

Suspended sediment simulation using machine learning algorithms and CHIRPS satellite precipitation data with emphasis on data clustering and gamma test, case study: Ramyan Watershed, Golestan Province

Mahmoudreza Tabatabaei^{1*}, Amin Salehpour Jam¹, Jamal Mosaffaie¹

¹ Associate Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

Received: 17 April 2022

Accepted: 06 June 2022

Extended abstract

Introduction

The cycle of soil erosion (including removal, transport and deposition) that controls the sedimentation of watersheds, includes a set of complex and highly nonlinear processes. On the other hand, the factors influencing sedimentation in watersheds are very diverse, and according to the specific conditions of climate, soil, vegetation, geology, topography, etc., in each basin, the weight and role of each of the mentioned factors in sediment production is very different. Accurately determining and measuring these factors and making mathematical relationships between them are often difficult, expensive, time-consuming and error-prone, and this is the case with the use of models based on computational intelligence and the use of a limited number of basin dynamic variables, it is possible to simulate the behavior of the watershed in sediment production. Regardless of the type of intelligent models, in most of the conducted research (especially in internal research), the simulation of suspended sediment is mainly based on the discharge variable and the role of variables such as precipitation (especially precipitation obtained from satellite images), which are effective in the sedimentation of basins, have received less attention. In addition to precipitation, the skewness of sediment measurement data is also one of the issues that lack of recognition and attention will reduce the efficiency of estimator models. In the present study, the role of variable daily rainfall (taken from CHIRPS satellite) in the simulation of suspended sediment of Qarachai River has been investigated.

Materials and methods

Multi-layer perceptron artificial neural network was used in order to simulate the daily suspended sediment concentration of Qarachai River (at the Ramian hydrometer station in Golestan province). In this regard, the variables of discharge and previous discharge (in instantaneous and daily scales) as well as the average daily and previous rainfall of the basin (taken from CHIRPS satellite) for a statistical period of 37 years (1980-2017) as variables model input was used. In order to increase the generalization power of the models, self-organized mapping neural network (for data clustering) and gamma test was used to find the best combination of input variables. In order to improve the efficiency of network training, a variety of activation and loss functions as well as the overfitting prevention algorithm were used. In order to investigate the effect of using activation and loss functions in suspended sediment estimation, different scenarios were considered, which led to the construction of 9 models. After that, using validation indicators, the effectiveness of the models in simulating suspended sediment was investigated and compared, and then the best model was selected.

Results and discussion

The results obtained from the present research showed that among the different models, the neural network model with Huber's activation function and ReLU loss function, having the average absolute value of the error equal to 368 mg/l, the root mean square error equal to 597 mg per liter, the Nash-Sutcliffe coefficient of 0.87 and the percent bias -2.2% were selected as the best model. The results also showed that the use of the

* Corresponding author: taba1345@hotmail.com

rainfall variable (as one of the important factors in causing erosion and sediment transfer in the basin) has improved the efficiency of the models, therefore, considering the ease of using CHIRPS satellite rainfall data, it is suggested in order to simulate the suspended sediment of rivers, this data is also used along with other predictive variables.

Conclusion

In the simulation of suspended sediment, discharge variable is often used as the only predicting variable of suspended sediment, while in basins with rainy, or rainy-snow regimes, the role of precipitation in the production of surface runoff and soil erosion is very important and plays an important role in the production and transport of sediment in the basin. In this regard, although the use of rainfall data obtained from ground rain gauge stations has played an effective role in increasing the efficiency of data-based models in estimating suspended sediment, however, the preparation of hundreds of spatial distribution layers of daily rainfall from the data point data of ground stations, the use of this variable in the simulation of the suspended sediment of the basin has been faced with many problems (such as the lack or inappropriateness of the spatial distribution of rain gauge stations, statistical deficiencies, the use of inappropriate interpolation methods and time-consuming calculations). Therefore, in practice, the variable of river flow is often used as a predictor of sediment, and precipitation is used less often. One of the solutions to the problem mentioned in the present study is the use of CHIRPS satellite data, which was investigated for the first time in this study. These data, available since 1981, can easily be used to simulate suspended sediment or other applications related to watersheds. Another important point that needs to be taken into account in the simulation of suspended sediment is the presence of high skewness in sediment measurement data (both suspended sediment and flow rate), which lack of attention in the process of training (or recalibration) and testing the models leads to It will lead to the construction of weak models in terms of efficiency and the existence of uncertainty in the accuracy of their results. In this regard, it is necessary to use logarithmic transformations or suitable functions of activation and loss in the training process, which in this research, two functions, ReLU and Huber, were proposed respectively. Another important point is to pay attention to the generalization power of data-based models, which is largely dependent on the data used in their calibration or training process. These data should be selected in such a way that while they are representative of the data in the entire statistical period, they are similar and have the same distribution with other data sets (such as cross-validation or test sets). According to the results obtained from the present research and in order to increase the efficiency of artificial neural network models in estimating the suspended sediment of watershed hydrometric stations, it is suggested to use the experiences obtained in this research in other sediment measuring stations of the country.

Keywords: Daily precipitation, Model, Neural network, Sediment yield, Self-organizing map

Cite this article: Tabatabaei, M., Salehpour Jam, A., Mosaffaie, J., 2023. Suspended sediment simulation using machine learning algorithms and CHIRPS satellite precipitation data with emphasis on data clustering and gamma test, case study: Ramyan Watershed, Golestan Province. *Watershed Engineering and Management* 15 (3), 328–350.

© 2023, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



شبیه‌سازی رسوب معلق با استفاده از الگوریتم‌های یادگیری ماشینی و داده‌های بارش ماهواره CHIRPS با تاکید بر خوشه‌بندی داده‌ها و آزمون گاما، مطالعه موردی: حوزه آبخیز رامیان، استان گلستان

محمودرضا طباطبائی^{۱*}، امین صالح پورجم^۱ و جمال مصفائی^۱

^۱ دانشیار پژوهشی، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۴۰۱/۰۳/۱۶

تاریخ دریافت: ۱۴۰۱/۰۱/۲۸

چکیده مبسوط

مقدمه

چرخه فرسایش خاک، شامل برداشت، حمل و رسوبگذاری که رسوبدهی حوزه‌های آبخیز را کنترل می‌کند، شامل مجموعه‌ای از فرایندهای پیچیده و به شدت غیرخطی است. از سوی دیگر، عوامل تاثیرگذار در رسوبدهی حوزه‌های آبخیز بسیار متنوع بوده و با توجه به شرایط خاص اقلیمی، خاکشناسی، پوشش گیاهی، زمین‌شناسی، توپوگرافی و غیره در هر حوضه، وزن و نقش هر یک از عوامل یاد شده در تولید رسوب بسیار متفاوت است. تعیین و اندازه‌گیری دقیق این عوامل و ایجاد رابطه‌های ریاضی بین آن‌ها اغلب مشکل، پرهزینه، زمان‌بر و با خطا همراه بوده است. این در حالی است که با استفاده از مدل‌های مبتنی بر هوش محاسباتی و به‌کارگیری تعداد محدودی از متغیرهای دینامیک حوضه، می‌توان رفتار حوزه آبخیز را در تولید رسوب به خوبی شبیه‌سازی کرد. صرف‌نظر از نوع مدل‌های هوشمند، در اغلب پژوهش‌های انجام شده (به ویژه در تحقیقات داخلی)، شبیه‌سازی رسوب معلق به‌طور عمده، بر پایه متغیر دبی جریان بوده است و به نقش متغیرهایی نظیر بارش (به‌ویژه بارش اخذ شده از تصاویر ماهواره‌ای) که در رسوبدهی حوضه‌ها موثرند، کمتر توجه شده است. علاوه بر بارش، چولگی داده‌های رسوب‌سنجی نیز از جمله مسائلی است که عدم شناخت و توجه به آن سبب کاهش کارایی مدل‌های برآوردگر خواهد شد. در پژوهش حاضر، نقش متغیر بارش روزانه اخذ شده از ماهواره CHIRPS در شبیه‌سازی رسوب معلق رودخانه قره‌چای مورد بررسی قرار گرفته است.

مواد و روش‌ها

به‌منظور شبیه‌سازی غلظت رسوب معلق روزانه رودخانه قره‌چای در محل ایستگاه آب‌سنجی رامیان در استان گلستان، از شبکه عصبی مصنوعی پرسپترون چند لایه استفاده شد. به این منظور، از متغیرهای دبی جریان و دبی جریان پیشین در مقیاس‌های لحظه‌ای و روزانه و همچنین، متوسط بارش روزانه و پیشین حوضه اخذ شده از ماهواره CHIRPS برای یک دوره آماری ۳۷ ساله (۱۳۵۹-۱۳۹۶) به‌عنوان متغیرهای ورودی مدل، استفاده شد. جهت افزایش قدرت تعمیم‌دهی مدل‌ها، از شبکه عصبی نگاشت خود سازمان‌ده (برای خوشه‌بندی داده‌ها) و به‌منظور یافتن بهترین ترکیب متغیرهای ورودی، از آزمون گاما استفاده شد. در راستای افزایش کارایی آموزش شبکه، انواع توابع فعال‌سازی و زیان و همچنین، الگوریتم جلوگیری از بیش‌برازش استفاده شد. به‌منظور بررسی تاثیر به‌کارگیری توابع فعال‌سازی و زیان در برآورد رسوب معلق،

سناریوهای مختلفی در نظر گرفته شد که در مجموع منجر به ساخت نه مدل شد. پس از آن، با استفاده از شاخص‌های صحت‌سنجی، میزان کارایی مدل‌ها در شبیه‌سازی رسوب معلق مورد بررسی و مقایسه قرار گرفت و سپس مدل برتر انتخاب شد.

نتایج و بحث

نتایج پژوهش حاضر، نشان داد که از بین مدل‌های مختلف، مدل شبکه عصبی با تابع فعال‌سازی Huber و تابع زیان ReLU، با داشتن میانگین قدر مطلق خطا برابر ۳۶۸ میلی‌گرم در لیتر، ریشه میانگین مربعات خطا برابر ۵۹۷ میلی‌گرم در لیتر، ضریب ناش-ساتکلیف ۰/۸۷ و درصد ارببی ۲/۲- درصد، به‌عنوان مدل برتر انتخاب شد. نتایج همچنین نشان داد که استفاده از متغیر بارش، به‌عنوان یکی از عوامل مهم در ایجاد فرسایش و انتقال رسوب حوضه، سبب بهبود کارایی مدل‌ها شده است. لذا با توجه به سهولت استفاده از داده‌های بارش ماهواره CHIRPS، می‌توان در شبیه‌سازی رسوب معلق رودخانه‌ها، از این داده نیز به همراه سایر متغیرهای پیش‌بینی کننده استفاده شود.

نتیجه‌گیری

در شبیه‌سازی رسوب معلق، اغلب از متغیر دبی جریان به‌عنوان تنها متغیر پیش‌بینی کننده رسوب معلق استفاده می‌شود، این در حالی است که در حوضه‌هایی با رژیم‌های بارانی، یا بارانی-برفی، نقش بارش در تولید رواناب‌های سطحی و فرسایش خاک بسیار با اهمیت بوده است و نقش مهمی در تولید و انتقال رسوب حوضه دارد. اگرچه استفاده از داده‌های بارش اخذ شده از ایستگاه‌های باران‌سنجی زمینی، نقش موثری در افزایش کارایی مدل‌های داده مبنای برآورد رسوب معلق داشته است، با این حال، تهیه صدها لایه مکانی توزیعی بارش روزانه از داده‌های نقطه‌ای ایستگاه‌های زمینی، استفاده از این متغیر را در شبیه‌سازی رسوب معلق حوضه با مشکلات فراوان (نظیر کمبود یا نامناسب بودن توزیع مکانی ایستگاه‌های باران‌سنجی، نواقص آماری، به‌کارگیری روش‌های میان‌بایی نامناسب و زمان‌بر بودن انجام محاسبات) روبه‌رو ساخته است. لذا، در عمل، اغلب از متغیر دبی جریان رودخانه به‌عنوان متغیر پیش‌بینی کننده رسوب استفاده شده و کمتر از بارش استفاده می‌شود. یکی از راه‌حل‌های برون‌رفت از مشکل یاد شده که در پژوهش حاضر به آن پرداخته شد، استفاده از داده‌های ماهواره‌ای CHIRPS است که برای اولین بار در این پژوهش مورد بررسی قرار گرفت. این داده‌ها از سال ۱۹۸۱ میلادی در دسترس است و به سادگی می‌تواند برای شبیه‌سازی رسوب معلق یا دیگر کاربردهای مرتبط با حوزه‌های آبخیز مورد استفاده قرار گیرد. نکته مهم دیگر که لازم است در شبیه‌سازی رسوب معلق به آن توجه شود، وجود چولگی زیاد در داده‌های رسوب‌سنجی بوده (داده‌های رسوب معلق و دبی جریان) که عدم توجه به آن در فرایند آموزش (یا واسنجی) و آزمون مدل‌ها منجر به ساخت مدل‌های ضعیف به لحاظ کارایی و وجود عدم قطعیت در صحت نتایج آن‌ها خواهد شد. در این رابطه، لازم است از تبدیل‌های لگاریتمی و یا توابع مناسب فعال‌سازی و زیان در فرایند آموزش استفاده شود که در این پژوهش به‌ترتیب دو تابع ReLU و Huber پیشنهاد شد. از نکات مهم دیگر، توجه به قدرت تعمیم‌دهی مدل‌های داده مبنای است که تا اندازه زیادی وابسته به داده‌های استفاده شده در فرایند واسنجی یا آموزش آن‌ها است. این داده‌ها باید به‌گونه‌ای انتخاب شوند که ضمن آن‌که معرف داده‌ها در کل دوره آماری هستند، با دیگر مجموعه‌های داده (نظیر مجموعه‌های ارزیابی یا آزمون)، مشابه و از توزیع یکسان برخوردار باشند. با توجه به نتایج به‌دست آمده از پژوهش حاضر و به‌منظور افزایش کارایی مدل‌های شبکه عصبی مصنوعی در برآورد رسوب معلق ایستگاه‌های هیدرومتری حوزه‌های آبخیز، پیشنهاد می‌شود از تجارب به‌دست آمده در این پژوهش در دیگر ایستگاه‌های رسوب‌سنجی کشور نیز استفاده شود.

