورد شود و در مقادیر کم آبدهی نیز، بار رسوبی را بیش برآورد کند (Hapsari et al., 2019). محققان بسیاری در راستای بهبود عملکرد روش‌های محاسباتی، در پی اصلاح روابط آبدهی-رسوب بوده‌اند. Efthimiou (2019) پس از مقایسه منحنی سنجه کلاسیک، منحنی سنجه دوخطی، منحنی سنجه تفکیک شده بر اساس فصول تر و خشک سال و منحنی سنجه تفکیک شده بر اساس بازوی بالارونده و پایین‌رونده هیدروگراف سیلاب، نشان داد تخصیص دو خط مجزا برای برآورد بار رسوبی در منحنی سنجه، نسبت به سایر روش‌های بررسی شده از دقت بیشتری برخوردار است. Asadi et al (2021) برای بهینه‌سازی ضرایب مدل رگرسیونی منحنی سنجه، از الگوریتم‌های فراابتکاری GA، PSO، رقابت استعماری (Imperialist Competitive Algorithm) و روش‌های کلاسیک اصلاحی FAO و CF2 استفاده کردند. نتایج این مطالعه نشان داد، بهینه‌سازی ضرایب منحنی سنجه باعث بهبود عملکرد این روش می‌شود و الگوریتم‌های فراابتکاری نسبت به روش‌های اصلاحی کلاسیک موفق‌تر هستند. Barzegari Bonadkohi و Armin (2016) برای پیش‌بینی بار رسوب معلق رودخانه، مدل‌های سری زمانی مارکف و آریما را با روش‌های منحنی سنجه اصلاح شده مقایسه کردند. نتایج این مطالعه نشان داد، مدل‌های سری زمانی نسبت به روش‌های محاسباتی عملکرد بهتری داشتند و روش حد وسط دسته‌ها و ضریب MVUE به‌ترتیب به عنوان بهترین نوع منحنی سنجه و ضریب اصلاحی معرفی می‌شوند. در مطالعه‌ای دیگر، Varvani و Khalighi (2007) تأثیر ضرایب اصلاحی MVUE، CF1، CF2 و FAO را بر بهبود عملکرد منحنی سنجه مقایسه کردند. نتایج این مطالعه نشان داد، اصلاح منحنی سنجه با روش رسوب‌سنجی FAO، روش موفق‌تری برای محاسبه بار رسوب معلق رودخانه است.

با مروری بر مطالعه‌های انجام شده و با توجه به نقص آماری داده‌های بار رسوبی و هزینه بالای اندازه‌گیری مستقیم بار رسوبی، استفاده از روش‌های غیرمستقیم برای برآورد بار رسوب معلق رودخانه امری اجتناب ناپذیر است. از طرف دیگر، مطالعه‌های بسیاری به بهبود عملکرد روش‌های محاسباتی و مدل‌های هوش مصنوعی از طریق اصلاح روابط آبدهی-رسوب و به‌کارگیری الگوریتم‌های بهینه‌سازی تأکید کرده‌اند. از این رو در مطالعه‌ی حاضر، به مقایسه دو روش مختلف برای پیش‌بینی بار رسوب معلق رودخانه پرداخته شده است. در روش اول تأثیر الگوی وارد شده به مدل و نوع توزیع احتمالاتی داده‌ها، بر عملکرد مدل SVM بررسی می‌شود. در روش دوم نیز تأثیر روش بهینه‌سازی گرادیان کاهش‌یافته عمومی، بر عملکرد روش‌های محاسباتی رسوب‌سنجی اصلاحی FAO و منحنی سنجه بررسی می‌شود. در نهایت نتایج حاصل از برآورد مستقیم و غیرمستقیم بار رسوب معلق رودخانه مقایسه و بهترین روش برای برآورد بار رسوبی معرفی خواهد شد.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مطالعاتی پژوهش حاضر، ایستگاه هیدرومتری یلفان در محل رودخانه یلفان واقع در طول جغرافیایی "۴۱'۳۶°۴۸ و عرض جغرافیایی "۴۷'۳۴°۴۳ در استان همدان است. متوسط آبدهی و بار رسوبی سالانه ثبت شده در دوره ۱۳۹۴-۱۳۸۶ این ایستگاه به‌ترتیب برابر ۳/۰۳ مترمکعب بر ثانیه و ۸۹/۷۰ تن در ماه است. انحراف معیار آبدهی و بار رسوبی ثبت شده در دوره آماری مذکور نیز به‌ترتیب برابر ۶/۳۴ و ۸۹۱/۵۶ هستند. سری آبدهی و بار رسوبی مشاهداتی مورد مطالعه، در شکل (۱) ارائه شده‌اند. مساحت حوضه آبخیز یلفان ۷۱۷۳ هکتار است. حوضه آبخیز یلفان از زیرحوضه‌های سد اکباتان همدان و سد وفرقان ساوه است، که از شمال به حوضه آبخیز قره‌چای، از جنوب به حوضه آبخیز سد کرخه، از شرق به بخشی از حوضه آبخیز قره‌چای و از غرب به حوضه آبخیز گاماسیاب منتهی می‌شود (Nouri et al., 2019). در این مطالعه، از داده‌های بار رسوب معلق و آبدهی دوره ۱۳۹۴-۱۳۸۶ این ایستگاه که توسط سازمان آب منطقه‌ای استان همدان جمع آوری شده، استفاده شده است. موقعیت جغرافیایی منطقه مورد مطالعه، در شکل (۲) نمایش داده شده است.

مدل ماشین بردار پشتیبان (SVM)

مدل SVM یک سیستم یادگیری آماری است، که در یک طبقه‌بندی دودویی با انتخاب خط بهینه‌ای که بیشترین فاصله را با دو دسته دارد، داده‌ها را دسته‌بندی می‌کند (Üneş et al., 2021). SVM دارای دو مدل رگرسیونی نوع اول و رگرسیونی نوع دوم است که به‌ترتیب با SVM-v و SVM-ε نشان داده می‌شوند و نوع دوم دارای کاربرد بیشتری در مسائل رگرسیونی است (Hamel, 2009). در مسائل غیرخطی نیز تابع ریاضی کرنل، داده‌ها را به فضای با ابعاد بالاتر منتقل و آن‌ها را در فضای خطی جدید دسته‌بندی می‌کند. به‌کارگیری توابع کرنل باعث ساده‌تر شدن مدل و کاهش حداکثری خطای پیش‌بینی رابطه (۱) با درنظر گرفتن یکسری محدودیت‌ها رابطه (۲) می‌شود، که بر محبوبیت این مدل می‌افزاید (Deka, 2014).

$$\frac{1}{2}W^TW + C\sum_{i=1}^{N}\xi_i + C\sum_{i=1}^{N}\xi_i^* \qquad (۱)$$

$$\begin{aligned} &W^T\phi(x_i) + b - y_i \le \varepsilon + \xi_i^* \\ &y_i - W^T\phi(x_i) - b \le \varepsilon + \xi_i^* \\ &\xi_i^*, \xi_i \ge 0 \end{aligned} \qquad (۲)$$

DOI: 10.22055/jise.2024.44894.2096

که در این روابط C ثابت گنجایش، W بردار ضرایب، ξ_i و ξ_i^* ضرایب کمبود، b ضریب ثابت، N الگوهای آموزش مدل و Ø تابع کرنل هستند. در مدل SVM پس از وارد کردن داده‌ها، عملیات پردازش شروع می‌شود. سپس نوع تابع کرنل انتخاب و پارامترهای آن تنظیم می‌شوند. درنهایت آموزش مدل آغاز و خروجی‌ها تولید خواهند شد (Üneş et al., 2021). مراحل اجرای این مدل در شکل (۳) ارائه شده است. در مطالعه‌ی حاضر، عملکرد مدل SVM به ازای کرنل‌های چندجمله‌ای (Polynomial)، خطی (Linear) و تابع پایه شعاعی (RBF) مقایسه شد. معادله ریاضی کرنل‌های مورد بررسی، در جدول (۱) ارائه شده است. در این روابط x_i و x_j پارامترهای ورودی به مدل، d درجه چندجمله‌ای، C مقدار ثابت و γ عرض کرنل است که توسط کاربر تعیین می‌شود.

