

Research Article

Agricultural Engineering., 46(1) (2023) 101-119
DOI: 10.22055/AGEN.2023.44206.1677

ISSN (P): 2588-526X

ISSN (E): 2588-5944

Simulation of daily suspended sediment of Roud-Zard River using different machine learning techniques

H. Ghafari ^{1,*} and H. Ameri Khah ²

1. Assistant Professor, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
2. Instructor, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

Received: 19 March 2023

Accepted: 14 June 2023

Abstract

Introduction: The processes of soil erosion and sediment transport along rivers are the main causes of some socio-economic and environmental problems, such as a reduction in water quality, storage capacity of dams, destruction of aquatic habitats, failure of hydroelectric power plants, and soil degradation. Therefore, understanding the sedimentation status of watersheds is crucial for the effective management of soil and water resources. However, due to the lack of technical and human resources, continuous recording of sediment data is not possible in most sediment measuring stations, and sediment data are recorded only for a few days. In such a situation, a model that can estimate the amount of sediment load using auxiliary variables such as stream discharge and rainfall becomes crucial. Today, it is believed that techniques based on artificial intelligence have a much greater ability to uncover hidden relationships between variables than classical methods and are thus very useful and effective in modeling natural processes.

Materials and methods: In this study, various machine learning techniques, including Artificial Neural Network (ANN), Adaptive Fuzzy-Neural Inference System (ANFIS), and Random Forest (RF), were used for sediment load modeling and sediment forecast for days without measurements. To achieve the research objectives, long-term meteorological and hydrometric data ranging from 2000 to 2020 were collected from related organizations and pre-processed before entering the model. The input variables for the models included rainfall, flow rate, normalized difference vegetation index, maximum and minimum temperature, and daily suspended sediment as the dependent variable. Prior to modeling, the entire dataset was divided into two parts, training and testing, in a 70:30 ratio. Relationship modeling was performed using the training data, and model validation was conducted using the test dataset. The efficiency of the models was evaluated using two indicators, the coefficient of explanation (R^2) and the root mean square error (RMSE). Additionally, morphometric parameters such as form factor (FF), drainage density (DF) coefficient, and relief ratio (RR) were utilized in modeling.

Results and discussion: The hydrological analysis of the basin revealed that the highest annual amount of rainfall and erosivity index were recorded at the Sheyvand station in the east of the basin, while the lowest values were observed at the Ramhormoz station. The highest average



monthly flow rate of 5.8 cubic meters per second was obtained at the Manjeniq station in April, and at the Mashin station, the highest average monthly flow rate of 8.8 cubic meters per second was recorded in December and January. Morphometrically, the studied basin belonged to the class of elongated basins, sloping basins in terms of relief, and the medium class in terms of drainage density. Analysis of the time series of NDVI index showed that the highest vegetation cover occurred in March, while the lowest values were recorded in September and October. The annual trend of the vegetation index indicated an overall improvement in vegetation cover in the region from 2000 to 2020, with the NDVI value increasing from 0.15 to 0.22.

Among the different machine learning techniques studied, the Artificial Neural Network (ANN) model had the highest coefficient of explanation ($R^2=0.87$) and the lowest RMSE for both sediment measuring stations in the region, making it the best model. The optimal inputs for the neural network model at Mashin station were daily average flow adjusted by the basin shape factor, daily rainfall, last day's rainfall, daily minimum temperature and daily maximum temperature. For the Manjeniq station, the optimal inputs were daily average flow, daily rainfall, last day's rainfall, cumulative rainfall for the past two days, and cumulative rainfall for the past three days. The NDVI index was removed from the model due to its low significance. The Random Forest (RF) model ranked second, and the Adaptive Fuzzy-Neural Inference System (ANFIS) model ranked third, with weak performance, especially for the Mashin station, where out-of-range errors occurred.

Temporal analysis of sediment values showed that the highest sediment production occurred in December and January for Mashin station and in April for Manjeniq station. The highest production of sediment occurred in 2006 and 2002, and the trend of changes from 2011 to 2018 showed a decline, attributed to consecutive droughts and lack of rainfall. The annual average sediment production calculated using the values estimated with the neural network model was 88017 tons, equivalent to 1 ton per hectare per year.

Conclusion: Overall, this research demonstrated that machine learning methods, especially the neural network model, are highly effective for modeling and predicting sediment on a daily scale. These methods can compensate for the lack of sediment measuring facilities and equipment in most existing hydrometric stations in the country and eliminate the need for continuous sediment data and other water quality parameters.

Key Words *Sedimentation, artificial neural network, adaptive fuzzy-neural inference system, random forest*

شبیه‌سازی رسوب معلق روزانه رودخانه رودزرد با استفاده از تکنیک‌های مختلف یادگیری ماشینی

حیدر غفاری^{۱*} و هادی عامری خواه^۲

۱- استادیار گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز

۲- مربی گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز

تاریخچه مقاله

دریافت: ۱۴۰۱/۱۲/۲۸

پذیرش نهایی: ۱۴۰۲/۰۳/۲۴

کلمات کلیدی:

رسوب‌دهی،

شبکه عصبی مصنوعی،

سیستم استنتاجی فازی-عصبی

تطبیقی،

جنگل تصادفی

* عهده دار مکاتبات

Email: h.ghafari @scu.ac.ir

چکیده

باتوجه به فقدان تجهیزات مناسب در ایستگاه‌های رسوب‌سنجی کشور و اندازه-گیری بسیار محدود داده‌های رسوب، تخمین مقدار رسوب در روزهای فاقد داده در راستای مدیریت منابع آب و خاک بسیار حائز اهمیت است. در این پژوهش، از تکنیک‌های مختلف یادگیری ماشینی شامل، شبکه عصبی مصنوعی (ANN)، سیستم استنتاجی فازی-عصبی تطبیقی (ANFIS) و جنگل تصادفی (RF) به منظور شبیه‌سازی رسوب و برآورد آن در روزهای فاقد داده استفاده شد. برای دستیابی به اهداف پژوهش، ابتدا داده‌های بلند مدت هواشناسی و هیدرومتری (سال ۲۰۰۰ تا ۲۰۲۰) از سازمان‌های مرتبط جمع‌آوری و قبل از ورود به مدل پیش‌پردازش شدند. متغیرهای ورودی به مدل شامل بارندگی، دبی جریان، شاخص پوشش گیاهی نرمال شده، دمای حداکثر و دمای حداقل بود و مقادیر رسوب معلق به عنوان خروجی تمام مدل‌ها در نظر گرفته شد. داده‌ها قبل از مدل‌سازی با نسبت ۷۰ به ۳۰ به دو گروه داده‌های آموزشی و داده‌های آزمون تقسیم شدند. کارایی مدل‌ها با استفاده از پنج شاخص ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE)، درصد اریب (PBIS)، میانگین خطای مطلق (MAE) و ضریب ناش-ساتکلیف (NSE) ارزیابی شد. نتایج نشان داد که در مورد ایستگاه ماشین از بین تکنیک‌های مختلف، مدل شبکه عصبی مصنوعی دارای بیشترین مقدار ضریب تبیین (۰/۷۸) و کمترین مقدار خطا بود. همچنین در مورد ایستگاه منجنیق، مدل شبکه عصبی و نروفازی عملکرد تقریباً مشابهی را نشان دادند. لذا، مدل شبکه عصبی به عنوان مدل برتر در این پژوهش انتخاب شد. بر اساس نتایج PBIAS اغلب مدل‌ها در پیش‌بینی دبی‌های اوج رسوب ضعف داشتند و در مجموع کم‌برآوردی قابل توجهی را نشان دادند. به طوری که در مدل شبکه عصبی مصنوعی، مقدار کم‌برآوردی حدود ۵۰ درصد بود. میانگین سالانه تولید رسوب برای دوره آماری مورد مطالعه بر اساس مدل شبکه عصبی، برابر با ۱ تن در هکتار در سال بدست آمد.

مقدمه

فرسایش خاک یکی از مهم‌ترین فرآیندهای تخریب محیطی است که خسارت‌های اجتماعی-اقتصادی و محیط زیستی متعددی را به دنبال دارد. فرسایش خاک در وهله اول باعث حذف لایه سطحی حاصلخیز و کاهش باروری خاک‌ها شده (۲۵) و در وهله دوم از طریق تولید رسوب در پایین-دست مکان فرسایش یافته منجر به ایجاد برخی مسائل زیست محیطی و کاهش ظرفیت کانال‌ها و مخازن آب می‌شود (۱۴).

گزارش‌های بین‌المللی نشان می‌دهد که در مقیاس جهانی هر سال به‌طور متوسط حدود ۷۵ میلیارد تن خاک سطحی حاصلخیز در اثر فرسایش از بین می‌رود (۲۴). این مقدار فرسایش باعث می‌شود سالانه حدود ۲۰ میلیارد تن رسوب وارد رودخانه‌ها شود که در نهایت ۸۰ درصد آنها وارد اقیانوس‌ها می‌شوند (۳۷). از زاویه دیگر، سالانه حدود ۰/۵-۱٪ از ظرفیت مخازن آب در سراسر جهان در اثر رسوب‌گذاری کاهش می‌یابد و باعث کاهش عمر مفید سدها می‌شود. همچنین پیش‌بینی شده است که در دهه ۲۰۵۰، بیشتر سدهای جهان ۵۰ درصد از حجم کنونی خود را از دست خواهند داد که رقم بسیار نگران‌کننده‌ای است. در همین حال، محققان خاطر نشان می‌کنند که در آسیا تقریباً ۴۰ درصد از کل ظرفیت ذخیره‌ای مخازن با رسوبات پر شده است که رقم بسیار بالایی است. بنابراین، فرسایش و رسوب‌گذاری از جمله مهم‌ترین عوامل تاثیرگذار بر پایداری بلندمدت منابع آب به‌شمار می‌روند (۳۶).

گزارش‌های رسمی و غیررسمی در کشور نیز حاکی از بالا بودن مقدار فرسایش در کشور است. طوری که میزان فرسایش خاک چندین برابر حد مجاز بوده و به‌طور متوسط سالانه حدود ۲ میلیارد تن خاک در اثر فرسایش از بین می‌رود (۲). در مطالعه اخیر،

متوسط سالانه فرسایش خاک در کشور ۲۴ تن در هکتار در سال برآورد شده است (۱۳). حدود ۰/۳ میلیارد تن رسوبات حاصل از فرسایش وارد سدها و شبکه آب‌رسانی می‌شود.