واژه‌های کلیدی: بارش روزانه، شبکه عصبی، نگاشت خود سازمان‌ده، رسوبدهی، مدل

مقدمه

چرخه فرسایش خاک شامل برداشت، حمل و رسوبگذاری که رسوبدهی^۱ حوزه‌های آبخیز را کنترل می‌کند، شامل مجموعه‌ای از فرایندهای پیچیده و به شدت غیرخطی است. از سوی دیگر، عوامل تاثیرگذار در رسوبدهی حوزه‌های آبخیز بسیار متنوع بوده است و با توجه به شرایط خاص اقلیمی، خاکشناسی، پوشش گیاهی، زمین‌شناسی، توپوگرافی و غیره در هر حوضه، وزن و نقش هر یک از عوامل یاد شده در تولید رسوب بسیار متفاوت است. تعیین و اندازه‌گیری دقیق این عوامل و ایجاد رابطه‌های ریاضی بین آنها اغلب مشکل، پرهزینه، زمان‌بر و با خطا همراه بوده است. در حالی که با استفاده از مدل‌های مبتنی بر هوش محاسباتی و به کارگیری تعداد محدودی از متغیرهای دینامیک حوضه می‌توان، رفتار حوزه آبخیز در تولید رسوب را به خوبی شبیه‌سازی کرد (Tayfur, 2012).

امروزه، استفاده از مدل‌های داده‌مبنای نظیر مدل‌های رگرسیونی (منحنی سنج رسوب) یا ماشینی (شبکه‌های عصبی، فازی، نروفازی، الگوریتم‌های ژنتیک و غیره) در شبیه‌سازی رسوب معلق رودخانه‌ها بسیار رایج شده است (Buyukyildiz and Kumcu, 2017; Chen and Chau, 2019; Khan et al., 2019; Olyaie et al., 2015; Tabatabaei et al., 2019). با توجه به تنوع و گستردگی پژوهش‌های انجام شده در زمینه کاربرد شبکه‌های عصبی مصنوعی در برآورد رسوب معلق رودخانه‌ها (در داخل و خارج از کشور) در ادامه، به برخی از نتایج آنها اشاره می‌شود.

Rezaei banafsheh et al., (2013) برای برآورد بار رسوب معلق روزانه حوضه رودخانه قرانقو، از سامانه استنتاج فازی-عصبی تطبیقی^۲ استفاده کردند. در این پژوهش، ترکیب‌های مختلفی از ورودی، مشتمل بر داده‌های دبی روزانه و بار رسوب معلق روزهای پیشین،

مورد استفاده قرار گرفت. نتایج نشان داد که مدل ANFIS در مقایسه با سایر روش‌های رگرسیونی و منحنی سنج رسوب، از کارایی بالاتری برخوردار است. در پژوهش دیگری، (Joshi et al., 2016) بیان کردند که غلظت رسوب معلق^۴ با ویژگی‌های هیدرولوژیکی حوزه آبخیز رابطه غیرخطی دارد. به همین دلیل، استفاده از روش‌های سنتی منحنی سنج رسوب نمی‌تواند تخمین درستی در برآورد غلظت رسوب معلق داشته باشد. در نتیجه، آنها از روش‌های مبتنی بر شبکه عصبی مصنوعی برای شبیه‌سازی رسوب معلق استفاده کردند. منطقه مورد مطالعه، یخچال‌های طبیعی Gangotri در هیمالیا بود که رابطه بین غلظت رسوب معلق با رواناب حاصل از ذوب برف با استفاده از شبکه عصبی مصنوعی پیش‌رو با الگوریتم پس انتشار^۵ خطا مورد بررسی قرار گرفت.

داده‌ها، طی یک دوره ۱۱ ساله از سال ۱۹۹۹ تا ۲۰۰۹ جمع‌آوری شد. از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای آزمون مدل‌ها استفاده شد. در این پژوهش، هر دو مدل شبکه عصبی مصنوعی و منحنی سنج رسوب مورد بررسی قرار گرفت. بررسی آماره‌های میانگین مربعات خطا^۶، میانگین قدر مطلق خطا^۷ و ضریب تبیین^۸ نشان داد که مدل شبکه عصبی مصنوعی برآورد بهتری از غلظت رسوب معلق نسبت به منحنی سنج رسوب داشته است.

در پژوهشی در حوزه آبخیز Goodwin Creek در آمریکا، (Chiang et al., 2014) برای برآورد بار رسوب معلق، از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل رگرسیون استفاده کردند. در این پژوهش، از دبی جریان به‌عنوان داده‌های ورودی و از بار رسوب معلق به‌عنوان داده‌های خروجی در مدلسازی استفاده شد. نتایج پژوهش آنها نشان داد که کارایی مدل ماشین

⁴ Suspended Sediment Concentration (SSC)

⁵ Back propagation

⁶ Mean Square Error (MSE)

⁷ Mean Absolut Error (MAE)

⁸ Coefficient of determination (R²)

¹ Sediment yield

² Data driven models

³ Adaptive Neuro-Fuzzy Inference System (ANFIS)

به کمک مدل SWAT^۳ انجام شد، از داده‌های بارش ماهواره CHIRPS و TRMM^۴ استفاده شد که نتایج به‌دست آمده از داده‌های CHIRPS رضایت‌بخش‌تر بوده است. آن‌ها استفاده از این داده‌ها در حوضه‌هایی که کمبود یا فقدان اطلاعات بارش وجود دارد را توصیه کردند. نتایج مشابه دیگری در رابطه با شبیه‌سازی جریان و استفاده از داده‌های بارش ماهواره CHIRPS به‌وسیله Sulugodu and Deka (2019), Ahmadi et al., (2019) گزارش شده است.

به‌منظور آموزش و آزمون مدل‌های شبکه عصبی، لازم است تا داده‌های مورد استفاده در مجموعه داده‌های آموزش^۵، اعتبارسنجی متقابل^۶ و آزمون^۷ مشابه و همگن باشند (Li et al., 2010؛ May et al., 2006؛ Nour et al., 2010؛ Kaufman and Bowden et al., 2002؛ Rousseeuw, 2009). عدم استفاده از داده‌های مشابه و همگن در مجموعه‌های یاد شده، تاثیرات بسیار مستقیم در میزان صحت و کارایی نهایی مدل‌های طراحی شده خواهد داشت که موجب کاهش قدرت تعمیم‌دهی آن‌ها خواهد شد (May et al., 2010).

لذا، در این پژوهش، برای ایجاد مجموعه داده‌های همگن و مشابه از شبکه عصبی نگاشت خود سازمان‌ده^۸ استفاده شده است (Kohonen, 1998). در مجموع، پژوهش حاضر با هدف شبیه‌سازی و برآورد رسوب معلق روزانه در ایستگاه هیدرومتری رامیان با تاکید بر استفاده از داده‌های بارش ماهواره CHIRPS که تا کنون در پژوهشی مشابه به کار گرفته نشده و همچنین، به‌کارگیری آزمون گاما برای انتخاب ویژگی^۹ (انتخاب بهینه ترکیب متغیرهای ورودی مدل)، انجام شده است. علاوه بر این، به مشکل چولگی داده‌های رسوب‌سنجی پرداخته و راهکارهایی برای آن معرفی شد.

بردار پشتیبان در برآورد رسوب معلق، بهتر از شبکه عصبی و مدل رگرسیونی بوده است. Kisi and Fedakar (2014)، به‌منظور برآورد غلظت رسوب معلق در دو ایستگاه آب‌سنجی Muddy Creek در آمریکا، کارایی مدل‌های هیبرید فازی-ژنتیک، ANFIS، شبکه عصبی پرسپترون چند لایه و منحنی سنج رسوب را با یکدیگر مقایسه کردند. در همه مدل‌ها از دبی جریان به‌عنوان داده ورودی و از غلظت رسوب معلق، به‌عنوان داده خروجی استفاده شد. نتایج پژوهش آن‌ها، حاکی از کارایی بالاتر مدل هیبرید فازی-ژنتیک نسبت به دیگر مدل‌ها بود.

در پژوهش دیگری نیز (Tayfur and Guldal (2006)، به‌منظور برآورد مجموع رسوب معلق روزانه^۱ که در یکی از زیرحوضه‌های Tennessee در آمریکا انجام شد، از داده‌های بارش ایستگاه‌های زمینی و مدل شبکه عصبی استفاده کرده‌اند. در این پژوهش، از ۲۴۰ نمونه بارش روزانه-رسوب معلق (بارش به‌عنوان تنها متغیر ورودی و غلظت رسوب معلق به‌عنوان متغیر خروجی) برای شبیه‌سازی و برآورد رسوب معلق استفاده شد.

همچنین، از بارش روزانه روزهای گذشته (تا چهار روز قبل) نیز به‌عنوان متغیرهای ورودی استفاده شد. از پژوهش‌های مشابه دیگر که در آن از بارش روزانه به‌عنوان یکی از متغیرهای اثرگذار در مدل‌سازی رسوب معلق در روش‌های یادگیری ماشینی استفاده شده است، می‌توان به کارهای (Cobaner, Teixeira et al., 2020)، (Kisi and Shiri (2012)، (Melesse et al., (2009)، (Khan et al., (2019) اشاره کرد.