الگوریتم بهینه‌سازی تبرید (SA)

الگوریتم تبرید یک روش بهینه‌سازی فراابتکاری مبتنی بر مدل مونت کارلو است، که توسط Kirkpatrick et al (1983) معرفی شد. این الگوریتم یک روش جستجوی محلی است، که سعی بر به‌دست آوردن جواب بهینه عمومی دارد (Bahrami et al., 2016). اساس عملکرد این الگوریتم برگرفته از فرآیند تبرید یا آنیلینگ (Annealing) در علم متالوژی است. در علم مواد، تبرید یک عملیات حرارتی است که با هدف افزایش شکل‌پذیری و کاهش سختی ماده انجام می‌شود. طی این فرآیند، ابتدا فلز گرم شده، سپس دمای آن در یک درجه خاص ثابت می‌ماند و به تدریج سرد خواهد شد. با گرم کردن فلز، مولکول‌های آن آزادانه حرکت می‌کنند، اما با سردکردن تدریجی ماده، حرکت مولکول‌ها محدود می‌شود. اگر فرآیند سرد کردن به حدی کند باشد که از تعادل ترمودینامیکی ماده در هر مرحله اطمینان حاصل شود، انرژی گرمایی به‌طور یکنواختی در جسم توزیع می‌شود و ساختار بلوری ایجاد شده به بهترین شکل و به‌صورت مقاوم و متقارن خواهد بود. این کاهش دما و حرکت به سمت سرد شدن سیستم در رابطه‌ی (۳) نشان داده شده است.

$$T_i = \alpha \times (T_{i-1}), \qquad \forall_i = 1,\ldots,n \qquad (۳)$$

در این رابطه α ضریب تبرید است، که مقدار آن معمولاً بین ۰/۵ تا ۰/۹۹ درنظر گرفته میشود. T دمای سیستم و n تعداد دفعات کاهش سطح دما در سیستم هستند (Kirkpatrick et al., 1983).

عملکرد الگوریتم SA نیز در ابتدا با یافتن یک جواب اولیه آغاز می‌شود و با نوسانات زیادی به سمت جواب‌های همسایه پیش می‌رود، اما به تدریج دامنه تغییرات آن کاهش می‌یابد و در نهایت به سمت جواب بهینه همگرا می‌شود. این امر سبب شده تا SA برخلاف روش‌های بهینه‌سازی موضعی که فقط مقدار کمینه نزدیک به حدس اولیه را پیدا می‌کنند، قادر به ارائه مقدار کمینه مطلق باشد (Tran and Tran, 2007 ،Fabian, 1997).

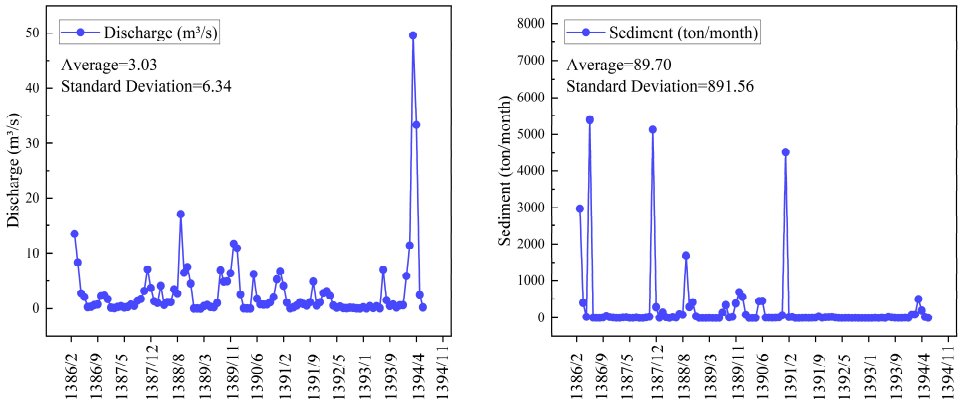


Fig. 1- Observational (a) discharge flow and (b) sediment time series of the Yalfaan station (2007-2015)

شکل ۱- (a) سری آبدهی و (b) بار رسوبی مشاهداتی ایستگاه یلفان (۱۳۹٤-۱۳۸٦)

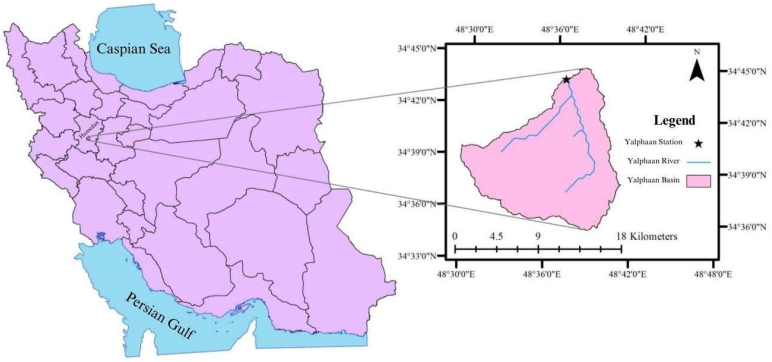


Fig. 2- Location of the study area
شکل ۲- موقعیت جغرافیایی منطقه مورد مطالعه

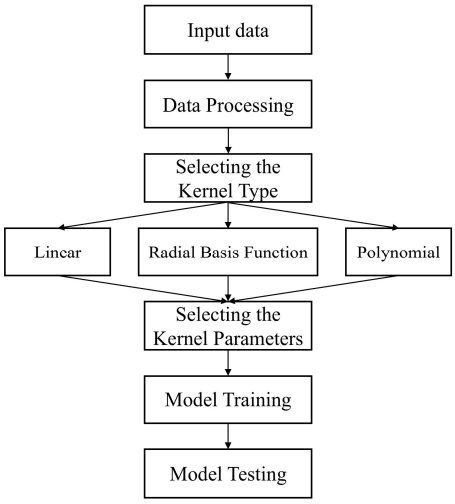


Fig. 3- Flowchart of the SVM model
شکل ۳- مراحل اجرای مدل SVM

جدول ۱- انواع توابع کرنل
Table 1- Types of kernel functions

Kernel	Formula	Optimisation parameter(s)
Linear	$K(x_i, x_j) = x_i . x_j$	-
RBF	$K(x_i, x_j) = exp(-\gamma \left\| x_i - x_j \right\|^2)$	γ
Polynomial	$K(x_i, x_j) = \left(\gamma \left(x_i . x_j\right) + C\right)^d$	γ,C,d

مدل SVM-SA

یکی از عوامل مؤثر بر عملکرد مدل‌های SVM، تنظیم پارامترهای طبقه‌بندی کننده آن‌ها است (Sedighkia and Datta, 2023). در جدول (۱) پارامترهای کنترل‌کننده و قابل تنظیم توسط کاربر برای هر یک از کرنل‌ها ارائه شده است. گاما (γ) که متناظر با نوع تابع کرنل است، بر تعداد بردارهای پشتیبان تأثیرگذار است. تعداد بردارهای پشتیبان، زمان آموزش مدل را تعیین می‌کنند و مقدار بیش از حد آن‌ها باعث بیش‌برازش مدل می‌شود. بنابراین تعیین این پارامتر به‌طور مستقیم عملکرد مدل SVM را

DOI: 10.22055/jise.2024.44894.2096

تحت تأثیر قرار می‌دهد. d درجه چندجمله‌ای و C نیز مقدار ثابت است (Sedighkia and Datta, 2023).