بنابراین، پایش و اندازه‌گیری مستمر و پیوسته مقدار فرسایش خاک و تولید رسوب در حوزه‌های آبخیز کشور در راستای مدیریت منابع خاک و آب از جایگاه ویژه‌ای برخوردار بوده و مورد توجه مسئولین امر قرار داشته و دارد. به عبارتی دیگر، کمی‌سازی تلفات خاک چه از بعد فرسایش و چه از بعد تولید رسوب از نیازهای اصلی در برنامه‌ریزی-های منابع طبیعی و محیط زیست است. با این حال، به دلیل این که اندازه‌گیری فرسایش در سطح وسیع عملاً امکان‌پذیر نیست، برای تعیین آن معمولاً از مدل‌های تجربی مانند USLE استفاده می‌شود که گاهی نتایج آنها نسبت به واقعیت بسیار متفاوت است. این در حالی است که پایش و اندازه‌گیری مستقیم رسوبات به عنوان محصول نهایی فرایند فرسایش خاک در اراضی بالادست، امکان‌پذیر بوده و می‌تواند به عنوان شاخصی از شدت فرسایش خاک مورد استفاده قرار گیرد (۲۶). علاوه بر این، مدل‌های تجربی فرسایش معمولاً با استفاده از مقادیر رسوب اندازه‌گیری شده در ایستگاه‌های هیدرومتری واسنجی و اعتبارسنجی می‌شوند. طبق معادله ۱ رسوبات تولید شده (S) در خروجی حوزه‌های آبخیز کسری از مقدار کل فرسایش خاک (E) هستند که آن را نسبت تحویل رسوب (SDR) می‌نامند:

$$S = E \cdot SDR \quad \text{معادله ۱}$$

علاوه بر این، آگاهی از وضعیت رسوب‌دهی حوزه‌های آبخیز و رودخانه‌ها نقش مهمی در طراحی سازه‌های آبخیزداری و مدیریت کیفیت منابع آب دارد (۳۲). به‌طور کلی، رسوبات از نظر نحوه انتقال به دو دسته رسوبات معلق و رسوبات بستر قابل تقسیم

مقالات مختلف مبین این واقعیت است که در بین تکنیک‌های مختلف یادگیری ماشینی برتری قطعی برای یک روش وجود ندارد و بستگی به شرایط حوضه دارد. با این حال روش شبکه عصبی، ماشین بردار پشتیبان، جنگل تصادفی و سیستم استنتاجی فازی-عصبی به عنوان پیش‌بینی کننده‌های برتر معرفی شده اند (۹).

دوغان و همکاران^۱ (۴) برتری مدل‌های هوش مصنوعی از جمله ANN در پیش‌بینی رسوب معلق ایستگاه‌های اندازه‌گیری رودخانه لیتل بلک و رودخانه سالت در ترکیه را گزارش کردند. میسرا و همکاران^۲ (۲۰) مدل SVM را برای رواناب و پیش‌بینی بار رسوب معلق به کار بردند. این محققان بیان کردند که مدل SVM نسبت به مدل ANN در مراحل آموزش، کالیبراسیون و اعتبار سنجی بهتر عمل می‌کند. در تحقیق کیسی و همکاران^۳ (۱۶) مدل نروفازی نسبت به شبکه عصبی مصنوعی و منحنی سنجه رسوب در پیش‌بینی بار رسوبات معلق عملکرد بهتری را نشان داد. حسن و همکاران^۴ (۱۰) از یک روش مبتنی بر ANN برای پیش‌بینی بار رسوب معلق استفاده کردند و دقت بالای ANN را در ارزیابی مقادیر بار رسوب گزارش نمودند. همچنین علیایی و همکاران^۵ (۲۳) مدل‌های ANN، ANFIS و SRC را برای پیش‌بینی بار رسوب معلق مورد مطالعه قرار دادند و دریافتند که ترکیب روش شبکه عصبی و توابع موجک بهترین تخمین را در بین روش‌های انتخاب شده داشت. چن و چاو^۶ (۳) از یک مدل هیبریدی متشکل از شبکه عصبی پیش‌خور و معادله تشخیص الگوی فازی برای پیش‌بینی بار

رسوبات معلق به دلیل این که بخش عمده رسوبات را شامل می‌شوند از اهمیت بیشتری برخوردارند (۲). از طرفی، رسوبات معلق نسبت به بار کف همبستگی بیشتری با شدت فرسایش در بالادست داشته و یک معرف کلیدی از وضعیت فرسایش به حساب می‌آید. با این همه، به دلیل پاره-ای از مسائل و مشکلات مالی و فنی، اندازه‌گیری مستمر، پیوسته و دقیق بار رسوبی در بسیاری از کشورها از جمله ایران تاکنون محقق نشده و معمولاً در هر ایستگاه رسوب‌سنجی در طول سال تنها در روزهای اندکی اقدام به نمونه برداری رسوب می‌شود و در سایر روزها داده‌های رسوب موجود نیست. در چنین وضعیتی، مدلی که بتواند با استفاده از متغیرهای پیش‌بینی کننده مانند دبی جریان و بارش، میزان بار رسوبی را برآورد کند، بسیار حائز اهمیت است (۲۲).