داده‌های بارش ماهواره CHIRPS، با داده‌های ایستگاهی کارگروه مخاطرات آب و هوایی^۲ می‌تواند به‌صورت روزانه اخذ و مورد استفاده قرار گیرد. در پژوهشی که به‌وسیله Duan et al., (2019) به‌منظور شبیه‌سازی جریان رودخانه در حوضه Adige در ایتالیا و

³ Soil and Water Assessment Tool

⁴ Tropical Rainfall Measuring Mission (TRMM)

⁵ Training data set

⁶ Cross-validation data set

⁷ Test data set

⁸ Self-organizing map

⁹ Feature selection

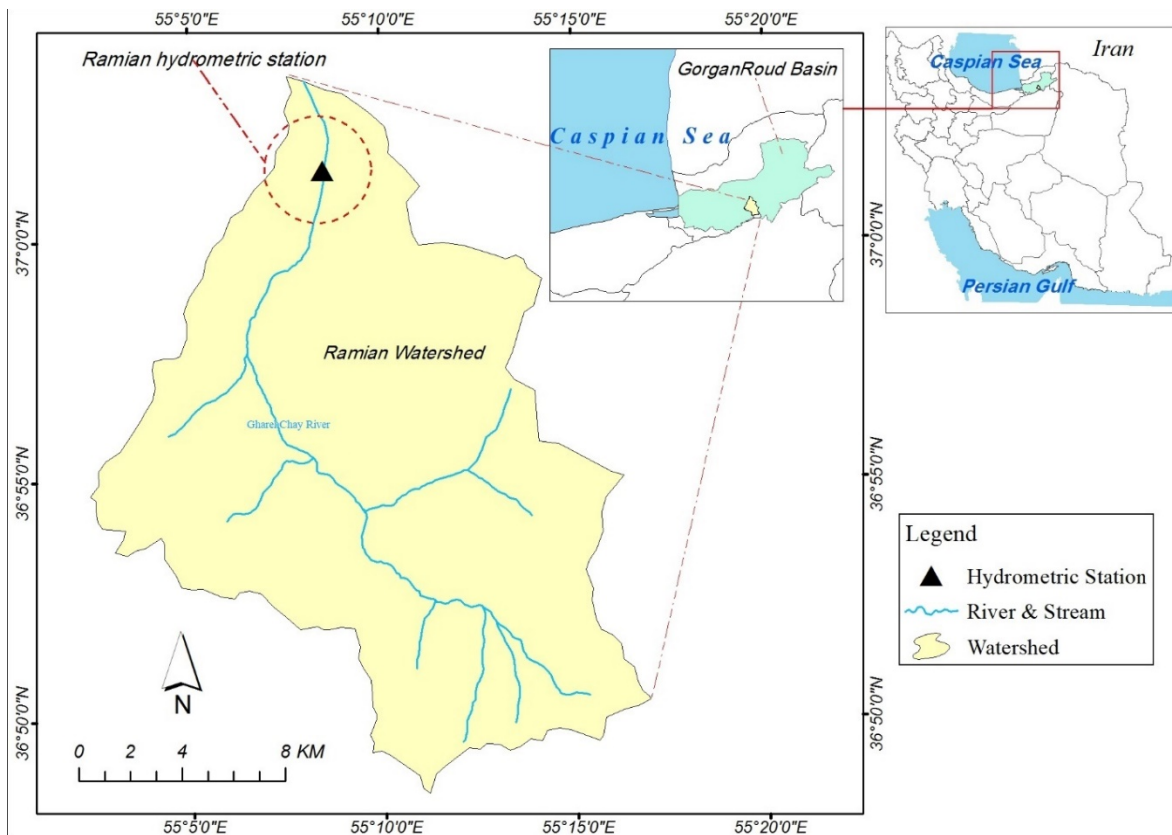
¹ Total Suspended Sediment (TSS)

² Climate Hazards Group Infrared Precipitation with Station Data (CHIRPS)

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده: پژوهش حاضر در استان گلستان در حوزه آبخیز رامیان و در محل ایستگاه هیدرومتری رامیان بر روی رودخانه قره چای انجام شده است (شکل ۱). این حوزه در مختصات جغرافیایی $55^{\circ}02'$ تا $55^{\circ}16'$ طول شرقی و $36^{\circ}49'$ تا $37^{\circ}02'$ عرض شمالی در استان گلستان واقع است. مساحت حوزه، 30345 هکتار و متوسط ارتفاع آن

1189 متر از سطح دریا است. طول رودخانه قره‌چای 33 کیلومتر بوده و مناطق بالادست آن کاملاً کوهستانی و از نظر کاربری اراضی بیشتر جنگلی است. مناطق اطراف رودخانه در پایین‌دست، تقریباً هموار بوده و شامل اراضی کشاورزی است. بافت خاک سیلتی لوم و اقلیم منطقه بر اساس طبقه‌بندی دومارتن بسیار مرطوب تا نیمه‌مرطوب است. در جدول ۱، برخی از خصوصیات فیزیوگرافی و کاربری اراضی حوزه رامیان نشان داده شده است.



شکل ۱- موقعیت حوزه آبخیز مورد مطالعه و ایستگاه هیدرومتری رامیان

Fig. 1. The location of the studied watershed and Ramyan hydrometric station

جدول ۲ استنباط می‌شود، رسوب معلق ایستگاه، دارای چولگی (چولگی مثبت) و تغییرات بین کمینه و بیشینه آن (ضریب تغییرات) زیاد است. این موضوع به همراه سایر آماره‌های محاسبه‌شده، حکایت از پیچیدگی مدل‌سازی برآورد رسوب معلق رودخانه دارد.

لازم به توضیح است که در پژوهش حاضر و در شبیه‌سازی رسوب معلق ایستگاه هیدرومتری رامیان، از داده‌های دبی لحظه‌ای، دبی روزانه و بارش متوسط

داده‌های مورد استفاده در این پژوهش، شامل داده‌های دبی لحظه‌ای جریان و غلظت رسوب معلق روزانه ایستگاه هیدرومتری رامیان، در یک دوره زمانی ۳۷ ساله (۱۳۹۶-۱۳۵۹) و به تعداد ۳۵۸ رکورد اطلاعاتی و همچنین، داده‌های بارش روزانه تصاویر ماهواره‌ای CHIRPS در دوره یاد شده است.

ویژگی‌های آماری داده‌های مورد استفاده در جدول ۲، ارائه شده است. همان‌طور که از اطلاعات آماری

معلق به عنوان متغیر خروجی، در مدل سازی استفاده شده است. حوضه، به همراه داده های روزهای پیشین آن ها به عنوان متغیرهای ورودی (تخمین گر مدل)، و از غلظت رسوب

جدول ۱- برخی از خصوصیات فیزیوگرافی و کاربری اراضی حوضه رامیان

Table 1. Some features of physiography and land use of Ramyan Watershed

Physiographic characteristics and land use	Values
Area (ha)	30345
Average slope of the watershed (percent)	35.7
Minimum watershed height (meter)	127
Maximum watershed height (meter)	2774
Average watershed height (meter)	1189
Forest (percent)	57.67
Pasture (percent)	10.21
Agriculture (percent)	32.12

جدول ۲- ویژگی های آماری داده های رسوب سنجی ایستگاه هیدرومتری رامیان و داده های بارش روزانه تصاویر ماهواره ای CHIRPS
Table 2. Statistical features of Ramyan hydrometric station sediment measurement data and daily rainfall data of CHIRPS satellite images

Statistical year and number of data	Data type	Average	Median	Standard deviation	Minimum	Maximum	Skewness	Coefficient of variation (percent)
1980-2017 358	Instantaneous discharge ($m^3 s^{-1}$)	1.60	0.624	2.43	0.002	13.4	2.61	152
	Suspended sediment concentration ($mg l^{-1}$)	1175.09	382.16	2473.88	4.2	23456	5.04	210
	Daily rainfall (mm)	2.21	0	8.07	0	65.5	5.39	365

روبه جلو^۱: شبکه عصبی مصنوعی پرسپترون چند لایه، از عناصر عملیاتی ساده ای به نام نرون ساخته شده که به صورت موازی و در کنار هم، عمل می کنند. شبکه های عصبی چند لایه، از یک لایه ورودی (در ارتباط با داده های ورودی)، یک یا چند لایه پنهان (برای سازمان دهی نرون ها) و یک لایه خروجی (در رابطه با داده خروجی) تشکیل می شوند. عملکرد شبکه عصبی، از طریق نحوه اتصال بین اجزا، با تنظیم مقادیر هر اتصال که به نام وزن اتصال بیان می شود، تعیین می شود. یکی از انواع شبکه های عصبی پر کاربرد در هیدرولوژی و منابع آب، شبکه های عصبی پرسپترون چند لایه روبه جلو با

داده های ماهواره CHIRPS: داده های بارش ماهواره CHIRPS که با اهداف پایش خشکسالی کشاورزی توسعه داده شده اند، مجموعه ای مشتعل بر حدود ۴۰ سال داده بارندگی جهانی بوده که در مقیاس های زمانی شش ساعته، روزانه و ماهانه و با قدرت تفکیک مکانی ۰/۰۵ درجه تهیه و از سال ۱۹۸۱ میلادی در دسترس هستند (Funk et al., 2015). این محصولات، تنها اطلاعات خام ماهواره ای نبوده، بلکه به وسیله ایستگاه های زمینی تدقیق شده اند. در پژوهش حاضر، به منظور پردازش و تجزیه و تحلیل داده های رقومی تصاویر CHIRPS و محاسبه میانگین بارش های روزانه حوضه مورد مطالعه در طول دوره آماری، از کدنویسی در محیط سامانه Google Earth Engine استفاده شده است.

شبکه عصبی مصنوعی پرسپترون چند لایه

¹ Feed-Forward Multi-Layer Perceptron (FFMLP)

همچنین، به منظور جلوگیری از بیش‌برازش^۲ مدل‌ها در مدت زمان آموزش، از الگوریتم توقف زودرس^۳ استفاده شد.

تهیه داده‌های همگن جهت آموزش و آزمون مدل‌ها: به منظور افزایش قدرت تعمیم‌دهی مدل شبکه عصبی، لازم است داده‌های مورد استفاده در آموزش مدل، معرف و نماینده داده‌های کل دوره آماری باشند. همچنین، برای آزمون و ارزیابی صحیح نتایج مدل، لازم است داده‌های آزمون، مشابه داده‌های آموزش و ارزیابی متقاطع^۴ (که برای جلوگیری از بیش‌برازش مدل استفاده می‌شود) بوده و از توزیع فراوانی یکسانی با آن‌ها برخوردار باشند. بدین منظور، در پژوهش حاضر از شبکه عصبی نگاشت خود سازمان‌ده، برای خوشه‌بندی داده‌ها و از روش تخصیص برابر^۵، به منظور نمونه‌گیری از خوشه‌ها استفاده شده است. تعیین تعداد بهینه خوشه‌ها، به وسیله شاخص ارزیابی کیفیت خوشه‌بندی دیویس-بولدین^۶ انجام گرفته است.

به منظور تحلیل نتایج آماری حاصل از خوشه‌بندی داده‌ها در سه مجموعه داده آموزش، ارزیابی متقاطع و آزمون، مقایسه پارامترهای آماری (میانگین، انحراف معیار و چولگی) آن‌ها با یکدیگر انجام شد. همچنین، از آزمون ناپارامتری دو نمونه‌ای کلموگروف-اسمیرنوف^۷ برای بررسی و مقایسه یکسان بودن توزیع داده‌های موجود در مجموعه‌های یاد شده، استفاده شد که در ادامه به اختصار به آن‌ها اشاره می‌شود.

شبکه عصبی نگاشت خود سازمان‌ده: شبکه عصبی نگاشت خود سازمان‌ده یا SOM، یک شبکه عصبی مصنوعی غیرنظارتی بوده است که الگوریتم آموزش آن، به صورت رقابتی و بدون ناظر انجام می‌شود. ساختار SOM، از یک لایه ورودی و یک لایه خروجی (لایه کوهنن) تشکیل می‌شود (Kohonen, 1998). در این

الگوی آموزش پس انتشار خطا است (Ulke et al., 2009).

در این نوع از شبکه‌های عصبی، جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی بوده است که از این نظر به آن‌ها شبکه‌های عصبی روبه‌جلو یا پیش‌خور گفته می‌شود. به منظور آموزش شبکه عصبی، مقدار خطا در جهت بیشترین شیب تابع خطا محاسبه شده و این مقدار، به لایه‌های قبل (لایه یا لایه‌های پنهان) فرستاده شده تا با تنظیم مجدد مقادیر وزن نرون‌ها، مقدار خطا را کاهش دهند (قانون دلتا) (Tayfur, 2012) (رابطه ۱).

$$w_{ij}^{new} = w_{ij}^{old} - \eta \frac{\partial E}{\partial w_{ij}} \quad (1)$$

که در آن، w_{ij}^{new} و w_{ij}^{old} ، به ترتیب وزن بین نرون‌های i و j قبل و بعد از یک تکرار معین، η نرخ یادگیری و E تابع خطا است.

آموزش شبکه و کاهش خطا تا ایجاد همگرایی در شبکه ادامه می‌یابد. شبکه‌های عصبی می‌توانند دارای چندین لایه پنهان باشند، با این وجود، تحقیقات انجام‌شده نشان می‌دهد که شبکه‌های عصبی پیش‌خور، با دارا بودن یک لایه پنهان، قادر به تقریب زدن هر نوع تابع غیرخطی هستند (Hornik et al., 1989).

در پژوهش حاضر، از یک شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) استفاده شده است که تعداد بهینه نرون‌ها با سعی و خطا تعیین شد. به منظور آموزش شبکه عصبی از الگوریتم یادگیری Adam، به دلیل کارایی و همگرایی سریع‌تر در آموزش شبکه و اثبات کارآمدی آن در تخمین رسوب رودخانه‌ای استفاده شده است (Sahoo et al., 2021; Kaveh et al., 2022). در آموزش مدل‌های شبکه عصبی، توابع فعال‌سازی مختلفی نظیر ReLU، Sigmoid و Tanh در نرون‌های شبکه مورد استفاده قرار گرفت و از توابع زیان^۱ MSE، MAE و Huber برای بهینه‌سازی ماتریس ضرایب شبکه استفاده شد.