در مدل سنتی SVM، معمولاً پارامترها را با سعی و خطا تعیین می‌کنند، اما در مطالعه‌ی حاضر، برای انتخاب پارامترهای مذکور، از الگوریتم بهینه‌سازی SA استفاده شد. بدین منظور ابتدا مقدار اولیه پارامترها مطابق با مقادیر پیشنهادی مطالعه‌های پیشین، بر اساس ماهیت داده‌های ورودی و به‌صورت دستی تنظیم می‌شوند، سپس مقادیر بهینه آن‌ها با استفاده از الگوریتم SA محاسبه و برای تولید خروجی و اتمام مدل‌سازی، وارد مدل SVM خواهند شد (Mehrabani Bashar et al., 2023). بدین ترتیب مدل‌سازی از سعی و خطای مکرر بی‌نیاز و با سرعت و دقت بیشتری انجام می‌شود (Azadi et al., 2022).

منحنی سنجه

درون‌یابی و برون‌یابی، دو روش متداول برای محاسبه بار رسوب معلق رودخانه هستند، که نیازمند نمونه‌برداری منظم و پیوسته از ایستگاه‌های هیدرولوژی می‌باشند. از جمله روش‌های برونیابی مؤثر برای برآورد بار رسوبی، منحنی‌های سنجه هستند (Efthimiou, 2019). تنها متغیر مورد نیاز برای برآورد بار رسوبی با استفاده از منحنی سنجه، مقادیر دبی نظیر است، در حالی که در مدل‌های هیدرولیکی به اطلاعات ورودی زیادی نیاز است. Azadi et al (2020) برای برآورد بار رسوب معلق ماهانه حوضه آبیاکا (Abiaca Creek) طی دوره ۲۰۰۳-۱۹۹۱ از روش‌های مختلفی از جمله مدل‌سازی آماری، منحنی سنجه رسوب و روش تجزیه ضربی و جمع‌پذیر استفاده کردند، که دقت بالای نتایج منحنی سنجه رسوب را تأیید کردند. در منحنی سنجه، بار رسوب و دبی جریان در برابر هم و در یک محور مختصات تمام لگاریتمی ترسیم و خطی بر آن‌ها برازش داده می‌شود. از معادله این خط برای تکمیل سری زمانی بار رسوبی استفاده می‌شود، که Q_s بار رسوبی، Q_w دبی جریان و a و b ضرایب رگرسیون هستند.

$$Q_s = aQ_w^b \qquad (۴)$$

روش رسوب‌سنجی اصلاحی FAO

روش رسوب‌سنجی FAO، نسخه اصلاح شده معادله USBR است، که در آن شیب خط رگرسیونی منحنی سنجه ثابت فرض می‌شود (Javidan et al., 2022) و برای بهبود عملکرد منحنی سنجه یک خطی اعمال می‌گردد (Varvani and Khalighi, 2007). در این روش برای نزدیک کردن مقادیر بار رسوبی برآورد شده توسط منحنی سنجه به مقادیر مشاهده‌ای، ضریب آبدهی را اصلاح و از رابطه (۵) برای محاسبه بار رسوبی استفاده می‌شود:

$$Q_s = (\overline{Q}_S / \overline{Q}_w^{\ b})Q_w^b \qquad (۵)$$

که $\overline{Q}_S$ و $\overline{Q}_W$ به ترتیب مقادیر بار رسوبی متوسط و آبدهی متوسط هستند.

گرادیان کاهش‌یافته عمومی (GRG)

روش گرادیان کاهش یافته عمومی یک روش بهینه‌سازی غیرخطی است، که با یک رویکرد تکرارشونده به مقدار بهینه مسئله نزدیک می‌شود. در این روش، تابع هدف یا هر یک از قیود می‌توانند خطی یا غیرخطی باشند. GRG ابتدا محدودیت‌های تابع هدف را خطی می‌کند، سپس با تکرار روش بهینه‌سازی خطی به جواب بهینه مسئله می‌رسد (Hatami et al., 2020). در مطالعه حاضر، ضرایب متغیرها در روابط آبدهی-رسوب (روش‌های رسوب‌سنجی اصلاحی FAO و منحنی سنجه)، به‌عنوان متغیرهای تصمیم درنظر گرفته شدند و تابع هدف نیز حداقل‌سازی اختلاف بین رسوب برآورد شده و داده‌های مشاهده‌ای است. تابع هدف مطالعه‌ی حاضر، در رابطه (۶) ارائه شده و محدودیت اعمال شده برای آن نیز مثبت بودن مقادیر داده‌ها است.

$$Minf = \sum_{i=1}^{n} \left| X_{i_{obs}} - X_{i_{sim}} \right| \qquad (۶)$$

در این رابطه n، $X_{i_{obs}}$ و $X_{i_{sim}}$ به‌ترتیب تعداد داده‌ها، داده‌های مشاهداتی و داده‌های شبیه‌سازی شده هستند.

ارزیابی عملکرد مدل

برای ارزیابی کارایی و دقت مدل‌های مورد استفاده در مطالعه حاضر، از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE)، خطای استاندارد (SE)، اریب متوسط (MBIAS) و ضریب تعیین (R^2) استفاده شد.

$$RMSE = \frac{\sqrt{\sum_{i=1}^{n} \left(X_{i_{obs}} - X_{i_{sim}} \right)^2}}{n} \qquad (۷)$$

$$SE = \frac{RMSE}{\overline{X}_{obs}} \qquad (۸)$$

$$\mathrm{MBIAS} = \frac{\sum_{i=1}^{n} (X_{i_{obs}} - X_{i_{sim}})}{n} \qquad (۹)$$

$$R^2 = \frac{\left[\sum_{i=1}^{n} (X_{i_{obs}} - \overline{X}_{obs})(X_{i_{sim}} - \overline{X}_{sim}) \right]^2}{\sum_{i=1}^{n} (X_{i_{obs}} - \overline{X}_{obs})^2 . \sum_{i=1}^{n} (X_{sim} - \overline{X}_{sim})^2} \qquad (۱۰)$$

که در این روابط، $X_{i_{obs}}$ و $X_{i_{sim}}$ به‌ترتیب داده‌های مشاهداتی و شبیه‌سازی شده، $\overline{X}_{obs}$ و $\overline{X}_{sim}$ به‌ترتیب میانگین داده‌های مشاهداتی و میانگین داده‌های شبیه‌سازی شده و n تعداد داده‌ها هستند.

نتایج و بحث

در این مطالعه برای پیش‌بینی بار رسوب معلق ماهانه ایستگاه هیدرومتری یلفان، از سری زمانی آبدهی و بار رسوبی این ایستگاه طی ۱۳۹۴-۱۳۸۶ استفاده شد. متوسط آبدهی و بار رسوبی سالانه ثبت شده در این دوره ایستگاه به‌ترتیب برابر ۳/۰۳ مترمکعب و ۸۹/۷۰ هزار تن در سال است. انحراف معیار آبدهی و بار رسوبی ثبت شده در دوره آماری مذکور نیز به‌ترتیب برابر ۶/۳۴ و ۸۹۱/۵۶ هستند. از مجموع ۱۰۶ داده به‌کار رفته در هر سری، تعداد ۷۴ داده (۷۰ درصد) به‌صورت تصادفی برای واسنجی و ۳۲ داده (۳۰ درصد) برای صحت‌سنجی نتایج مدل‌ها درنظر گرفته شدند. بدین منظور از مدل تلفیقی ماشین بردار پشتیبان-الگوریتم تبرید (SVM-SA)، منحنی سنجه و روش رسوب‌سنجی اصلاحی FAO استفاده گردید.