اخیراً روش‌های مبتنی بر هوش مصنوعی (AI) به دلیل قابلیت‌های زیادی که در کشف روابط پنهان پیچیده بین متغیرهای محیطی دارند، به عنوان یک ابزار مفید و کارآمد برای تصمیم‌گیری در بسیاری از مسایل اجتماعی، اکولوژیکی و حتی پزشکی مورد توجه قرار گرفته‌اند (۵، ۱۷، ۲۹، ۳۰). در این میان، تکنیک‌های یادگیری ماشینی که مبتنی بر داده هستند، به عنوان زیرمجموعه‌ای از هوش مصنوعی به طور گسترده و رضایت‌بخشی برای پیش‌بینی پدیده‌های هیدرولوژیکی و تخمین بار رسوب مورد توجه قرار گرفته‌اند (۷، ۱۷، ۲۱، ۳۰، ۳۱، ۳۸). این مدل‌ها غالباً بر پایه داده‌های ورودی و تشخیص الگوهای آن‌ها و بدون دخالت انسان، به یادگیری مسئله می‌پردازند. در این زمینه می‌توان به شبکه عصبی مصنوعی (ANN)، سیستم‌های استنتاج عصبی فازی تطبیقی (ANFIS)، روش دسته‌بندی داده‌ها (GMDH)، ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) اشاره کرد. بررسی گزارشات و

1- Doğan *et al.*2- Misra *et al.*3- Kisi *et al.*4- Hassan *et al.*5- Olyaie *et al.*6- Chen and Chau *et al.*

مجموعه‌ای از متغیرهای پیش‌بینی‌کننده شامل رواناب، بارندگی، پوشش گیاهی، دما و خصوصیات مورفومتریک حوضه به منظور برآورد دبی روزانه بار رسوبات معلق رودخانه رودزرد در استان خوزستان می‌باشد.

موارد و روش‌ها

معرفی منطقه مورد مطالعه

حوزه آبخیز رودخانه رودزرد در محدوده شهرستان باغملک (شرق استان خوزستان) با مساحت ۸۸۲ کیلومتر مربع و محیط ۲۰۸ کیلومتر در عرض شمالی $31^{\circ} 10' 38''$ تا $50^{\circ} 10' 38''$ و طول شرقی $31^{\circ} 22' 78''$ تا $31^{\circ} 42' 52''$ واقع شده و یکی از بخش‌های حوزه آبخیز مارون- جراحی می‌باشد (شکل ۱). حوضه مورد مطالعه از جنوب به شهرستان رامهرمز و از شمال به شهرستان ایذه منتهی می‌شود. طول بزرگترین آبراهه حوضه حدود ۸۴/۷ کیلومتر بوده که به شکل درختی از شرق به غرب در جریان است. جنگل، مرتع و اراضی کشاورزی از جمله کابرای‌های اصلی منطقه هستند. بر اساس نقشه‌های زمین‌شناسی، سطح حوضه عمدتاً توسط سازندهای گچساران، بختیاری و آسماری و رسوبات کواترنری پوشیده شده است. حوزه آبخیز رودزرد مسئول تامین آب سد جره در ۲۸ کیلومتری شمال رامهرمز می‌باشد. متوسط سالانه بارندگی حوضه ۵۰۰ میلی‌متر و دبی متوسط سالانه آن معادل ۳/۶۹ متر مکعب بر ثانیه گزارش شده است (۶). همچنین ارتفاع متوسط وزنی حوضه ۱۱۹۷/۳۷۳ متر و میانگین دمای آن ۲۰ درجه سانتیگراد می‌باشد. بلندترین ارتفاعات حوضه با مقدار ۳۳۰۰ متر در قسمت شرقی حوضه واقع شده‌اند و به سمت غرب کاهش می‌یابند. شغل اصلی مردم این منطقه کشاورزی، باغداری و دام‌پروری است. لذا حفظ آب و خاک به طور مستقیم بر زندگی و معیشت آنها تاثیر گذار است.

رسوب معلق استفاده کردند و نتایج بسیار مطلوب ارزیابی گردید. شماعی و کائدی^۱ (۳۳) از تکنیک یادگیری گروهی برای پیش‌بینی بار رسوب معلق رودخانه استفاده کردند و دریافتند که ادغام نتایج مدل‌های فازی عصبی و ژنتیک خطی به طور چشم‌گیری مقدار جذر میانگین مربعات خطا را کاهش داد. در تحقیق المختار^۲ (۱) از بین مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی، مدل جنگل تصادفی عملکرد بهتری در پیش‌بینی بار رسوبات معلق ارائه داد. زونعمت کرمانی و همکاران^۳ (۳۹) مدل‌های یادگیری ماشینی از جمله ANFIS و رگرسیون بردار پشتیبان و همچنین ترکیب آنها با الگوریتم ژنتیک (GA-SVR و GAANFIS) را برای پیش‌بینی بار معلق و بار بستر بررسی کردند. نتایج پژوهش آنها نشان داد که مدل‌های ترکیبی در مقایسه با مدل‌های تکی به طور قابل توجهی بهتر عمل کردند. رجایی و جعفری (۲۸) در بررسی خود بیان کردند که مدل‌های هوش مصنوعی می‌توانند به طور موثر غلظت رسوب را در رودخانه‌های پیچیده پیش‌بینی کنند. در مطالعه رضایی و همکاران^۴ (۳۰) مدل SVM از نظر میانگین معیارهای خطا نسبت به سایر مدل‌ها یادگیری ماشینی توانایی بیشتری در پیش‌بینی مقادیر بار رسوب معلق نشان داد.