² Overfitting

³ Early stopping method

⁴ Cross validation

⁵ Proportional allocation

⁶ Davies-Bouldin Index

⁷ Two-sample Kolmogorov-Smirnov Test (KS)

¹ Loss functions

رابطه‌های (۳) و (۴) به ترتیب، برای نرمال کردن داده‌ها در بازه‌های $[0/0-1/9]$ و $[-0/0-9/9]$ استفاده شده است.

$$z=0.1+(0.8*\frac{X_i-X_{imin}}{X_{imax}-X_{imin}}) \quad (3)$$

$$z=\left(\frac{1.8(X_i-X_{imin})}{X_{imax}-X_{imin}}\right)-0.9 \quad (4)$$

که در آن‌ها، Z متغیر نرمال شده، X_i متغیر اولیه، X_{imax} و X_{imin} به ترتیب مقادیر کمینه و بیشینه متغیر X_i هستند.

روش نمونه‌گیری از خوشه‌ها: به منظور تهیه سه مجموعه تقریباً مشابه و همگن (مجموعه‌های آموزش، ارزیابی متقاطع و آزمون)، باید از خوشه‌های تولیدی به شکل مناسبی نمونه‌گیری به عمل بیاید که در پژوهش حاضر، از روش تخصیص متناسب (رابطه ۵)، به نسبت ۷۰، ۱۵ و ۱۵ درصد به ترتیب برای سه مجموعه داده یاد شده استفاده شده است. در روش تخصیص متناسب، تعداد نمونه‌ها متناسب با اندازه خوشه تغییر کرده است. به این صورت که با افزایش اندازه هر خوشه، تعداد نمونه‌گیری از آن‌ها افزایش و یا کاهش یافته است (رابطه ۵).

$$nh=n\frac{Nh}{\sum_{j=1}^H Nj} \quad (5)$$

که در آن، nh تعداد نمونه گرفته شده از خوشه h ، n تعداد داده مورد نیاز، Nh تعداد داده‌ها در خوشه h و Nj تعداد داده در سایر خوشه‌ها است.

تحلیل آماری داده‌های خوشه‌بندی شده: به منظور بررسی و مقایسه همگنی و مشابهت داده‌های مجموعه‌های آموزش^۶، ارزیابی متقاطع و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار و چولگی) از آزمون ناپارامتری کولموگروف-اسمیرنوف دو نمونه‌ای، به منظور بررسی یکسانی و تشابه توزیع فراوانی داده‌ها در مجموعه داده‌های یاد شده استفاده شد (Mansourfar, 2017).

در پژوهش حاضر، به منظور پیاده‌سازی مدل‌های شبکه عصبی، خوشه‌بندی داده‌ها و همچنین انجام تحلیل‌های آماری، از نرم‌افزارهای پایتون، متلب و سامانه

ساختار، نورون‌های لایه ورودی، محل ارتباط داده‌های ورودی با شبکه بوده است که به ازای هر متغیر ورودی، یک نورون در این لایه وجود دارد (به‌عنوان مثال دبی و بارش). لایه خروجی، ماتریس یا شبکه‌ای (عموماً یک شبکه دو بعدی) از نورون‌ها را تشکیل داده است، به طوری که هر نورون این شبکه، به کلیه نورون‌های لایه ورودی متصل بوده است، ولی به نورون‌های دیگر این لایه متصل نیست. فرایند آموزش در شبکه SOM از سه مرحله رقابت^۱، همکاری^۲ و تطبیق^۳ تشکیل می‌شود. در ابتدا، وزن نورون‌های لایه خروجی به صورت تصادفی تعریف شده است و در طی فرایند آموزش و در طول زمان، به مقادیر متغیرهای بردارهای ورودی بیشتر شبیه می‌شود. پس از آن که شبیه‌ترین نورون به بردار ورودی^۴ مشخص شد، وزن‌های آن و وزن‌های دیگر نورون‌های همسایه آن، برحسب مقدار فاصله‌ای که از BMU دارند (فاز همکاری) بر طبق رابطه (۲) به هنگام می‌شوند (فاز تطبیق).

$$wji(t+1)=wji(t)+\theta(t)*\eta(t)*[xi(t)-wji(t)] \quad (2)$$

که در آن، t نماینده زمان، $\theta(t)$ تابعی است که فاصله نورون‌های همسایه BMU را به نسبتی از همسایگی تبدیل می‌کند و $\eta(t)$ نرخ یادگیری است. در پژوهش حاضر، به منظور تعیین تعداد خوشه‌های بهینه، از شاخص ارزیابی دیویس-بولدین^۵ استفاده شده است (Kaufman and Rousseeuw, 2009).

نرمال‌سازی خطی داده‌ها: نرمال‌سازی داده‌ها، به منظور بی‌بعد کردن آن‌ها در محاسبات فاصله (در عملیات خوشه‌بندی)، امکان استفاده از متغیرهای چندگانه با واحدهای اندازه‌گیری متفاوت در یک مدل و یا به منظور جلوگیری از کوچک شدن بیش از حد وزن‌های تخصیص یافته به نورون‌ها (در مدل‌های شبکه عصبی)، استفاده می‌شود. در این پژوهش، با توجه به استفاده از توابع محرک سیگموئید و تانژانت هایپربولیک (Tanh) از

¹ Competitive phase

² Co-operative phase

³ Adaptive Phase

⁴ Best Matching Unit (BMU)

⁵ Davies-Bouldin Index

⁶ Training set

شبیه‌سازی رسوب معلق در نظر گرفت. با توجه به این که تعداد ترکیبات غیرتکراری ممکن از قانون کلی 2^{n-1} (n تعداد متغیر) قابل محاسبه است،

لذا می‌توان تعداد ترکیبات ممکن از الگوهای ورودی را قبل از شروع شبیه‌سازی تعیین کرد. به‌عنوان مثال در پژوهش حاضر، چنانچه از متغیر دبی لحظه‌ای و دو متغیر بارش روزانه و دبی روزانه (با احتساب داده‌های چهار روز پیشین آن‌ها) استفاده شود، تعداد الگوهای غیرتکراری ممکن حاصل از ترکیب آن‌ها، 2^{11-1} یا ۱۰۲۴ الگو است.

از آنجا که تعیین بهترین الگو یا الگوهای ورودی (در برآورد هرچه صحیح‌تر رسوب معلق) از بین این تعداد الگوی ممکن، عملاً کاری دشوار است، لذا لازم است قبل از شروع شبیه‌سازی، با استفاده از روش‌های انتخاب ویژگی، نسبت به تعیین الگوهای مناسب اقدام شود. در این رابطه، آزمون گاما^۱ یکی از روش‌های مناسب برای کشف الگو یا الگوهای مناسب ورودی بوده که در ادامه به اختصار در مورد آن مطالبی ارائه می‌شود.

به‌منظور بررسی تاثیر به‌کارگیری متغیر بارش اخذ شده از ماهواره CHIRPS در مقدار کارایی مدل‌های برآوردکننده رسوب معلق، دو سناریوی کلی الف) شامل متغیرهای بارش و دبی جریان و ب) تنها متغیرهای دبی جریان، در نظر گرفته شد.

در هر دو سناریو، انتخاب ویژگی‌ها (متغیرهای ورودی) به‌وسیله آزمون گاما انجام شد. پس از آن که متغیرهای منتخب هر دو سناریو تعیین شد، با استفاده از داده‌های مجموعه آموزش، برای هر سناریو مدل‌های شبکه عصبی ساخته و در آن‌ها تاثیر به‌کارگیری توابع فعال‌سازی (Sigmoid، Tanh و ReLU) و توابع زیان (MSE، MAE و Huber) بررسی شد.

مکانی هوشمند شبیه‌ساز رسوب معلق که به‌وسیله نگارنده تهیه و تدوین شده و دارای گواهی ثبت اختراع به شماره ۹۹۹۲۵، استفاده شده است.

متغیرهای ورودی-خروجی، سناریوهای مدل‌سازی و اسامی مدل‌ها: در آموزش مدل‌های شبکه عصبی به‌منظور شبیه‌سازی رسوب معلق، از داده‌های دبی لحظه‌ای (Q)، دبی روزانه (Q_{w-i}) و بارش متوسط حوضه ($P-i$) به‌عنوان متغیرهای ورودی (تخمین‌گر مدل)، و از غلظت رسوب معلق (SSC) به‌عنوان متغیر خروجی استفاده شده است.

از آنجا که مقدار رسوب معلق رودخانه در زمان اندازه‌گیری می‌تواند با مقادیر روزهای قبل متغیرهای ورودی (در این پژوهش دبی و بارش) ارتباط داشته باشد (Tayfur and Guldal, 2006; Ulke et al., 2009)،


لذا، به‌منظور افزایش کارایی مدل‌های شبکه عصبی و آزمون این روش، از مقادیر روزهای پیشین آن‌ها (تاخیر های یک روزه، دو روزه تا چهار روزه) نیز در شبیه‌سازی رسوب معلق استفاده شد.

در نام‌گذاری متغیرهای ورودی، شماره روزهای پیشین با اندیس i مشخص شده است. به‌طور مثال، متغیر Q_{w-1} ، اشاره به متغیر دبی روزانه با تاخیر یک روزه دارد یا متغیر P_2 ، اشاره به مقدار متوسط بارش حوضه در دو روز قبل آن دارد.

به‌منظور درک مناسب‌تر از آنچه گفته شد در شکل ۲، الگوهایی از داده‌های مورد استفاده در آموزش مدل های شبکه عصبی نشان داده شده است.

همان‌طور که در شکل ۲، قابل مشاهده است، از ترکیب متغیرهای ورودی (دبی لحظه‌ای، دبی روزانه و بارش)، الگوهای ورودی متنوعی را می‌توان برای

¹ Gamma test



شکل ۲- الگوهایی از داده‌های مورد استفاده در آموزش مدل‌های شبکه عصبی

Fig. 2. Patterns of data used in training neural network models

ترکیب ورودی برای مدل‌سازی انتخاب می‌شود. بهترین مدلی که در آینده از این ترکیب متغیرها به‌عنوان ورودی استفاده می‌کند، نباید خطایی کمتر از مقدار خطای آزمون گاما داشته باشد و اگر چنین باشد، نشان‌دهنده آن است که مدل مورد مطالعه دچار بیش برآزش شده است. ایده اصلی این آزمون در ادامه ارائه شده است.

به‌طور فرض، مجموعه‌ای از M مشاهده ورودی-خروجی (x_i, y_i) مجموعه زیر (رابطه ۶) را تشکیل می‌دهند.

$$\{(x_i, y_i), 1 \leq i \leq M\} \quad (6)$$

در این صورت، آزمون گاما با فرض عدم قطعیت و پذیرش مقدار خطا در به‌دست آوردن خروجی از روی ورودی (به‌خاطر پیچیدگی و غیرخطی بودن پدیده‌های مدل‌سازی) این خطا را به‌صورت رابطه (۷) بین مجموعه داده‌های ورودی و خروجی با تابع f نشان می‌دهد.

$$y = f(x_1, x_2, \dots, x_m) + r \quad (7)$$

که در آن، f تابع ناشناخته و همواری است که متغیرهای ورودی (x_1, x_2, \dots, x_m) را به متغیر خروجی (y) ارتباط می‌دهد و r متغیر تصادفی است که مقدار خطای مدل‌سازی را بیان می‌کند.

در رابطه (۷)، آنچه که آزمون گاما اندازه‌گیری می‌کند در حقیقت، آن بخش از واریانس خروجی (y) است که به‌وسیله تابع f نمی‌تواند تبیین شود. در واقع، آزمون گاما قبل از آن که تابعی نظیر تابع f، مقادیر خروجی را مدل‌سازی کند، واریانس خطا یا $\text{Var}(r)$ برای مجموعه داده (رابطه ۶) را گزارش می‌کند. نکته اخیر، یکی از نقاط قوت آزمون گاما بوده که به کمک آن می‌توان، مقدار خطای هر ترکیب از متغیرهای ورودی را مستقیماً از خود داده‌ها و قبل از فرایند مدل‌سازی و حتی با ناشناخته بودن تابع f حدس زد. این امکان موجب

به‌طور خلاصه، در هر سناریو نه مدل و در مجموع ۱۸ مدل ساخته شد و پس از آن، کارایی آن‌ها با داده‌های آزمون مورد مقایسه قرار گرفت. به‌منظور درک بهتر و سهولت مقایسه مدل‌ها، اسامی آن‌ها، مطابق الگو "نام تابع فعال‌سازی-نام تابع زیان-M-A(or B)" تعریف شد. در این الگو، حرف M، اشاره به مدل و حروف A یا B اشاره به سناریوهای الف و ب دارند. برای مثال، الگوی M-A-ReLU-MSE اشاره به یک مدل در سناریوی الف با تابع فعال‌سازی ReLU و تابع زیان MSE دارد.