به منظور پیش‌بینی بار رسوبی توسط مدل SVM-SA، از مدل تهیه شده در نرم‌افزار متلب استفاده شد و عملکرد این مدل، قبل و بعد از نرمال‌سازی داده‌ها و به ازای الگوهای تک ورودی-تک خروجی (SISO) و چند ورودی-تک خروجی (MISO) مقایسه شد. با توجه به اینکه آمار و اطلاعات آبدهی و بار رسوبی ایستگاه مورد بررسی در این تحقیق، به‌صورت پیوسته و منظم برداشت نشده و داده‌های روزانه با تعداد محدود و با فواصل زمانی پراکنده برداشت شده است. بنابراین امکان تعیین ساختارهای متفاوت از ورودی و ایجاد تأخیر یک و یا چند روزه در ورودی‌ها وجود ندارد. لذا داده‌ها بدون تأخیر زمانی و به‌صورت هم‌زمان وارد مدل شدند. متغیرهای ورودی، خروجی و مقدار بهینه پارامترهای مدل SVM در جدول (۲) ارائه شده است. نرمال‌سازی داده‌ها از طریق عمل لگاریتم‌گیری صورت گرفت. همچنین مقادیر آبدهی در سه بازه‌ی $x < 0.36$، $0.36 < x < 1.31$ و $x > 1.31$، تفکیک شدند و به‌ترتیب اعداد ۱، ۲ و ۳ به هر یک از بازه‌ها نسبت داده شد و به‌عنوان ورودی دوم برای آموزش مدل به‌کار رفت. عملکرد مدل SVM به ازای کرنل‌های RBF، خطی و چندگانه بررسی و نتایج مقایسه شدند. همچنین تعیین پارامترهای کنترل‌کننده مدل نیز از طریق به‌کارگیری الگوریتم بهینه‌سازی SA صورت گرفت. در شکل (۴) نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای بخش آزمون مدل SVM-SA به ازای حالت‌های مذکور مقایسه شده اند. از میان کرنل‌های بررسی شده برای مدل SVM، کرنل RBF، کرنل خطی و کرنل چندجمله‌ای به‌ترتیب در رتبه‌های اول تا سوم قرار گرفتند و این نتیجه به ازای الگوهای SISO، MISO، داده‌های اصلی و داده‌های نرمال شده نیز تکرار شد. در مطالعه حاضر، جدول و اشکال ارائه شده برای مدل SVM، نتایج مبتنی بر RBF هستند و از تکرار آن‌ها برای سایر کرنل‌ها صرف نظر شده است. شکل (۵) نیز عملکرد این مدل را به ازای داده‌های نرمال شده نشان می‌دهد. اصلاح الگوی داده‌های وارد شده به مدل از حالت SISO به MISO باعث بهبود نتایج مدل‌سازی به ازای هر دو سری اصلی و نرمال شده گردید. نرمال‌سازی داده‌ها نیز باعث بهبود عملکرد مدل در هر دو الگوی SISO و MISO شد. از میان تمام حالت‌های بررسی شده، مدل SVM-SA با الگوی چند ورودی-تک خروجی نرمال شده، عملکرد بهتری داشته و برای پیش‌بینی بار رسوب معلق رودخانه پیشنهاد می‌گردد.

شکل (۶) توزیع خطای مدل در روش‌های مذکور را نشان می دهد. ملاحظه می‌شود که احتمال اینکه مقادیر خطا به صفر نزدیک باشند در روش الگوی چند ورودی-تک خروجی نرمال شده، بیشتر است. همچنین توزیع این خطا به نرمال نزدیکتر است.

تجزیه و تحلیل عدم قطعیت مدل‌ها و تشخیص ویژگی‌های آماری خروجی مدل براساس روابط موجود بین پارامترها و ورودی‌های مدل از مهم‌ترین موارد مدل‌سازی در هیدرولوژی به‌شمار می‌آید. لذا مدل‌های مورد نظر در این تحقیق ۲۰ مرتبه اجرا شدند و عدم قطعیت نتایج حاصل از اجراهای مختلف هر یک از مدل‌ها محاسبه شدند. با توجه به برتری نتایج مدل مبتنی بر کرنل RBF نسبت به سایر کرنل‌ها، عدم قطعیت SVM مبتنی بر کرنل RBF به ازای الگوهای مختلف در شکل (۷) نشان داده شده است. ملاحظه می‌شود که در تکرارهای مختلف SVM با الگوهای SISO، SISO نرمال شده و MISO نرمال شده، نتایج مدل مشابه و فاقد عدم قطعیت می‌باشد و بیشترین عدم قطعیت در نتایج مربوط به الگوی MISO می‌باشد.

از آنجا که همبستگی مناسبی بین بار رسوب معلق و آبدهی نظیر وجود دارد، برای برآورد غیرمستقیم بار رسوب معلق رودخانه، از منحنی سنجه استفاده شد. بدین منظور ۷۰ درصد از مقادیر آبدهی به‌ترتیب صعودی مرتب و در برابر بار رسوبی نظیر، و در محورهای تمام لگاریتمی ترسیم شدند. در نهایت از معادله خط توانی برازش داده شده بر این نقاط، برای تکمیل ۳۰ درصد باقی مانده سری زمانی رسوب استفاده شد. در شکل (۸)، منحنی سنجه ایستگاه هیدرومتری یلفان ارائه شده است. در مقادیر پایین دبی، اختلاف داده‌های مشاهده‌ای و مقادیر برازش داده شده کم است، اما با افزایش دبی رودخانه، این اختلاف نیز افزایش می‌یابد، که ناشی از خاصیت لگاریتمی محورهای منحنی سنجه است (Azadi et al., 2020). در همین راستا با ایجاد یک شکست در نقطه‌ی دبی متوسط، داده‌ها به دو قسمت تقسیم می‌شوند و با برازش دو خط مجزا، تخمین بار رسوبی با دقت بیشتری انجام خواهد شد.

جدول ۲- متغیرهای ورودی، خروجی و مقادیر بهینه پارامترهای مدل SVM

Table 2- Inputs, outputs, and Optimized parameter(s) of the SVM model

Model	Optimized parameter(s)			Inputs	Outputs
	Linear	RBF	Polynomial		
SVM-SA (SISO)	-	$\gamma = 2.92$	$\gamma = 0.0009$ $C = 42.77$ $d = 3$	Discharge flow	Sediment load
SVM-SA (MISO)	-	$\gamma = 0.97$	$\gamma = 0.0048$ $C = 2.18$ $d = 3$	Discharge flow	Sediment load
SVM-SA (SISO) – Normalized	-	$\gamma = 8.37$	$\gamma = 5000.5$ $C = 8.81$ $d = 5$	Normalized Discharge flow	Normalized Sediment load
SVM-SA (MISO) – Normalized	-	$\gamma = 28.69$	$\gamma = 0.00002$ $C = 53.4$ $d = 3$	Normalized Discharge flow	Normalized Sediment load

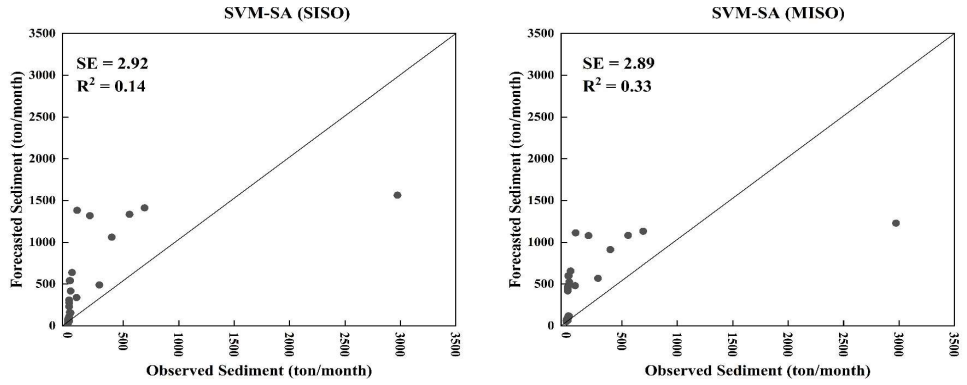


Fig. 4- Distribution of the computational-observational data for the SVM-SA's test part

شکل ٤- نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای بخش آزمون مدل SVM-SA