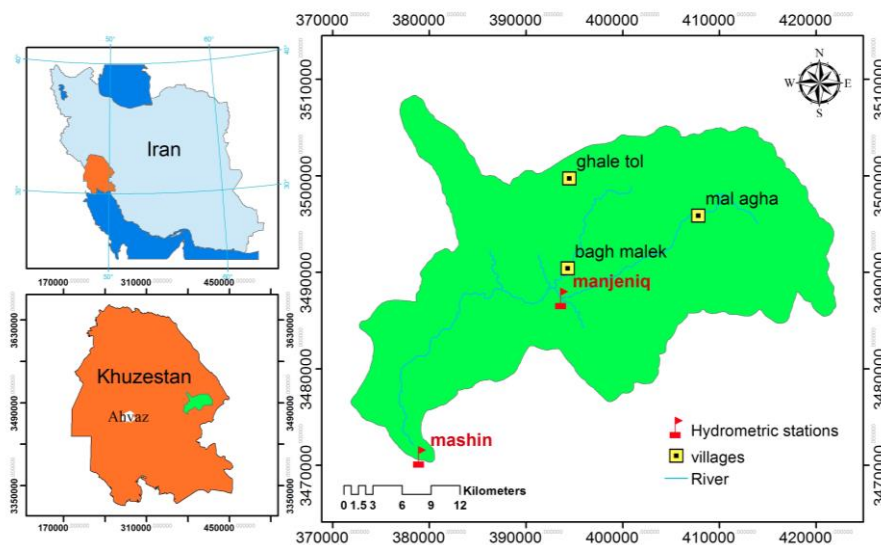
در اغلب تحقیقات انجام شده تنها از دبی جریان به عنوان متغیر پیش‌بینی‌کننده رسوب استفاده شده و از سایر متغیرهای موثر مانند بارندگی، پوشش گیاهی و خصوصیات مورفومتریک حوضه چشم‌پوشی شده است. لذا، هدف اصلی این پژوهش استفاده از مدل‌های مختلف یادگیری ماشینی و

1 Shamaei et al.

2- Al-Mukhtar

3- Kermani et al.

4- Rezaei et al.



شکل (۱) موقعیت حوزه آبخیز رودزرد در کشور و استان
Figure (1) The location of Roud-Zard watershed in the country and province

باتوجه به وجود ایستگاه‌های متعدد باران‌سنجی و همچنین شرایط توپوگرافی متنوع در سطح حوضه، برای محاسبه میانگین بارش روزانه از روش تیسن استفاده شد. در این روش، برای هر ایستگاه باران‌سنجی یک چند ضلعی ترسیم شد که سطح موثر هر ایستگاه را نشان می‌دهد (شکل ۲).
باتوجه به تاثیر خصوصیات مورفومتریک حوضه بر رفتار هیدرولوژیکی آن، با استفاده از برخی شاخص‌های مورفومتری از جمله ضریب شکل حوضه (FF)، ضریب تراکم شبکه زهکشی (DF) و ضریب توپوگرافی (RF) به عنوان تعدیل کننده مقادیر رواناب و بارندگی (۱۱)، متغیرهای جدیدی شامل R_{FF} ، R_{DF} و R_{RF} برای رواناب و P_{DF} ، P_{FF} و P_{RF} برای بارندگی ساخته شد (معادله ۲).

معادله ۲

$$R_{FF} = R^{\sqrt{FF}}, R_{DF} = R^{\sqrt{DF}}, R_{RF} = R^{\sqrt{RF}}$$

متغیرهای جدید بارندگی نیز مشابه معادله ۲ تولید شدند.

تهیه داده‌های مورد نیاز

در این تحقیق، از داده‌های دبی روزانه، بارندگی روزانه، متوسط حداقل و حداکثر دمای روزانه و شاخص تفاوت پوشش گیاهی نرمال شده (NDVI) به عنوان متغیرهای پیش‌بینی کننده برای مدل‌سازی دبی رسوب معلق روزانه استفاده شد. داده‌های دبی جریان و رسوب معلق ایستگاه هیدرومتری منجیق و ماشین در طول دوره آماری ۲۰۰۰ تا ۲۰۲۰ از سازمان آب و برق استان خوزستان اخذ گردید. آمار هواشناسی ایستگاه‌های موجود در محدوده حوزه آبخیز نیز در همین بازه زمانی از سازمان هواشناسی استان دریافت شد. سری زمانی (۸ روزه) شاخص NDVI با استفاده از تصاویر ماهواره MODIS در پلتفرم گوگل ارث انجین برای کل دوره آماری تهیه شد. چنانچه برای روزهای دارای داده رسوب، داده NDVI موجود نبود، از NDVI نزدیک‌ترین روز استفاده گردید. پس از جمع‌آوری داده‌ها شروط کفایت، درستی، همگنی و مرتبط بودن داده‌ها توسط آزمون کفایت، آزمون داده‌های پرت و آزمون کولموگروف-اسمیرنوف بررسی شدند.