آزمون گاما: آزمون گاما، یک ابزار مدل‌سازی غیرخطی است که به کمک آن می‌توان از بین متغیرهای (ویژگی) مختلف ورودی، ترکیب مناسب متغیرها را برای یک ایجاد یک مدل هموار^۱ بررسی و تعیین کرد. آزمون گاما برای اولین بار به‌وسیله Koncar (1997) ارائه و در سال‌های بعد به‌وسیله بسیاری از محققین مورد استفاده قرار گرفته است (Durrant, 2001; Choubin and Malekian, 2017). به کمک آزمون گاما می‌توان، ترکیبات مختلف متغیرهای ورودی را تعیین و سپس، مقدار نویز (خطا) موجود در هر ترکیب را قبل از انجام مدل‌سازی مشخص کرد. به‌طور کلی، آزمون گاما روی این فرض است که اگر دو متغیر x و x' در فضای ورودی به هم نزدیک باشند، آنگاه دو متغیر خروجی متناظر آن‌ها (y و y') نیز می‌بایست در فضای خروجی به هم نزدیک باشند. بنابراین، اگر این دو مقدار y و y' از هم فاصله داشته باشند، این فاصله به‌دلیل نویز یا خطا است.

آزمون گاما برای تمامی ترکیبات ممکن از متغیرهای ورودی، مقدار خطا را محاسبه می‌کند و هر ترکیبی که کمترین مقدار خطا را داشته باشد، به‌عنوان بهترین

¹ Smooth

که در آن، Γ آماره گاما و عرض از مبدأ خط رگرسیون، A شیب خط و $\gamma_m(k)$ واریانس خطای داده‌های خروجی است.

همان‌طور که پیش‌تر بیان شد، آماره گاما (Γ) در رابطه (۱۰)، بیانگر آن بخش از واریانس داده‌های خروجی است که نمی‌تواند به‌وسیله مدل (تابع f) برآورد شود، به‌عبارت دیگر، آماره گاما مقدار خطای موجود در داده‌های خروجی را نشان می‌دهد. لذا، مقدار آن هر چقدر کمتر باشد، بیانگر آن است که ترکیب متغیرهای ورودی بهتر بوده است. علاوه بر آماره گاما، شیب خط رگرسیون (A) نیز نشان‌دهنده پیچیدگی مدلی است که از روی مجموعه داده‌های ورودی و خروجی ساخته می‌شود و این شیب هرچه تندتر باشد، نشان‌دهنده پیچیدگی بیشتر مدل است. یکی دیگر از معیارهای مهم آزمون گاما، معیار بدون بعد $Vratio$ است (رابطه ۱۱) (Jones et al., 2002).

$$Vratio = \frac{\Gamma}{\sigma^2(y)} \quad (11)$$

که در آن، $\sigma^2(y)$ ، واریانس داده‌های خروجی (y) است. مقدار این آماره بین صفر و یک بوده و هرچه مقدار آن به صفر نزدیک‌تر باشد، نمایانگر بهتر بودن آن ترکیب متغیری برای یافتن خروجی‌های مطلوب در مدل‌سازی است. در این پژوهش، به‌منظور انجام آزمون گاما، از نرم افزار winGammaTM نسخه ۱/۹۸، محصول دانشگاه Cardiff استفاده شده است.

صحت‌سنجی و ارزیابی مدل‌ها: به‌منظور ارزیابی و مقایسه نتایج گرفته شده از مدل‌های شبکه عصبی و مقایسه آن‌ها با داده‌های رسوب مشاهداتی (داده‌های مجموعه آزمون)، اندازه‌گیری مقدار خطا و ترسیم‌های گرافیکی انجام شد. در این رابطه، از شاخص‌های ریشه میانگین مربعات خطا^۱، میانگین قدر مطلق خطا، ضریب کارایی ناش-ساتکلیف (NSE)، ضریب تبیین (R^2) و درصد اریبی یا بایاس (PBIAS) بین داده‌های مشاهده‌ای با داده‌های محاسباتی (به ترتیب رابطه‌های ۱۱ تا ۱۵) استفاده شد.

می‌شود، بدون صرف هزینه و زمان، ترکیبات مختلف ورودی را بررسی و بهترین ترکیب ورودی را برای فرایند مدل‌سازی انتخاب کرد. محاسبه آماره آزمون گاما (Γ) بر اساس توابع دلتا (رابطه ۸) و گاما (رابطه ۹) و بر اساس لیستی از همسایگان k برای هر بردار ورودی X_i ($1 \leq i \leq M$) محاسبه می‌شود (Durrant, 2001).


$$\delta_m(k) = \frac{1}{M} \sum_{i=1}^M |X_{N[i,k]} - X_i|^2 \quad (8)$$

که در آن، $N[i,k]$ شاخص K ام نزدیک‌ترین همسایه به X_i را اعلان می‌کند، تابع دلتا، میانگین مجذور فاصله K ام همسایگی و $|.$ علامت فاصله اقلیدسی است.

$$\gamma_m(k) = \frac{1}{2M} \sum_{i=1}^M |y_{N[i,k]} - y_i|^2 \quad (9)$$

که در آن، $y_{N[i,k]}$ مقدار متناظر با K ام همسایگی X_i در رابطه (۸) و $\gamma_m(k)$ تابع گاما، است.

به‌منظور محاسبه آماره Γ ، یک خط رگرسیون بر P نقطه (به‌طور پیش‌فرض مقدار P را ۱۰ فرض می‌کنند) از مقادیر $\delta_m(k)$ و $\gamma_m(k)$ با استفاده از روش کمینه مربعات خطا^۱ برازش داده می‌شود. عرض از مبدأ خط رگرسیون، بیانگر مقدار آماره Γ است (شکل ۳).



شکل ۳- نمودار خط رگرسیون آزمون گاما (Jones و

همکاران، 2002)

Fig. 3. Gamma test regression line diagram

معادله خط رگرسیونی در رابطه (۱۰) ارائه شده است.

$$\gamma = A\delta + \Gamma \quad (10)$$

² Root Mean Square Error (RMSE)

¹ Least square method

در رابطه‌های فوق، S_M و S_O به ترتیب، غلظت رسوب معلق مشاهده‌ای و برآورد شده (mg l^{-1})، \bar{S}_M و \bar{S}_O به ترتیب میانگین غلظت رسوب مشاهده‌ای و محاسبه شده و n تعداد داده‌ها است. پیش از ارائه نتایج، به منظور درک بهتر از روش‌های ارائه شده در فرایند مدل‌سازی رسوب معلق و چگونگی ارتباط بین بخش‌های مختلف پژوهش، ساختار کلی مراحل مدل‌سازی، در شکل ۴، خلاصه و نمایش داده شده است.

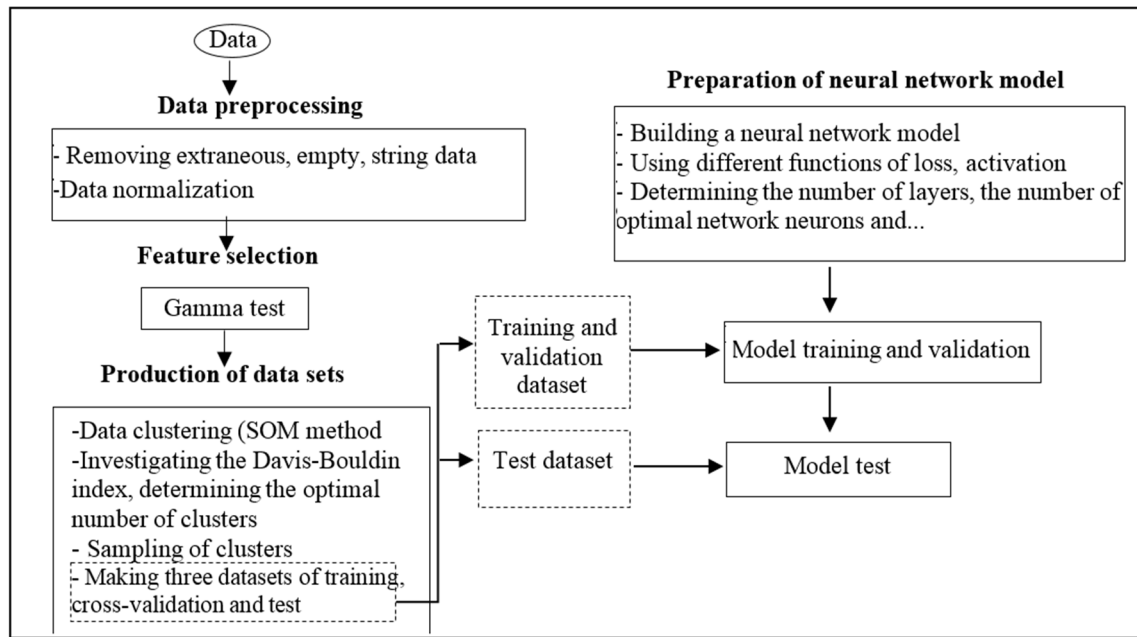
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_M - S_O)^2} \quad (11)$$

$$MAE = \frac{\sum_{i=1}^n |S_O - S_M|}{n} \quad (12)$$

$$NS^{-1} = \frac{\sum_{i=1}^n (S_M - S_O)^2}{\sum_{i=1}^n (S_O - \bar{S}_O)^2} \quad (13)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (S_O - \bar{S}_O)(S_M - \bar{S}_M)}{\sqrt{\sum_{i=1}^n (S_O - \bar{S}_O)^2 \sum_{i=1}^n (S_M - \bar{S}_M)^2}} \right]^2 \quad (14)$$

$$PBIAS = \frac{\sum_{i=1}^n (S_O - S_M)}{\sum_{i=1}^n (S_O)} * 100 \quad (15)$$



شکل ۴- روندنمای مراحل مختلف پژوهش
Fig. 4. Flowchart of different stages of the research

نتایج خوشه‌بندی و تحلیل آماری داده‌ها: با استفاده از الگوریتم خوشه‌بندی نگاشت خود سازمان‌ده و شاخص دیویس بولدین، تعداد خوشه‌های بهینه (K) برای داده‌های مورد مطالعه، ۱۴ خوشه تعیین شد (شکل ۵).

جدول ۳- نتایج آزمون گاما
Table 3. Gamma test results


Row	Combination of input variables	Gamma(Γ)	V_{ratio}
1	$Q, Q_{w-0}, Q_{w-2}, Q_{w-3}, Q_{w-4}, P_{-0}, P_{-3}$	0.049871	0.19948
2	$Q, Q_{w-0}, Q_{w-2}, Q_{w-3}, Q_{w-4}, P_{-1}, P_{-3}$	0.05026	0.20104
3	$Q, Q_{w-0}, Q_{w-2}, Q_{w-3}, P_{-3}$	0.052616	0.21046
4	$Q, Q_{w-0}, Q_{w-1}, Q_{w-4}$	0.12835	0.51341

نتایج و بحث

نتایج آزمون گاما: به کمک آزمون گاما، کلیه ترکیبات غیرتکراری متغیرهای ورودی مورد بررسی قرار گرفته و بر اساس آماره گاما (Γ) و V_{ratio} بهترین ترکیب متغیرهای ورودی برای شبیه‌سازی رسوب معلق تعیین شد. در جدول ۳، سه نمونه از بهترین ترکیبات متغیرهای ورودی محاسبه‌ای آورده شده است.

لازم به توضیح است که در پژوهش حاضر، تنها از ترکیب متغیرهای ردیف اول در شبیه‌سازی رسوب معلق استفاده شده است.

نتایج خوشه‌بندی و تحلیل آماری داده‌ها: با استفاده از الگوریتم خوشه‌بندی نگاشت خود سازمان‌ده و شاخص دیویس بولدین، تعداد خوشه‌های بهینه (K) برای داده‌های مورد مطالعه، ۱۴ خوشه تعیین شد (شکل ۵).



شکل ۵- تعیین تعداد بهینه خوشه‌ها با استفاده از خوشه‌بندی نگاشت خود سازمان‌ده و شاخص دیویس-بولدین در ایستگاه رامیان
Fig. 5. Determining the optimal number of clusters using self-organized map clustering and Davis-Bouldin index in Ramyan station

نتایج پارامترهای آماری (معیارهای مرکزیت و پراکندگی داده‌ها) و همچنین، نتایج مربوط به مقایسه توزیع داده‌ها (نتایج آزمون KS) در سه مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون، برای متغیرهای مورد استفاده در شبیه‌سازی رسوب معلق ایستگاه هیدرومتری رامیان در جدول‌های ۴ و ۵ آمده است.