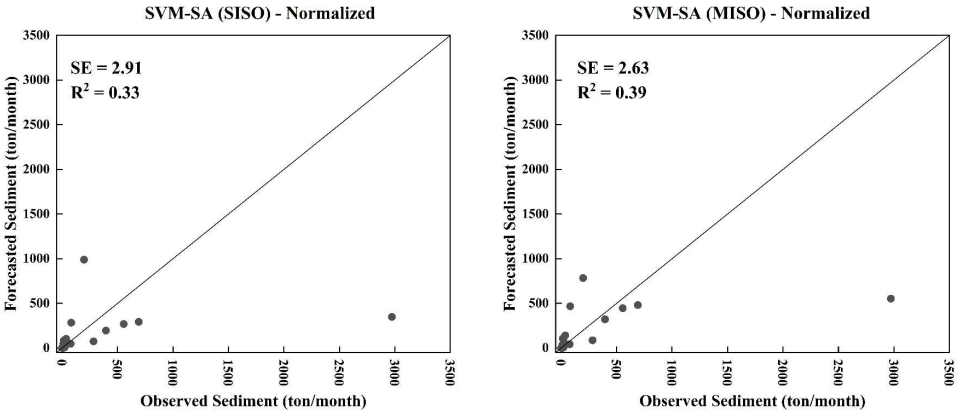


Fig. 5- Distribution of the computational-observational data for the normalized SVM-SA's test part

شکل ٥- نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای بخش آزمون مدل SVM-SA نرمال شده

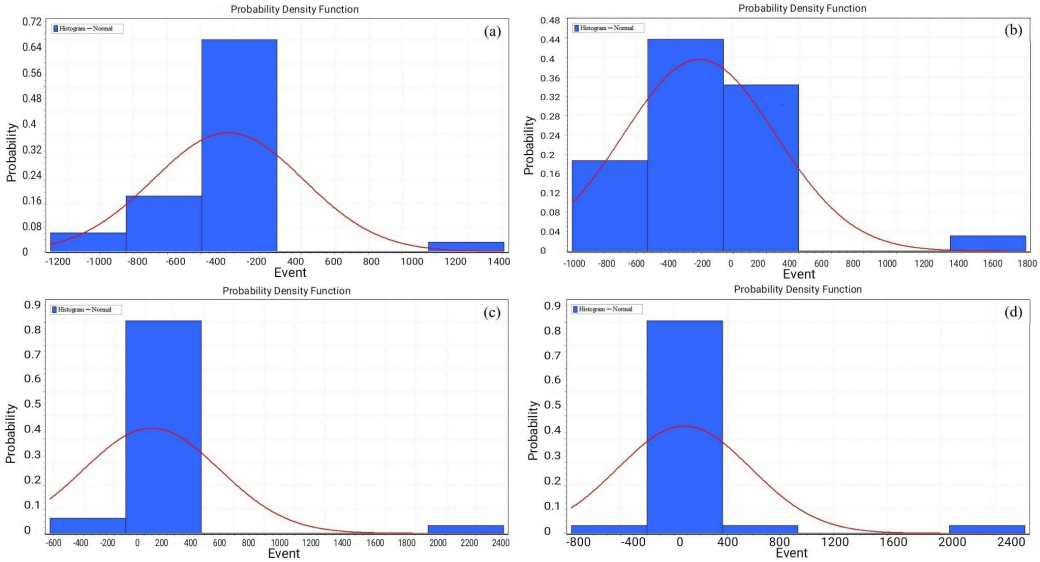


Fig. 6- Error distribution of SVM-SA model based on (a) SISO, (b) MISO, (c) normalized SISO and (d) normalized MISO patterns in sediment load simulation

شکل ٦- توزیع خطای مدل SVM-SA مبتنی بر الگوهای (a) SISO، (b) MISO، (C) SISO نرمال شده و (d) MISO نرمال شده در شبیه‌سازی بار رسوبی

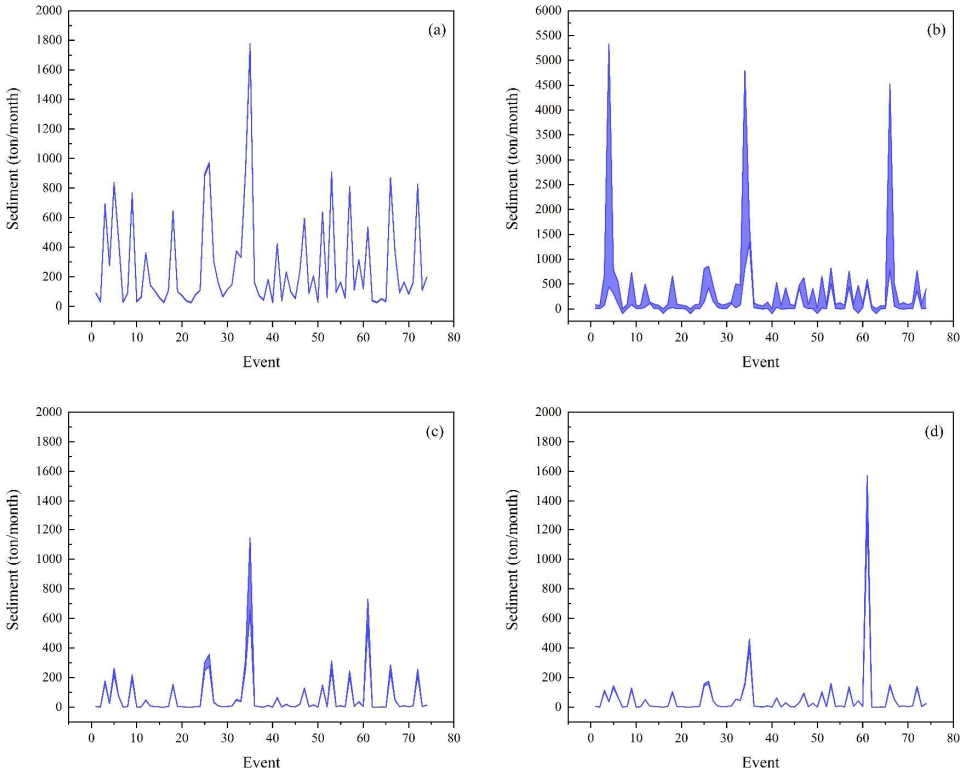


Fig. 7- Uncertainty of SVM-SA model based on (a) SISO, (b) MISO, (c) normalized SISO and (d) normalized MISO patterns in sediment load simulation

شکل ۷- عدم قطعیت مدل SVM-SA مبتنی بر الگوهای (a) SISO، (b) MISO، (C) SISO نرمال شده و (d) MISO نرمال شده در شبیه‌سازی بار رسوبی

DOI: 10.22055/jise.2024.44894.2096

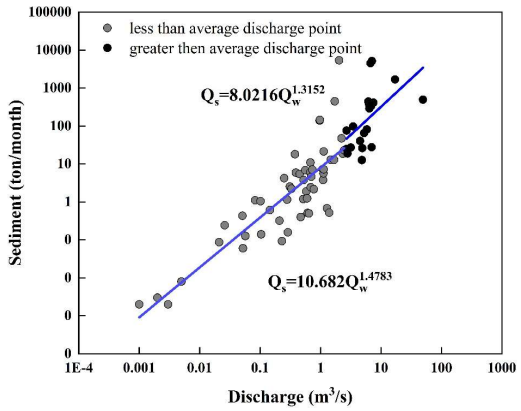


Fig. 8- Sediment rating curve for the Yalphan hydrometric station

شکل ۸- منحنی سنجه ایستگاه هیدرومتری یلفان

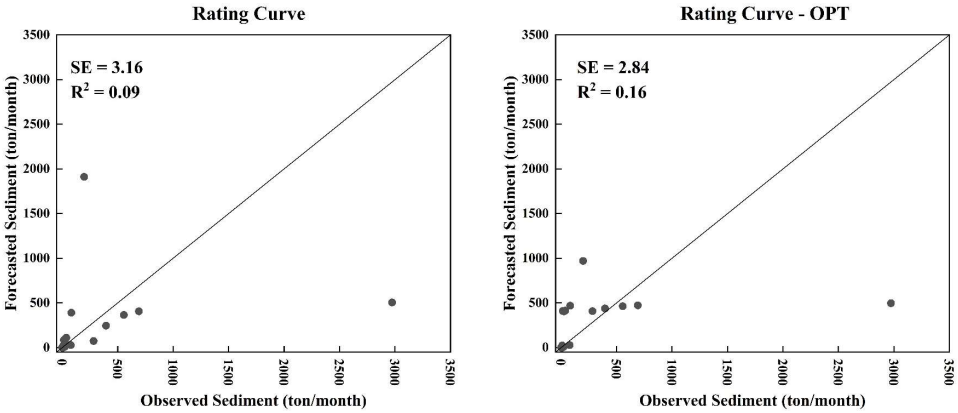


Fig. 9- Distribution of the computational-observational data for the sediment rating curve