۱- مدل شبکه عصبی

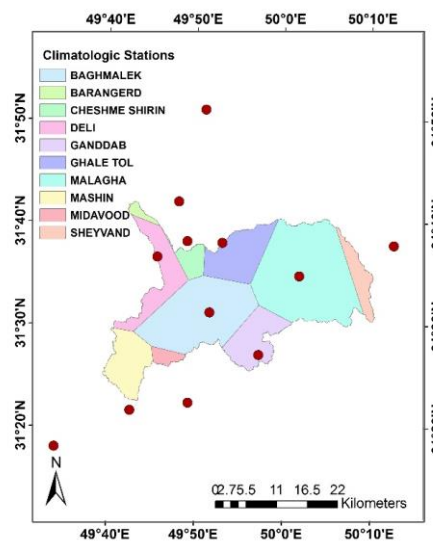
در این مطالعه، از مدل شبکه عصبی پرسپترون چند لایه (MLP^1) که شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است، برای یافتن روابط غیرخطی بین مقادیر رسوب و متغیرهای کمکی استفاده شد. برای ساخت مدل شبکه عصبی مصنوعی تعداد لایه پنهان و همچنین تعداد نرون‌ها در لایه پنهان حایز اهمیت است که از طریق سعی و خطا و بر اساس حداقل جذر میانگین مربعات خطا بهینه شدند. ساخت مدل شبکه عصبی مصنوعی در نرم افزار SPSS نسخه ۲۲ انجام شد.

۲- مدل استنتاج فازی-عصبی تطبیقی ($ANFIS^2$)

این روش از ترکیب شبکه‌های عصبی و سامانه‌های فازی تشکیل شده است (۱۲). لذا از مزایای هر دو بهره‌گیری می‌شود. برای ساخت مدل ANFIS نوع تابع عضویت (مثلثی، گوسی، دوزنقه و ...)، نوع روش آموزش (پس انتشار خطا و ترکیبی) و همچنین درجه عضویت ورودی‌ها و خروجی‌ها حایز اهمیت هستند که با استفاده از آزمون و خطا و بر اساس حداقل جذر میانگین مربعات خطا توسط کاربر تعیین می‌شوند. ساخت مدل عصبی-فازی در نرم افزار Matlab نسخه بتا ۲۰۱۵ انجام شد.

۳- مدل جنگل تصادفی

جنگل تصادفی نوعی روش درخت تصمیم است که با استفاده از مجموعه‌ای از درخت‌ها با در نظر گرفتن n داده مشاهده‌ای مستقل ساخته می‌شود. در این پژوهش محاسبات مدل جنگل تصادفی در محیط نرم‌افزار Rstudio نسخه ۱،۴،۱۱۰۳ و با استفاده از بسته تخصصی "random forest" انجام شد. برای ساخت مدل جنگل تصادفی دو پارامتر $mtry$ و $ntree$ حایز اهمیت است که به صورت سعی و خطا و بر اساس دستیابی به کمترین میزان جذر میانگین مربعات خطا تعیین می‌شوند. $ntree$ تعداد درخت ساخته شده در مدل و $mtry$ تعداد متغیرهای کمکی استفاده شده در هر درخت تصمیم است. تعداد $ntree$ بین ۱۰۰ تا ۵۰۰ و تعداد $mtry$ متناسب با نوع مدل و تعداد ورودی‌ها (پیش فرض مدل در فرایند رگرسیون برابر یک سوم ورودی‌ها است) در نظر گرفته شد.



شکل (۲) موقعیت ایستگاه‌های باران سنجی به

همراه مساحت تحت پوشش به روش تیسن

Figure (2) The location of the rain gauge stations and the division of the basin according to the Thiessen method

به‌طور کلی، متغیرهای ورودی اولیه تمامی مدل‌های مورد استفاده در این پژوهش شامل مجموعه داده‌های رواناب روزانه (R_{RF} ، R_{DF} ، R_{FF} ، Q_m)، مجموعه داده‌های بارندگی روزانه (P_{RF} و P_{DF} ، P_{FF} ، P_{24})، بارندگی روزانه (P72)، دمای حداقل ۴۸ ساعته (P_{48} ، بارندگی ۷۲ ساعته (P_{72})، دمای حداکثر روزانه (T_{max}) و شاخص NDVI و متغیر خروجی تمام مدل‌ها لگاریتم رسوب معلق روزانه بود. فرض بر این است که پارامترهای دما بتوانند اثر فصول مختلف سال و همچنین ذوب برف بر ذوب رسوب را منعکس کنند. همچنین پوشش گیاهی به عنوان یکی از عوامل اصلی در فرایند فرسایش خاک می‌تواند در تولید رسوب موثر باشد (۴۰).

شبیه‌سازی رسوب معلق

مدل شبکه عصبی مصنوعی (ANN)، مدل استنتاج عصبی-فازی تطبیقی (ANFIS) و جنگل تصادفی (RF) به عنوان تکنیک‌های رایج یادگیری ماشینی استفاده شدند که شرح مختصر هر کدام در ادامه آمده است.

1- Multilayer Perceptron

2- Adaptive Neuro-Fuzzy Inference System

ارزیابی مدل‌ها

فروردین تا ۱۱ اردیبهشت) ثبت شده است (جدول ۲). در حالی - که بیشترین دبی متوسط ماهانه (۸/۸ متر مکعب بر ثانیه) ایستگاه ماشین در ماه دسامبر و ژانویه مشاهده گردید. دبی رواناب ارتباط مستقیمی با تولید رسوب دارد.