جدول ۴- پارامترهای آماری مجموعه داده‌های واسنجی، اعتبارسنجی متقاطع و آزمون ایستگاه هیدرومتری رامیان

Table 4. Statistical parameters of the calibration, cross-validation and test data sets of the Ramyan hydrometry station

Model variables and datasets	Statistical parameters					
	Average	Standard deviation	Maximum	Minimum	Skewness	Coefficient of variation (percent)
Instantaneous discharge (Q) (m^3s^{-1})						
Training set	1.48	2.3	12.74	0	2.66	155.51
Cross validation set	1.75	2.55	11.79	0.02	2.38	145.67
Test set	2.01	2.89	13.46	0	2.57	143.49
Average daily discharge (Q_{w-0}) (m^3s^{-1})						
Training set	1.51	2.72	24	0	4.01	179.42
Cross validation set	1.69	3.15	20.3	.01	4.4	186.84
Test set	2.45	4.28	25.4	0	3.65	174.95
Average discharge 2 days ago (Q_{w-2}) (m^3s^{-1})						
Training set	1.84	3.67	26.7	0	4.13	199.76
Cross validation set	1.51	3.17	21.1	0	4.87	209.88
Test set	2.02	2.58	12.3	0.01	2.01	127.93
Average discharge 3 days ago (Q_{w-3}) (m^3s^{-1})						
Training set	1.77	4.2	48	0	7.04	236.73
Cross validation set	1.21	1.54	5.8	0	1.6	127.68
Test set	2.3	4.39	30.4	0	5.1	190.98
Average discharge 4 days ago (Q_{w-4}) (m^3s^{-1})						
Training set	1.44	2.7	27.7	0	5.08	188.23
Cross validation set	1.37	1.98	9.72	0	2.26	144.09
Test set	2	2.85	14.4	0	2.5	142.11
Average daily rainfall ($p_{.0}$) mm						
Training set	2.36	8.79	65.56	0	5.32	372.01
Cross validation set	2.37	6.38	34.44	0	3.4	269.68
Test set	1.38	5.96	42.62	0	6.36	431.53
Average daily rainfall 3 days ago ($p_{.3}$) mm						
Training set	2.35	7.45	74.32	0	5.48	317.17
Cross validation set	1.68	4.91	24.73	0	3.42	291.87
Test set	2.85	7.04	30.51	0	2.69	247.19
Suspended sediment concentration (ssc) ($mg l^{-1}$)						
Training set	1282.99	2754.01	23456	4.27	4.82	214.65
Cross validation set	960.72	1609.64	8935.67	31.88	3.44	167.55
Test set	898.21	1703.18	11484	29.06	4.92	189.62

شده است که مربوط به کل دوره آماری بوده و مربوط به یک دوره زمانی خاص نیستند.

در جدول ۵، ستون مربوط به شاخص نرم‌افزار متلب (h)، می‌تواند دارای دو مقدار صفر و یک باشد. مقدار صفر بیانگر یکسان بودن توزیع داده‌ها در دو مجموعه مورد مقایسه، و مقدار یک، بیانگر غیریکسان بودن توزیع است. با توجه به مقادیر صفر محاسبه شده در همه مقایسه‌ها، می‌توان نتیجه‌گیری کرد که توزیع متغیرهای نظیر در هر دو مجموعه مورد مقایسه، یکسان بوده است.

همان‌طور که نتایج جدول ۴، نشان می‌دهد، پارامترهای آماری متغیرهای موجود در سه مجموعه داده آموزش، اعتبارسنجی متقابل و آزمون، به یکدیگر نسبتاً نزدیک بوده‌اند که بیانگر آن است، اجرای عملیات خوشه‌بندی و نمونه‌گیری از آن‌ها سبب شده است تا داده‌های سه مجموعه، شبیه به هم انتخاب شوند. این مساله همان‌طور که پیش‌تر بیان شد، موجب افزایش قدرت تعمیم‌دهی مدل‌ها شده و بیانگر آن است که آموزش، اعتبارسنجی و آزمون مدل‌ها با داده‌هایی انجام

جدول ۵- نتایج آزمون ناپارامتری دو نمونه‌ای KS بر روی داده‌های سه مجموعه آموزش، اعتبارسنجی متقاطع و آزمون در ایستگاه هیدرومتری رامیان

Table 5. The results of two-sample KS non-parametric test on the data of three sets of training, cross-validation and test at the Ramyan hydrometric station

Variable	The sets to be compared	P-value	Dc or k statistic (calculated)**	MATLAB software index (h)
Instantaneous discharge (Q) (m^3s^{-1})	Training-Cross validation	0.72	0.1	0
Instantaneous discharge (Q) (m^3s^{-1})	Training-Test	0.02	0.22	0
Instantaneous discharge (Q) (m^3s^{-1})	Cross validation-Test	0.68	0.13	0
Average daily discharge (Q_{w-0}) (m^3s^{-1})	Training-Cross validation	0.81	0.09	0
Average daily discharge (Q_{w-0}) (m^3s^{-1})	Training-Test	0.01	0.24	0
Average daily discharge (Q_{w-0}) (m^3s^{-1})	Cross validation-Test	0.38	0.17	0
Average discharge 2 days ago (Q_{w-2}) (m^3s^{-1})	Training-Cross validation	0.91	0.08	0
Average discharge 2 days ago (Q_{w-2}) (m^3s^{-1})	Training-Test	0.1	0.18	0
Average discharge 2 days ago (Q_{w-2}) (m^3s^{-1})	Cross validation-Test	0.12	0.22	0
Average discharge 3 days ago (Q_{w-3}) (m^3s^{-1})	Training-Cross validation	0.95	0.08	0
Average discharge 3 days ago (Q_{w-3}) (m^3s^{-1})	Training-Test	0.03	0.21	0
Average discharge 3 days ago (Q_{w-3}) (m^3s^{-1})	Cross validation-Test	0.3	0.18	0
Average discharge 4 days ago (Q_{w-4}) (m^3s^{-1})	Training-Cross validation	0.95	0.08	0
Average discharge 4 days ago (Q_{w-4}) (m^3s^{-1})	Training-Test	0.12	0.17	0
Average discharge 4 days ago (Q_{w-4}) (m^3s^{-1})	Cross validation-Test	0.21	0.2	0
Average daily rainfall (p_{-0}) mm	Training-Cross validation	0.98	0.07	0
Average daily rainfall (p_{-0}) mm	Training-Test	1	0.05	0
Average daily rainfall (p_{-0}) mm	Cross validation-Test	0.95	0.1	0
Average daily rainfall 3 days ago (p_{-3}) mm	Training-Cross validation	1	0.06	0
Average daily rainfall 3 days ago (p_{-3}) mm	Training-Test	1	0.06	0
Average daily rainfall 3 days ago (p_{-3}) mm	Cross validation-Test	1	0.07	0
Suspended sediment concentration (ssc) ($mg l^{-1}$)	Training-Cross validation	0.64	0.11	0
Suspended sediment concentration (ssc) ($mg l^{-1}$)	Training-Test	0.1	0.18	0
Suspended sediment concentration (ssc) ($mg l^{-1}$)	Cross validation-Test	0.09	0.23	0

** معنی‌داری در سطح خطا یک درصد (یک درصد α) با اطمینان ۹۹ درصد
Significance at the error level of one percent ($\alpha = 1\%$) with 99 percent confidence

تعداد بهینه نرون‌های لایه پنهان مدل‌های شبکه عصبی با آزمون و خطا و کمینه کردن خطای شبکه در تکرارهای زیاد، تعیین شده است. لازم به توضیح است که آموزش، اعتبارسنجی و آزمون کلیه مدل‌ها با داده‌های یکسان (مجموع داده‌های آموزش، ارزیابی متقاطع و آزمون) انجام شده است.

نتایج مدل‌سازی: نتایج ساخت، آموزش و ارزیابی مدل‌های مختلف شبکه عصبی در ایستگاه مورد مطالعه در جدول ۶، به‌طور خلاصه آورده شده است. در این جدول، بهترین ساختار شبکه عصبی، نوع توابع فعال‌سازی و زیان، به همراه شاخص‌های ارزیابی صحت‌سنجی مدل‌ها ارائه شده است.

دیگر مدل‌ها در رتبه ۱ و پس از آن‌ها، مدل‌های M3 و M1 به ترتیب، در رتبه‌های بعدی هستند.

با توجه به نتایج مندرج در جدول ۶، مدل‌های (M5) M-A-ReLU-Huber (M2) و M-A-Tanh-Huber با داشتن شاخص‌های صحت‌سنجی مناسب‌تر نسبت به

جدول ۶- ساختار و نتایج ارزیابی مدل‌های مختلف شبکه عصبی در برآورد غلظت رسوب معلق ایستگاه هیدرومتری رامیان با داده‌های آزمون

Table 6. The structure and evaluation results of different neural network models in estimating the suspended sediment concentration of Ramian hydrometric station with test data

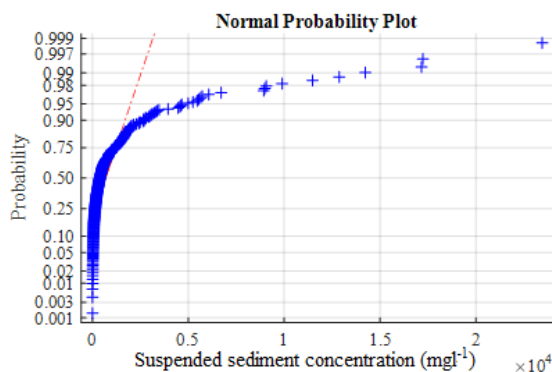
Model name	Abbreviated name of the model	Network structure	Activation function	Loss function	MAE (mg l ⁻¹)	RMSE (mg l ⁻¹)	NSE	R ²
M-A-ReLU-MSE	M1	1:14:1	ReLU	MSE	391.03	631.98	0.86	0.89
M-A-ReLU-Huber	M2	1:14:1	ReLU	Huber	368.68	589.42	0.88	0.88
M-A-ReLU-MAE	M3	1:14:1	ReLU	MAE	381.54	603.65	0.87	0.88
M-A-Tanh-MSE	M4	1:14:1	Tanh	MSE	466.16	1038.62	0.62	0.71
M-A-Tanh-Huber	M5	1:14:1	Tanh	Huber	368.94	597.89	0.82	0.88
M-A-Tanh-MAE	M6	1:14:1	Tanh	MAE	463.55	1083.67	0.59	0.7
M-A-Sigmoid-MSE	M7	1:14:1	Sigmoid	MSE	532.13	1134.34	0.55	0.67
M-A-Sigmoid-Huber	M8	1:14:1	Sigmoid	Huber	511.11	972.99	0.67	0.7
M-A-Sigmoid-MAE	M9	1:14:1	Sigmoid	MAE	508.75	1072.53	0.6	0.7

کمیت نامناسب داده‌ها است. داده‌ها عمدتاً مربوط به دبی پایه با مقادیر رسوب کم بوده است و داده‌های شرایط سیلابی با رسوب بالا کمتر ثبت می‌شوند. با توجه به آن‌که در محاسبه شاخص MSE، از مربعات خطا استفاده می‌شود، لذا، وجود خطاهای بزرگ که معمولاً در برآورد داده‌های بزرگ رسوب به وسیله مدل به وجود می‌آید، موجب می‌شود تا فاصله این شاخص از شاخص MAE که از قدر مطلق خطا استفاده می‌کند، زیاد شود (Legates and McCabe, 1999).

تابع خطای MSE، زمانی که در آموزش مدل‌ها استفاده می‌شود، خطای کمتر از واحد (یک) را کاهش داده است و برعکس، با بزرگ شدن خطا، مقدار آن را بیش از حد واقعی محاسبه می‌کند. لذا، در صورتی که تعداد معدودی داده پرت و بزرگ در مجموعه داده‌های آموزش مدل حضور داشته باشند، وزن این داده‌ها در مقایسه با سایر داده‌ها بسیار بیشتر شده و در نتیجه ضرایب و پارامترهای مدل به صورتی محاسبه می‌شوند که مقدار پیش‌بینی‌های مدل (در همه اوقات) به سمت مقادیر پرت متمایل شود.