شکل ۹- نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای روش منحنی سنجه

در این مطالعه، ضرایب متغیرهای معادله آبدهی-رسوب با استفاده از الگوریتم بهینه‌سازی گرادیان کاهش‌یافته عمومی (GRG) انتخاب شد. تابع هدف در بهینه‌سازی مذکور، حداقل‌سازی اختلاف بین رسوب برآورد شده و داده‌های مشاهده‌ای است و متغیرهای تصمیم نیز ضرایب متغیرهای این رابطه هستند.

در شکل (۹) نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای روش منحنی سنجه قبل و بعد از بهینه‌سازی مقایسه شده اند. انتخاب ضرایب متغیرهای معادله آبدهی-رسوب با استفاده از الگوریتم بهینه‌سازی GRG، باعث بهبود عملکرد منحنی سنجه در برآورد بار رسوب معلق رودخانه شد.

در این تحقیق، روش رسوب‌سنجی FAO نیز برای اصلاح رابطه آبدهی-رسوب و بهبود عملکرد منحنی سنجه بکار گرفته شد (شکل ۱۰). همچنین ضرایب متغیرها در معادله آبدهی-رسوب این روش، با استفاده از روش گرادیان کاهش‌یافته عمومی انتخاب شدند. تابع هدف در بهینه‌سازی مذکور، حداقل‌سازی اختلاف بین رسوب برآورد شده و داده‌های مشاهده‌ای است و متغیرهای تصمیم نیز ضرایب متغیرهای این رابطه هستند. در شکل (۱۱) نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای روش رسوب‌سنجی اصلاحی FAO قبل و بعد از بهینه‌سازی ضرایب مقایسه شده اند. انتخاب ضرایب متغیرهای معادله آبدهی-رسوب با استفاده از الگوریتم GRG، باعث بهبود قابل ملاحظه‌ای در عملکرد روش رسوب‌سنجی FAO و کاهش ۷۳/۱۹ درصدی شاخص خطای استاندارد (SE) شد.

دیاگرام تیلور ارائه شده در شکل (۱۲)، عملکرد مدل‌ها را قبل و بعد از بهینه‌سازی نشان می‌دهد. در این شکل، اختلاف خطی بین بار رسوبی مشاهداتی و مقادیر برآورد شده، توسط شاخص RMSE و با خطچین آبی مشخص شده است. تمامی روش‌ها به جز روش رسوب‌سنجی FAO، از عملکرد مشابهی برخوردارند و در محدوده‌ی RMSE=500 قرار گرفته‌اند. بهینه‌سازی روش FAO با استفاده از گرادیان کاهش یافته عمومی، باعث بهبود قابل ملاحظه‌ای در عملکرد این مدل شده است. مدل SVM-SA مبتنی بر الگوی چند ورودی-تک خروجی نرمال شده، نسبت به سایر روش‌ها دارای کمترین RMSE و بیشترین همبستگی است و از طرف دیگر به مقادیر مشاهداتی نیز نزدیک‌تر است، که نشان دهنده برتری این مدل نسبت به سایر مدل‌ها می‌باشد.

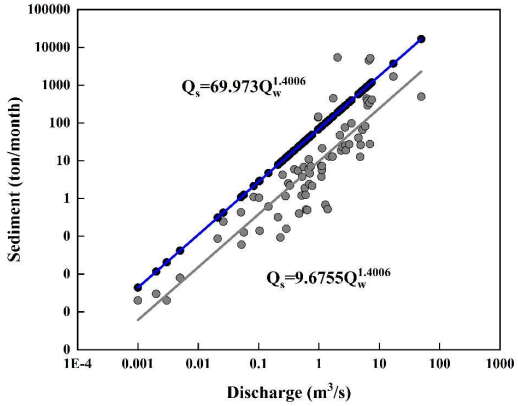


Fig. 10- The modified rating curve using FAO method for the Yalphan hydrometric station

شکل ۱۰- منحنی سنجه اصلاح شده با روش رسوب‌سنجی FAO برای ایستگاه هیدرومتری یلفان

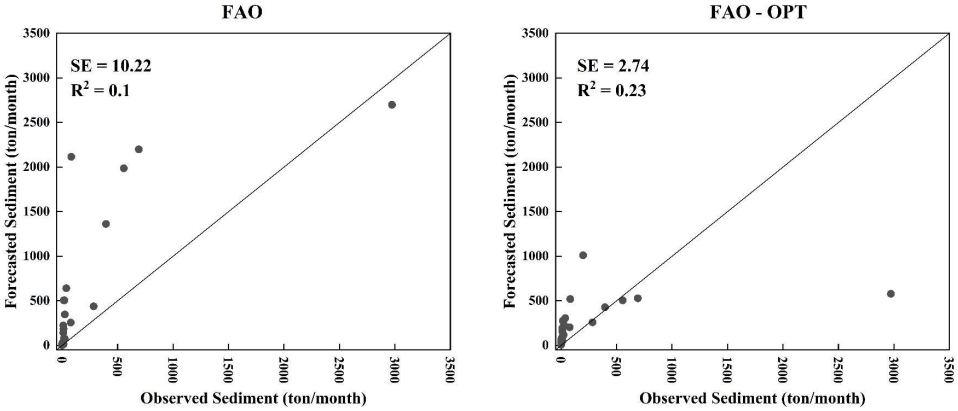


Fig. 11- Distribution of the computational-observational data for the FAO method

شکل ۱۱- نمودار پراکنش داده‌های محاسباتی-مشاهداتی برای روش رسوب‌سنجی اصلاحی FAO

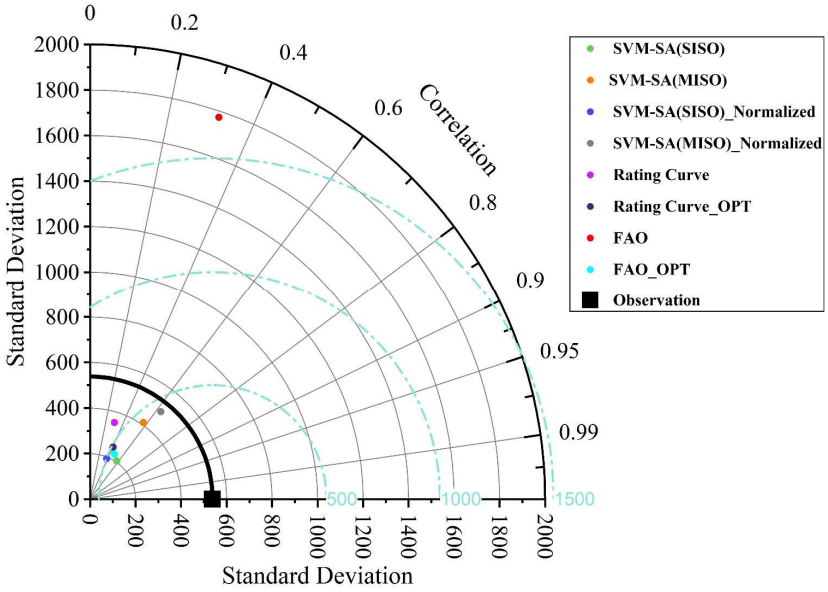


Fig. 12- Taylor diagram for the performance of the sediment load estimation methods