ویژگی‌های مورفومتریک و شاخص پوشش گیاهی

هر دو ناحیه از نظر شکل، در گروه حوضه‌های کشیده تقسیم می‌شوند و مقدار ضریب شکل آنها کمتر از ۰/۴ بدست آمد. معمولاً مقادیر فاکتور شکل کمتر از ۰/۷۸ به عنوان حوضه‌های کشیده طبقه‌بندی می‌شوند (۳۵). از نظر پستی و بلندی حوضه بالادست ایستگاه منجنیق دارای ضریب پستی و بلندی بیشتری بود که بیانگر اختلاف ارتفاع و شیب بیشتر در این قسمت از حوضه می‌باشد. از نظر تراکم آبراهه هر دو ناحیه تقریباً شبیه به هم بوده و مقدار ضریب تراکم برای ناحیه بالادست ایستگاه ماشین و منجنیق به ترتیب برابر با ۰/۷۴ و ۰/۸۴ بدست آمد که در کلاس متوسط قرار می‌گیرند. هر سه ویژگی مورفومتریک فوق بر منحنی هیدروگراف سیلاب تاثیر گذار هستند.

بررسی سری زمانی شاخص NDVI نشان داد که در ایستگاه ماشین بیشترین مقدار پوشش گیاهی مربوط به ماه مارس و کمترین مقدار مربوط به ماه‌های سپتامبر و اکتبر است. در حالی که در حوضه بالادست ایستگاه منجنیق بیشترین مقدار شاخص پوشش گیاهی در ماه آپریل و کمترین مقدار آن مشابه با ایستگاه ماشین در ماه‌های سپتامبر و اکتبر اتفاق افتاده است. علاوه بر این، بررسی روند سالانه شاخص پوشش گیاهی نشان داد که در مجموع، از سال ۲۰۰۰ تا ۲۰۲۰ پوشش گیاهی در منطقه بهبود یافته، طوری که مقدار این شاخص از ۰/۱۵ به ۰/۲۲ افزایش یافته است (شکل ۳). دلیل آن را می‌توان در گسترش زمین‌های کشاورزی یا تغییر الگوی کشت (مثلاً از گندم به ذرت) و یا تبدیل اراضی دیم به آبیاری به‌واسطه گسترش سیستم‌های آبیاری بارانی جستجو کرد. علاوه بر این، مدیریت عرصه‌های جنگلی و مرتعی نیز ممکن است تاثیر گذار بوده باشد. با فرض ثابت بودن سایر عوامل، افزایش پوشش گیاهی باعث کاهش فرسایش خاک و تولید رسوب خواهد شد.

برای ساخت و ارزیابی مدل‌های مورد استفاده ابتدا کل مجموعه داده‌ها به طور تصادفی به دو بخش آموزش و آزمون که به ترتیب شامل ۷۰ و ۳۰ درصد داده‌ها بودند، تقسیم شدند. خصوصیات آماری هر دو مجموعه داده در جدول ۱ ارائه شده است. مجموعه داده‌های آموزش برای ساخت مدل‌ها و مجموعه داده‌های آزمون برای اعتبارسنجی مدل‌ها استفاده شد. سپس با استفاده از شاخص‌های جذر میانگین مربعات خطا ($RMSE^1$)، میانگین خطای مطلق (MAE^2)، ضریب ناش-ساتکلایف (NSE^3)، درصد اریب ($PBIAS^4$) و ضریب تبیین (R^2) بدست آمده در مرحله اعتبارسنجی، بهترین مدل از نظر کارایی انتخاب گردید. هر کدام از مدل‌ها که خطا کمتر و ضریب تبیین بیشتری داشته باشد، آن مدل نسبت به سایر مدل‌ها از دقت و کارایی بیشتری برخوردار خواهد بود.

برآورد میانگین سالانه تولید رسوب

پس از انتخاب بهترین مدل تخمین گر، با استفاده از آن رسوب معلق روزانه برای کل دوره آماری محاسبه و میانگین سالانه تولید رسوب حوضه برآورد گردید.

نتایج و بحث

هیدرولوژی حوضه

تجزیه و تحلیل مقادیر بارندگی‌های روزانه ایستگاه‌های مختلف نشان داد که بیشترین مقدار بارندگی سالانه با مقدار ۷۸۰ میلی‌متر مربوط به ایستگاه شیوند در شرق حوضه و کمترین مقادیر در ایستگاه رامهرمز مشاهده شد. متوسط بارندگی سالانه حوضه مورد مطالعه برای دوره آماری ۲۰۰۰ تا ۲۰۲۰ با استفاده از روش تیسن ۴۸۵ میلی‌متر تعیین گردید.

همچنین تجزیه و تحلیل دبی روزانه اندازه‌گیری شده در ایستگاه‌های هیدرومتری منجنیق و ماشین به تفکیک ماه‌های مختلف سال نشان داد که بیشترین دبی متوسط ماهانه (۵/۸ متر مکعب در ثانیه) در ایستگاه منجنیق در ماه آپریل (مقارن با ۱۰

1- Root Mean Square Error

2- Mean Absolute Error

3- Nash-Sutcliffe Efficiency

4- Percent Bias

غفاری و عامری خواه: شبیه‌سازی رسوب معلق روزانه رودخانه...