لازم به توضیح است که داده‌های پرت رسوب به سادگی قابل حذف شدن از مجموعه داده‌های رسوب

یکی از نکات مهم در جدول ۶، آن است که اختلاف بین مقادیر شاخص MAE و RMSE در همه مدل‌ها زیاد است. این مساله نشانه‌ای از وجود داده‌های پرت و دور افتاده در میان داده‌های رسوب‌سنجی بوده که به تبع آن، توزیع داده‌ها از حالت نرمال خارج شده به سمت راست کشیده می‌شوند (چولگی به سمت راست) (جدول ۲ و شکل ۶) (Altunkaynak, 2009).



شکل ۶- نمودار احتمال نرمال داده‌های غلظت رسوب معلق

Fig. 6. Normal probability diagram of suspended sediment concentration data

یکی از مشکلات داده‌های رسوب‌سنجی ایستگاه‌های هیدرومتری مخصوصاً ایستگاه‌های هیدرومتری کشور، وجود چولگی بوده که به‌طور معمول ناشی از کیفیت و

ReLU و تانژانت هایپربولیک (Tanh) در آموزش مدل‌ها، بهتر از تابع فعال‌سازی سیگموئید (Sigmoid) بوده است. در ادامه، با استفاده از نمودار تیلور^۴، تحلیل بصری از مقایسه صحت‌سنجی مدل‌های نه‌گانه ارائه خواهد شد.

نمودار(های) تیلور، نمودار(های) ریاضی هستند که به کمک آن‌ها می‌توان، مدل‌های مختلفی که یک سامانه، فرایند یا پدیده را نمایش می‌دهند، به صورت گرافیکی با یکدیگر مقایسه کرد (Taylor, 2001) (شکل ۷). به طور خلاصه در نمودار تیلور، سه پارامتر ضریب همبستگی، ریشه میانگین مربعات خطا^۵ و انحراف معیار برای مدل‌های مورد مطالعه قابل نمایش بصری و مقایسه هستند.

در شکل ۷، این سه پارامتر برای نه مدل برآوردگر رسوب معلق، نشان داده شده است. در این نمودار، ضریب همبستگی به صورت شعاع‌های دایره (خطوط آبی رنگ خط‌چین) و روی قوس دایره، مقادیر انحراف معیار داده‌ها بر روی محورهای افق و عمودی به صورت دایره‌های متحدالمرکز با مرکزیت مبدا مختصات (دایره‌های خاکستری رنگ نقطه‌چین) و شاخص RMSD به صورت دایره‌های متحدالمرکز با مرکزیت انحراف معیار داده‌های مشاهداتی (دایره‌های سبز رنگ خط‌چین) نشان داده شده است.

در این رابطه، واژه ref اشاره به مقدار انحراف معیار داده‌های رسوب معلق گروه آزمون داشته و ربع قوس قرمز رنگ، مقدار این شاخص را به منظور مقایسه مدل‌ها نشان می‌دهد. استفاده از نمودار تیلور، برخی از جنبه‌های پنهان در کارایی مدل‌ها را آشکار می‌کند. به عنوان مثال، مدل M1 به لحاظ شاخص‌های صحت‌سنجی (جدول ۶) بسیار به مدل M3 نزدیک است، با این حال، با دقت در نمودار تیلور مشخص می‌شود که مقدار انحراف معیار داده‌های برآورد شده رسوب معلق این مدل در مقایسه با مقدار انحراف معیار مرجع (ref) فاصله بیشتری دارد.

سنجی نبوده‌اند (به خصوص در صورتی که از مخدوش نبودن آن‌ها به خطا اطمینان وجود داشته باشد) و اطلاعات با ارزشی را در مورد رسوب رودخانه بیان می‌کنند. در چنین شرایطی، لازم است که به هنگام آموزش یا واسنجی مدل‌ها، به ماهیت داده‌های مورد پردازش توجه کافی شده و از پیش پردازش‌های لازم (نظیر تبدیلات لگاریتمی) و یا به‌کارگیری توابع مناسب خطا (هزینه یا زیان)^۱ به‌عنوان تابع هدف^۲ استفاده شود. استفاده از تابع MAE، تا حدی می‌تواند خطای حاصل از چولگی داده‌ها (ناشی از بزرگی داده‌های پرت) را برطرف کند. به این صورت که خطاهای بزرگ و کوچک، وزن یکسانی داشته، با افزایش بزرگی داده، مقدار بزرگی خطا نیز به صورت خطی افزایش می‌یابد.

به عبارتی دیگر، این تابع به داده‌های پرت حساس نیست (Muleta, 2011). البته استفاده از این تابع در فرایند آموزش مدل و به‌عنوان تابع هدف نیز، با چالش‌هایی روبه‌رو است و چنانچه در مجموعه داده‌های رسوب‌سنجی، بخش کوچکی از داده‌ها، دارای مقادیر زیاد رسوب (در این حالت ممکن است داده‌ها، داده‌های مخدوش و غیرواقعی نباشند) و بخش بزرگی دارای مقادیر کم باشند، کارایی تابع پایین آمده است، به نحوی که کمینه‌سازی این تابع، منجر به تولید پارامترهایی از مدل خواهد شد که خطای پیش‌بینی برای داده‌هایی با مقادیر بالای رسوب را افزایش می‌دهد. به عبارت ساده‌تر، مدل در برآورد مقادیر رسوب بزرگ دچار خطای بیشتری می‌شود.

راه حل دیگری که در این شرایط وجود دارد، استفاده از تابع زیان Huber^۳ یا میانگین خطای قدر مطلق هموار شده بوده است که حالتی حد واسط بین دو تابع MSE و MAE است. این تابع، در خطاهای زیاد، شبیه تابع MAE و در خطاهای کوچک، مشابه تابع MAE رفتار می‌کند. نکته دیگری که از جدول ۶، قابل استنباط است آن است که کارایی دو تابع فعال‌سازی

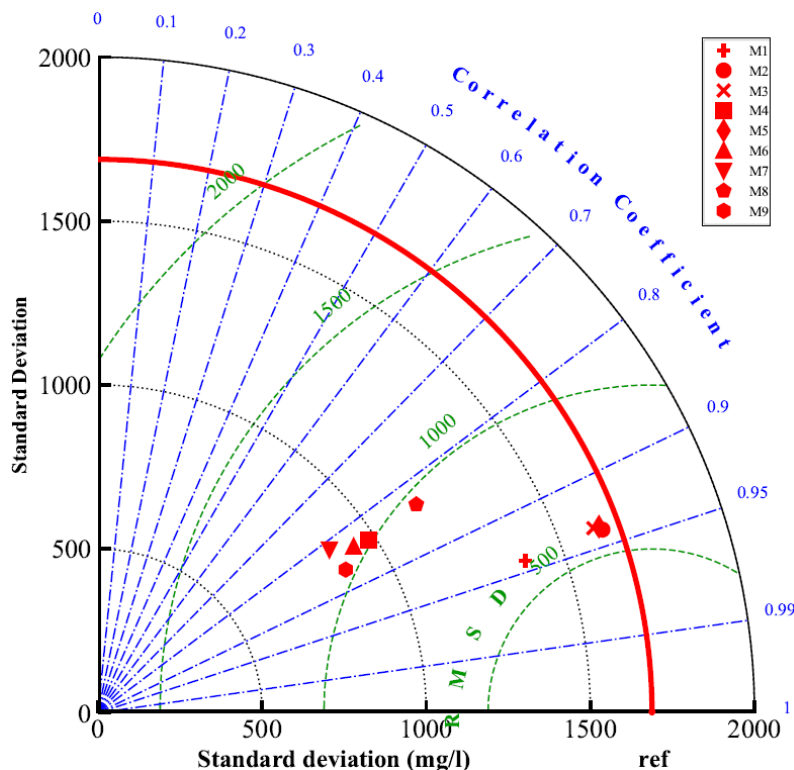
¹ Loss function

² Objective function

³ Smooth Mean Absolute Error

⁴ Taylor diagram

⁵ Root Mean Square Difference (RMSD)



شکل ۷- نمودار تیلور و مقایسه شاخص‌های صحت‌سنجی مدل‌های نه‌گانه برآوردگر رسوب معلق ایستگاه هیدرومتری رامیان
 Fig. 7. Taylor diagram and comparison of validation indices of nine models of suspended sediment estimator of Ramyan hydrometric station

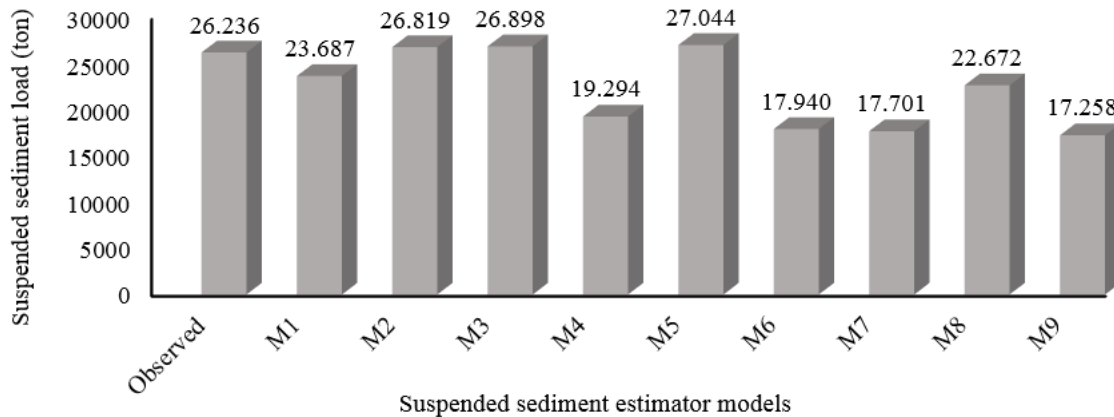
۲۷۰۴۳/۷ تن و در مدل‌های M8, M7, M6, M4, M1 و M9، به ترتیب با ۱۳/۶، ۳۲/۵، ۳۱/۶، ۲۶/۵، ۹/۷ و ۳۴/۲ درصد کم برآوردی مقادیر ۱۹۲۹۳/۸، ۲۳۶۸۶/۸، ۱۷۲۵۷/۵ و ۲۲۶۷۲، ۱۷۷۰۰/۹، ۱۷۹۳۹/۶ تن است. در مجموع، با مقایسه شاخص‌های صحت‌سنجی و مقدار درصد اریبی (بایاس) مدل‌ها می‌توان نتیجه‌گیری کرد که کارایی مدل M2 (M-A-ReLU-Huber) از دیگر مدل‌ها بهتر بوده است و بنابراین، این مدل به‌عنوان بهترین مدل برآوردگر رسوب معلق رودخانه قره‌چای (در محل ایستگاه هیدرومتری رامیان) انتخاب شد.

علاوه بر شاخص‌های صحت‌سنجی، مدل‌های مختلف شبکه عصبی از نظر مقدار برآورد کل رسوب معلق و میزان بیش برآوردی یا کم برآوردی برای داده‌های آزمون نیز با یکدیگر مورد مقایسه گرفتند که نتایج آن‌ها در جدول ۷ و شکل ۸، نشان داده شده است. همان‌طور که در جدول ۷ آمده است، مجموع وزنی رسوب معلق مشاهده‌ای در ایستگاه هیدرومتری رامیان برای داده‌های آزمون ۲۶۲۳۶/۲ تن است که این مقدار در مدل‌های M2، M3 و M5، به ترتیب با ۲/۲، ۲/۵ و ۳/۱ درصد بیش برآوردی مقادیر ۲۶۸۱۹/۳، ۲۶۸۹۸/۱ و

جدول ۷- مجموع کل رسوب معلق مشاهده‌ای و برآورد شده به‌وسیله مدل‌های مختلف برای داده‌های آزمون

Table 7. Total observed suspended sediment and estimated by different models for test data

The total amount of observed suspended sediment (tons) / model name	M1	M2	M3	M4	M5	M6	M7	M8	M9
26236.2	23686.8	26819.3	26898.1	19293.8	27043.7	17939.6	17700.9	22672	17257.5
PBIAS (%)	9.7	-2.2	-2.5	26.5	-3.1	31.6	32.5	13.6	34.2



شکل ۸- نمودار مجموع رسوب معلق مشاهده‌ای و برآورد شده به‌وسیله مدل‌های مختلف برای داده‌های آزمون
 Fig. 8. Diagram of total suspended sediment observed and estimated by different models for test data

نتیجه‌گیری

در شبیه‌سازی رسوب معلق، اغلب از متغیر دبی جریان به‌عنوان تنها متغیر پیش‌بینی‌کننده رسوب معلق استفاده می‌شود، این در حالی است که در حوضه‌هایی با رژیم‌های بارانی، یا بارانی-برفی، نقش بارش در تولید رواناب‌های سطحی و فرسایش خاک بسیار با اهمیت بوده و نقش مهمی در تولید و انتقال رسوب حوضه دارد (Ayes Rivera et al., 2019; Shams et al., 2020).