شکل ۱۲- دیاگرام تیلور عملکرد روش‌های برآورد بار رسوبی

 DOI: 10.22055/jise.2024.44894.2096

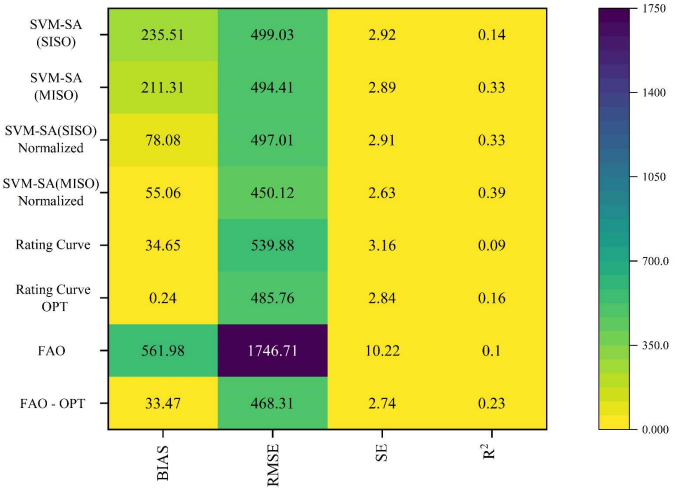


Fig. 13- Values of statistical indices in estimating the monthly sediment load by various models

شکل ۱۳- مقادیر شاخص‌های آماری در برآورد بار رسوبی ماهانه به تفکیک مدل‌ها

در شکل (۱۳) عملکرد مدل‌های مورد مطالعه، در قالب نمودار حرارتی مقایسه شده است. در این نمودار، مدل‌ها در محورهای افقی و شاخص‌های آماری نیز در محورهای عمودی ارائه شده اند. مقدار شاخص‌های آماری هر مدل نیز در سلول نظیر قرار گرفته است. با توجه به این شکل، بهترین مدل برای برآورد بار رسوبی ماهانه ایستگاه یلفان، مدل SVM-SA (MISO)-N با SE=2.63، RMSE=450.12، BIAS=55.06 و R^2=0.39 است، که تأییدی بر نتایج دیاگرام تیلور می‌باشد. مدل‌های FAO-OPT، Rating Curve-OPT، SVM-SA (MISO)، SVM-SA (SISO)-N، Rating Curve و FAO نیز به ترتیب در رتبه‌های دوم تا هفتم قرار گرفتند. نتایج حاکی از تأثیر مثبت الگوریتم بهینه‌سازی GRG بر عملکرد روش‌های محاسباتی است. همچنین نرمال‌سازی داده‌های ورودی به مدل SVM-SA باعث بهبود عملکرد این مدل در هر دو الگوی SISO و MISO شد. در این مطالعه، ضرایب متغیرهای معادله آبدهی–رسوب با استفاده از الگوریتم بهینه‌سازی گرادیان کاهش‌یافته عمومی (GRG) انتخاب شد. تابع هدف در بهینه‌سازی مذکور، حداقل‌سازی اختلاف بین رسوب برآورد شده و داده‌های مشاهده‌ای است و متغیرهای تصمیم نیز ضرایب متغیرهای این رابطه هستند.

نتیجه‌گیری

تحقیق حاضر با هدف بررسی تأثیر نوع توزیع احتمالاتی، نوع کرنل انتخابی و الگوی داده‌های ورودی بر عملکرد مدل SVM-SA و همچنین بهبود روش‌های محاسباتی برآورد بار رسوبی از طریق بهینه‌سازی ضرایب معادله‌ها، انجام شده است. بدین منظور از دو روش مختلف برای پیش‌بینی بار رسوب معلق ایستگاه هیدرومتری یلفان استفاده شد. در روش اول تأثیر الگوی وارد شده به مدل، نوع کرنل و نوع توزیع احتمالاتی داده‌ها، بر عملکرد مدل SVM-SA بررسی شد. نتایج نشان داد، تفکیک داده‌های مشاهداتی و اصلاح الگوی داده‌های وارد شده به این مدل از حالت SISO به MISO باعث بهبود نتایج مدل‌سازی به ازای هر دو سری اصلی و نرمال شده گردید. همچنین نرمال‌سازی داده‌ها با استفاده از عمل لگاریتم‌گیری، باعث بهبود عملکرد این مدل در هر دو الگوی SISO و MISO شد. از میان کرنل‌های بررسی شده برای مدل SVM نیز، RBF، کرنل خطی و کرنل چندجمله‌ای به ترتیب در رتبه‌های اول تا سوم قرار گرفتند و این نتیجه به ازای الگوهای SISO، MISO، داده‌های اصلی و داده‌های نرمال شده نیز تکرار شد. در روش دوم نیز تأثیر روش بهینه‌سازی گرادیان کاهش‌یافته عمومی، بر عملکرد روش‌های محاسباتی رسوب‌سنجی اصلاحی FAO و منحنی سنجه مورد بررسی قرار گرفت. نتایج نشان داد، انتخاب ضرایب متغیرهای معادله آبدهی–رسوب با استفاده از الگوریتم بهینه‌سازی GRG، باعث بهبود قابل توجهی در عملکرد روش‌های محاسباتی مذکور در برآورد بار رسوب معلق رودخانه می‌شود و این دو روش را به روش‌های مؤثر و قابل رقابت با روش‌های پیش‌بینی مستقیم بار رسوبی تبدیل کرده است. از میان روش‌های بررسی شده، مدل SVM-SA مبتنی بر الگوی چند ورودی–تک خروجی نرمال شده، به عنوان بهترین روش معرفی و برای پیش‌بینی بار رسوب معلق رودخانه پیشنهاد می‌گردد.

تشکر و قدردانی

مطالعه‌ی حاضر با حمایت مالی کمیته تحقیقات شرکت سهامی آب منطقه‌ای استان همدان انجام شده است و نویسندگان از این طریق مراتب تقدیر و تشکر خود را اعلام می‌دارند. همچنین از دانشگاه بوعلی سینا همدان برای در اختیار قرار دادن امکانات جهت انجام این پژوهش تشکر و قدردانی می شود.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ گونه تضاد منافعی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

منابع مالی

مطالعه‌ی حاضر با حمایت مالی کمیته تحقیقات شرکت سهامی آب منطقه‌ای استان همدان انجام شده است.

دسترسی به داده‌ها

مجموعه داده‌های تولید شده و یا تحلیل شده در طول مطالعه حاضر، در صورت درخواست معقول، از نویسنده مسئول در دسترس هستند.

مشارکت نویسندگان

نویسنده اول: حامد نوذری، مسئول برنامه‌ریزی پروژه، توسعه ایده‌های مفهومی اصلی و تجزیه و تحلیل داده‌ها

نویسنده دوم: فاطمه چدنی، انجام محاسبات، بررسی نتایج تجزیه و تحلیل داده ها و نوشتن نسخه ی خطی مقاله

نویسنده سوم: مهدی کلانتری، توسعه ایده‌های مفهومی اصلی، ایجاد چارچوب محاسباتی

نویسنده چهارم: علیرضا مهربانی بشار، انجام محاسبات، بررسی نتایج تجزیه و تحلیل داده ها و نوشتن نسخه ی خطی مقاله

References

1- AlDahoul, N., Essam, Y., Kumar, P., Ahmed, A. N., Sherif, M., Sefelnasr, A., and Elshafie, A. 2021. Suspended sediment load prediction using long short-term memory neural network. *Scientific Reports*, 11(1): 1-22. DOI: 10.1038/s41598-021-87415-4.

2- Asadi, H., Dastorani, M.T., Sidle, R.C., and Shahedi, K. 2021. Improving Flow Discharge-Suspended Sediment Relations: Intelligent Algorithms versus Data Separation. *Water* 13(24):3650. DOI: 10.3390/w13243650.

3- Azadi, S., Nozari, H., and Godarzi, E. 2020. Predicting sediment load using stochastic model and rating curves in a hydrological station. *Journal of Hydrologic Engineering*, 25(8): 05020017. DOI: 10.1061/(ASCE)HE.1943-5584.0001967.

4- Azadi, S., Vafaee, M., and Nozari, H. 2022. Estimation of precipitation using the combined method of Support Vector Machine-Simulated Annealing algorithm (case study: Gorgan synoptic station). *Advanced Technologies in Water Efficiency*, 2(3), 14-34. (In Persian). DOI: 10.22126/ATWE.2022.8393.1028.

5- Ba, H., Guo, S., Wang, Y., Hong, X., Zhong, Y., and Liu, Z. 2018. Improving ANN model performance in runoff forecasting by adding soil moisture input and using data preprocessing techniques. *Hydrology Research*, 49(3): 744-760. DOI: 10.2166/nh.2017.048.

6- Bahrami, S., Ardejani, F. D., and Baafi, E. 2016. Application of artificial neural network coupled with genetic algorithm and simulated annealing to solve groundwater inflow problem to an advancing open pit mine. *Journal of Hydrology*, 536, 471-484. DOI: 10.1016/j.jhydrol.2016.03.002.

7- Barzegari Banadkoki, F., and Armin, M. 2016. Suspended sediment prediction using time series and sediment rating curve (Case study: Ghazaghly station in Gorganroud River). *Iranian Journal of Watershed Management Science and Engineering*, 9(31), 77-88. (In Persian).

8- Cortes, C., and Vapnik, V. 1995. Support-vector networks. *Mach Learn* 20, 273–297. DOI: 10.1007/BF00994018.

9- Deka, P. C. 2014. Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing*, 19,372-386. DOI: 10.1016/j.asoc.2014.02.002.

10-Efthimiou, N. 2019. The role of sediment rating curve development methodology on river load modeling. *Environmental Monitoring and Assessment*, 191(2), 108. DOI: 10.1007/s10661-018-7167-4.

11-Fabian, V. 1997. Simulated Annealing Simulated. *Computers & Mathematics with Applications*, 33, 81-94. DOI: 10.1016/S0898-1221(96)00221-0.

12-Hamel, L. 2009. Knowledge Discovery with Support Vector Machines. John Wiley, Hoboken, NJ, USA. DOI: 10.1002/9780470503065.

13-Hapsari, D., Onishi, T., Imaizumi, F., Noda, K., and Senge, M. 2019. The Use of Sediment Rating Curve under its Limitations to Estimate the Suspended Load. *Reviews in Agricultural Science.* 7: 88-101. DOI: 10.7831/ras.7.0_88.

14-Hatami, S., Banihabib, M.E., and Soltani, J. 2020. Determination of Optimal Operation Policy of Reservior with Nonlinear Model to Reduce Reservoir Water Losses. *Iranian journal of Ecohydrology*, 7(1), pp. 277-290. (In Persian). DOI: 10.22059/ije.2020.295631.1266.

15-Huang, C. C., Chang, M. J., Lin, G. F., Wu, M. C., and Wang, P. H. 2021. Real-Time forecasting of suspended sediment concentrations reservoirs by the optimal integration of multiple machine learning techniques. *Journal of Hydrology*, 34: 100804. DOI: 10.1016/j.ejrh.2021.100804.

16-Javidan, S., Sattari, M. T., Karimzadeh, P., and Mehrabi, A. 2022. Performance Analysis of Hydrological and Data-Based Models in Estimation of Suspended Sediment Rate. *Environment and Water Engineering*, 8(2): 468-480. DOI: 10.22034/jewe.2021.305599.1632.

17-Kirkpatrick, S., Gelatt, C., D., and Vecchi, M., P. 1983. Optimization by simulated annealing. *Science*, 220, 671–680. DOI: 10.1126/science.220.4598.671.

18-Lin, J. Y., Cheng, C. T., and Chau, K. W. 2006. Using support vector machines for long-term discharge prediction. *Hydrological Sciences Journal*, 51(4), 599-612. DOI: 10.1623/hysj.51.4.599.

19-Mehrabani Bashar, A., Nozari, H., Marofi, S., Mohamadi, M., and Ahadiiman, A. 2023. Investigation of factors affecting rural drinking water consumption using intelligent hybrid models. *Water Science and Engineering*, 16(2), 175-183. DOI: 10.1016/j.wse.2022.12.002.

20-Mohammadi, B., and Heidarpour, B. 2019. Effect of climatic parameters on soil temperature estimation by hybrid refrigeration simulation algorithm. *Nivar*, 43((104-105), pp. 1-12. (In Persian). DOI: 10.30467/nivar.2019.83519.

21-Nouri, H., Ildoromi, A., Sepehri, M., and Artimani, M. 2019. Comparing Three Main Methods of Artificial Intelligence in Flood Estimation in Yalphan Catchment. *Geography and Environmental Planning*, 29(4), pp. 35-50. (In Persian). DOI: 10.22108/gep.2018.98036.0.

22-Nozari, H., and Tavakoli, F. 2018. Evaluation of the Efficiency of Linear and Nonlinear Models in Predicting Monthly Rainfall (Case Study: Hamedan Province). *Journal of Watershed Management Research*, 10(20): 1-12. (In Persian). DOI: 10.29252/jwmr.10.20.1.

23-Ramezanipour, E., Mosaedi, A., and Mesdaghi, M. 2017. Determination of the Best Model for Estimation of Suspended Sediment by using Statistical Error Criteria (Case Stude: Some Sub-Watersheds of Kashafroud). *Journal of Watershed Management Research*, 8(15): 112-124. (In Persian). DOI: 10.29252/jwmr.8.15.112.

24-Samantary, S., Sahoo, A., and Ghose, D. K. 2020. Assessment of Sediment Load Concentration Using SVM, SVM-FFA and PSR-SVM-FFA in Air Watershed, India: A Case Study. *KSCE Journal of Civil Engineering*, 24, 1944-1957. DOI: 10.1007/s12205-020-1889-x.

25-Sedighkia, M., and Datta, B. 2023. Linking SVM based habitat model and evolutionary optimization for managing environmental impacts of hydropower plants. *River Research and Applications*, 39, 897-910. DOI: 10.1002/rra.4121.

26-Shojaeezadeh, S. A., Nikoo, M. R., McNamara, J. P., AghaKouchak, A., and Sadegh, M. 2018. Stochastic modeling of suspended sediment load in alluvial rivers. *Advances in Water Resources, 119*: 188–196. DOI: 10.1016/j.advwatres.2018.06.006.

27-Tran, N. H., and Tran, K. 2007. Combination of fuzzy ranking and simulated annealing to improve discrete fracture inversion. *Mathematical and Computer Modeling*, 45(7-8), 1010-1020. DOI: 10.1016/j.mcm.2006.08.013.

28-Üneş, F., Taşar, B., Demirci, M., Zelenakova, M., Kaya, Y. Z., and Varçin, H. 2021. Daily Suspended Sediment Prediction Using Seasonal Time Series and Artificial Intelligence Techniques. *Rocznik Ochrona Środowiska*, 23: 117-137. DOI: 10.54740/ros.2021.008.

29-Varvani, J., and Khalighi, SH. 2007. Investigation of sediment rating curves error for estimating flood events sediment yield in Gharachay river. *New Finding in Agriculture*, 1(3), pp. 201-214. (In Persian).