همچنین، نتایج به‌دست آمده از برخی از پژوهش‌ها نشان می‌دهد که در فصول مختلف سال، دبی جریان به تنهایی، نمی‌تواند تغییرات رسوب رودخانه را به‌درستی تبیین کند. در این رابطه، Rodríguez-Blanco et al., (۲۰۱۰) بیان می‌کنند که دبی رودخانه تنها ۱۹ درصد واریانس رسوب معلق رودخانه را تشریح می‌کند. نتایج پژوهش‌های انجام شده به‌وسیله دیگر محققان نظیر Ulke et al. (2009), Melesse et al., (2011), Tayfur et al., (۲۰۱۲) نیز موید مطلب یاد شده است.

اگرچه استفاده از داده‌های بارش اخذ شده از ایستگاه‌های باران‌سنجی زمینی، نقش موثری در افزایش کارایی مدل‌های داده مبنای برآورد رسوب معلق داشته است، با این حال، تهیه صدها لایه مکانی توزیعی بارش روزانه از داده‌های نقطه‌ای ایستگاه‌های زمینی، استفاده از این متغیر را در شبیه‌سازی رسوب معلق حوضه با مشکلات فراوان نظیر کمبود یا نامناسب بودن توزیع مکانی ایستگاه‌های باران‌سنجی (Cho et al., 2009)،

نواقص آماری، به‌کارگیری روش‌های میان‌یابی نامناسب و زمان‌بر بودن انجام محاسبات، روبه‌رو ساخته است. لذا، در عمل، اغلب از متغیر دبی جریان رودخانه به‌عنوان متغیر پیش‌بینی‌کننده رسوب استفاده شده است و کمتر از بارش استفاده می‌شود. یکی از راه‌حل‌های برون‌رفت از مشکل یاد شده که در پژوهش حاضر به آن پرداخته شد استفاده از داده‌های ماهواره‌ای CHIRPS است که برای اولین بار در این پژوهش مورد بررسی قرار گرفت. این داده‌ها که از سال ۱۹۸۱ میلادی در دسترس است، به سادگی می‌تواند برای شبیه‌سازی رسوب معلق یا دیگر کاربردها مرتبط با حوزه‌های آبخیز مورد استفاده قرار گیرد.

نکته مهم دیگر که لازم است در شبیه‌سازی رسوب معلق به آن توجه شود، وجود چولگی زیاد در داده‌های رسوب‌سنجی بوده است (هم رسوب معلق و هم دبی جریان) که عدم توجه به آن در فرایند آموزش (یا واسنجی) و آزمون مدل‌ها منجر به ساخت مدل‌های ضعیف به لحاظ کارایی و وجود عدم قطعیت در صحت نتایج آن‌ها خواهد شد. در این رابطه لازم است از تبدیلات لگاریتمی و یا توابع مناسب فعال‌سازی و زیان در فرایند آموزش استفاده شود که در این پژوهش به ترتیب دو تابع ReLU و Huber پیشنهاد شد.

از نکات مهم دیگر، توجه به قدرت تعمیم‌دهی مدل‌های داده مبنای است که تا اندازه زیادی وابسته به داده‌های استفاده شده در فرایند واسنجی یا آموزش آن

آمده در این پژوهش در دیگر ایستگاه‌های رسوب‌سنجی کشور نیز استفاده شود.

تشکر و قدردانی

پژوهش انجام شده با حمایت مالی و معنوی پژوهشکده حفاظت خاک و آبخیزداری انجام شده است که بدین وسیله از کلیه عزیزانی که ما را در این راه کمک نموده‌اند، تشکر می‌شود.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مساله مورد تایید همه نویسندگان است.

ها است. این داده‌ها باید به‌گونه‌ای انتخاب شوند که ضمن آن‌که معرف داده‌ها در کل دوره آماری هستند، با دیگر مجموعه‌های داده (نظیر مجموعه‌های ارزیابی یا آزمون)، مشابه و از توزیع یکسان برخوردار باشند. در این راستا، در پژوهش حاضر با استفاده از شبکه عصبی نگاشت خود سازمان‌ده اقدام به تهیه مجموعه‌های همگن و مشابه از داده‌ها برای آموزش و آزمون مدل‌ها شد که نتایج این بخش از پژوهش با کار Li et al., (2010) مطابقت دارد.

با توجه به نتایج به‌دست‌آمده از پژوهش حاضر و به‌منظور افزایش کارایی مدل‌های شبکه عصبی مصنوعی در برآورد رسوب معلق ایستگاه‌های هیدرومتری حوزه‌های آبخیز، پیشنهاد می‌شود از تجارب به‌دست

منابع مورد استفاده

- Ahmadi, M., Dadashi Roudbari, A., Deyrmajai, A., 2020. Runoff estimation using ihacres model based on chirps satellite data and cmip5 models, case study: Gorganroud Basin-Aq Qala area. *Iran J Soil Water Res.* 51(3), 659-671.
- Altunkaynak, A., 2009. Sediment load prediction by genetic algorithms. *Adv. Eng. Softw.* 40, 928-934.
- Ayes Rivera, I., Callau Poduje, A.C., Molina-Carpio, J., Ayala, J.M., Armijos Cardenas, E., Espinoza-Villar, R., Espinoza, J.C., Gutierrez-Cori, O., Filizola, N., 2019. On the relationship between suspended sediment concentration, rainfall variability and groundwater: an empirical and probabilistic analysis for the Andean Beni River, Bolivia (2003–2016). *Water* 11(12), 2497.
- Bowden, G.J., Maier, H.R., Dandy, G.C., 2002. Optimal division of data for neural network models in water resources applications. *Water Resour. Res.* 38(2), 1-2.
- Buyukyildiz, M., Kumcu, S.Y., 2017. An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models. *Water Resour. Manag.* 31(4), 1343-1359.
- Chen, X.Y., Chau, K.W., 2019. Uncertainty analysis on hybrid double feedforward neural network model for sediment load estimation with LUBE method. *Water Resour. Manag.* 33(10), 3563-3577.
- Chiang, J.L., Tsai, K.J., Chen, Y.R., Lee, M.H., Sun, J.W., 2014. Suspended sediment load prediction using support vector machines in the Goodwin Creek Experimental Watershed. *Proceedings of the EGU General Assembly Conference, Munich, Germany.*
- Cho, J., Bosch, D., Lowrance, R., Strickland, T., Vellidis, G., 2009. Effect of spatial distribution of rainfall on temporal and spatial uncertainty of SWAT output. *Transactions of the ASABE* 52(5), 1545-1556.
- Choubin, B., Malekian, A., 2017. Combined gamma and M-test-based ANN and ARIMA models for groundwater fluctuation forecasting in semiarid regions. *Environ. Earth Sci.* 76(15), 1-10.
- Cobaner, M., Unal, B., Kisi, O., 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. *J. Hydrol.* 367(1-2), 52-61.
- Duan, Z., Tuo, Y., Liu, J., Gao, H., Song, X., Zhang, Z., Yang, L., Mekonnen, D.F., 2019. Hydrological evaluation of open-access precipitation and air temperature datasets using SWAT in a poorly gauged basin in Ethiopia. *J. Hydrol.* 569, 612-626.
- Durrant, P.J., 2001. Wingamma a non-linear data analysis and modelling tool with applications to flood prediction. PhD Thesis, Cardiff University.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., Michaelsen, J., 2015. The climate hazards infrared precipitation with stations-a new environmental record for monitoring extremes. *Sci. Data* 2(1), 1-21.

- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Netw.* 2(5), 359-366.
- Jones, A.J., Evans, D., Margetts, S., Durrant, P.J., 2002. Heuristic and optimization for knowledge discovery. Chapter IX, Idea Group Publishing, Hershey, 142-162 pages.
- Joshi, R., Kumar, K., Adhikari, V.P.S., 2016. Modelling suspended sediment concentration using artificial neural networks for Gangotri glacier. *Hydrol. Process.* 30(9), 1354-1366.
- Kaufman, L., Rousseeuw, P.J., 2009. Finding groups in data: an introduction to cluster analysis, Vol. 344. John Wiley and Sons, New Jersey, USA.
- Kaveh, K., Kaveh, H., Bui, M.D., Rutschmann, P., 2021. Long short-term memory for predicting daily suspended sediment concentration. *Eng. Comput.* 37(3), 2013-2027.
- Khan, M.Y.A., Tian, F., Hasan, F., Chakrapani, G.J., 2019. Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *Int. J. Sediment Res.* 34(2), 95-107.
- Kişİ, Ö., Fedakar, H.I., 2014. Modeling of suspended sediment concentration carried in natural streams using fuzzy genetic approach. *Computational Intelligence Techniques in Earth and Environmental Sciences*, Springer, Dordrecht.
- Kisi, O., Shiri, J., 2012. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Comput. Geosci.* 43, 73-82.
- Kohonen, T., 1998. The self-organizing map. *Neurocomputing* 21(1), 1-6.
- Koncar, N., 1997. Optimisation methodologies for direct inverse neurocontrol. PhD Thesis, University of London.
- Legates, D.R., McCabe, G.J., 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water Resour. Res.* 35(1), 233-241.
- Li, X., Nour, M.H., Smith, D.W., Prepasc, A.A., 2010. Neural networks modeling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environ. Technol.* 31(5), 495-510
- Mansourfar, K., 2017. Advanced statistical methods: using applied software. University of Tehran Press (in Persian).
- May, R.J., Maier, H.R., Dandy, G.C., 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Netw.* 23, 283-294.
- Melesse, A.M., Ahmad, S., McClain, M.E., Wang, X., Lim, Y.H., 2011. Suspended sediment load prediction of river systems: an artificial neural network. *Agric. Water Manag.* 98(5), 855-866.
- Muleta, M.K., 2011. Model performance sensitivity to objective function during automated calibrations. *J. Hydrol. Eng.* 17(6), 756-767.
- Nour, M.H., Smith, D.W., Gamal El-Din, M., Prepas, E.E., 2006. Neural networks modelling of streamflow, phosphorus, and suspended solids: application to the Canadian Boreal forest. *Water Sci. Technol.* 53(10), 91-99.
- Olyaie, E., Banejad, H., Chau, K.W., Melesse, A.M., 2015. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. *Environ. Monit. Assess.* 187(4), 1-22.
- Rezai Banafshe, M., Feyzolahpour, M., Sadrafshary, S., 2013. Using neural fuzzy inference system to estimate sediment load and a comparison with MLR and SRC models in Ghranghu River Basin. *Phys. Geog. Res. Quarterly* 45(2), 77-90.
- Rodríguez-Blanco, M.L., Taboada-Castro, M.M., Palleiro-Suárez, L., Taboada-Castro, M.T., 2010. Temporal changes in suspended sediment transport in an Atlantic Catchment, NW Spain. *Geomorphology* 123(1), 181-188.
- Sahoo, B.B., Dalai, C., Srikanth, B., Bhushan, M., 2022. Evaluation of daily suspended sediment load using deep learning models. *Research Square*, in Press.
- Shams, S., Ratnayake, U., Rahman, E.A., Alimin, A.A., 2020. Analysis of sediment load under combined effect of rainfall and flow. *Proceedings of the Second International Conference on Civil and Environmental Engineering*, Langkawi, Kedah, Malaysia.
- Sulugodu, B., Deka, P.C., 2019. Evaluating the performance of CHIRPS satellite rainfall data for streamflow forecasting. *Water Resour. Manag.* 33(11), 3913-3927.
- Tabatabaei, M., Salehpour Jam, A., Hosseini, S.A., 2019. Suspended sediment load prediction using non-dominated sorting genetic algorithm II. *Int. Soil Water Conserv. Res.* 7(2), 119-129.

- Tayfur, G., 2012. *Soft computing in water resources engineering: artificial neural networks, fuzzy logic and genetic algorithms*. WIT Press.
- Tayfur, G., Guldal, V., 2006. Artificial neural networks for estimating daily total suspended sediment in natural streams. *Hydrol. Res.* 37(1), 69-79.
- Taylor, K.E., 2001. Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res. Atmos.* 106(D7), 7183-7192.
- Teixeira, L.C., Mariani, P.P., Pedrollo, O.C., dos Reis Castro, N.M., Sari, V., 2020. Artificial neural network and fuzzy inference system models for forecasting suspended sediment and turbidity in basins at different scales. *Water Resour. Manag.* 34(11), 3709-3723.
- Ulke, A., Tayfur, G., Ozkul, S., 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. *J. Hydrol. Eng.* 14, 954-965.