جدول (۱) مشخصات آماری مجموعه داده‌های مورد استفاده برای شبیه‌سازی رسوب

Table(1) Statistical description of the dataset used for sediment simulation

ایستگاه منجنیق		ایستگاه ماشین		نام مجموعه داده						
Manjeniq st.		Mashin st.		Dataset name						
انحراف از معیار	میانگین	حداقل	حداکثر	انحراف از معیار	میانگین					
STD	Mean	Min	Max	STD	Mean					
		تعداد	تعداد							
		n	n							
512	101	4712	0.12	102	13915	1586	146170	0.44	130	آموزش
307	79	2222	0.11	57	18370	3910	139935	0.38	58	آزمون
										test

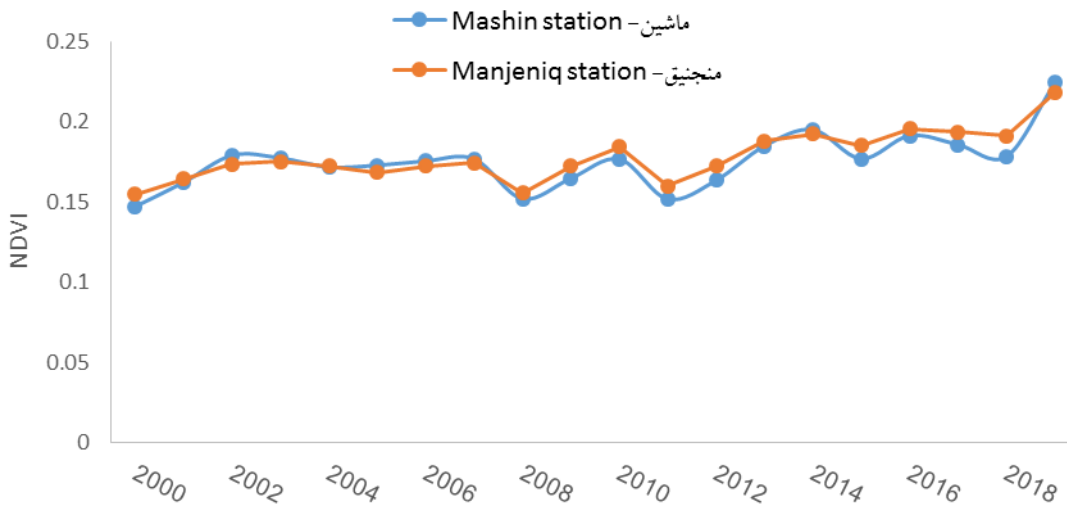
جدول (۲) میانگین ماهیانه دبی جریان

Table(2) Average monthly flow rate

دبی جریان

Flow rate (m³/s)

ایستگاه منجنیق	ایستگاه ماشین	ماه (میلادی)
Manjeniq st.	Mashin st.	month
2.49	8.87	1
3.16	6.50	2
3.31	5.71	3
5.80	8.26	4
3.16	4.06	5
1.20	2.51	6
0.32	2.68	7
0.13	3.11	8
0.15	3.39	9
0.70	3.39	10
1.20	5.08	11
2.28	8.36	12



شکل (۳) روند تغییرات شاخص تفاضل پوشش گیاهی نرمال شده
Figure (3) The trend of changes in the NDVI

جدول (۳) مقادیر همبستگی پیرسون و اسپیرمن بین رسوب و متغیرهای ورودی

Table (3) Pearson and Spearman correlation values between sediment and input variables

P _{df}	P _{rf}	P _{ff}	R _{rf}	R _{df}	R _{ff}	P ₄₈	P _y	NDVI	T _{max}	T _{min}	P ₂₄	Q _m	نوع همبستگی	ایستگاه
													Correlation type	Station Name
0.54	0.49	0.54	0.5	0.77	0.71	0.46	0.22	0.06	-0.2	-0.17	0.55	0.77	پیرسون	ماشین
0.19	0.19	0.19	0.78	0.78	0.78	0.17	0.16	0.26	-0.37	-0.35	0.19	0.79	اسپیرمن	Mashin
0.52	0.71	0.46	0.84	0.68	0.58	0.66	0.71	0.04	-0.18	-0.18	0.53	0.73	پیرسون	منجنیق
0.31	0.31	0.31	0.9	0.9	0.9	0.36	0.36	0.25	-0.27	-0.26	0.31	0.9	اسپیرمن	Manjeniq
													Spearman	

رسوب بیشتر از نوع غیرخطی و رابطه بارندگی بیشتر از نوع خطی است.

در مورد ایستگاه ماشین، بیشترین همبستگی مربوط به متغیرهای دبی روزانه رواناب (qm) و کمترین مربوط به بارندگی روز قبل (Py) بود. بر اساس مقادیر همبستگی، رابطه بین متغیرهای دمایی و رسوب معکوس است، بدین معنا که با افزایش دمای حداقل و حداکثر روزانه، از مقدار تولید رسوب کاسته می شود. زیرا، عمده بارندگی ها و فرسایش در ماه های سرد سال رخ می دهد و در فصول گرم، رواناب موجود در رودخانه ها عمدتاً ناشی از چشمه ها و جریانات زیرسطحی است

همبستگی بین متغیرهای پیش بینی کننده با رسوب معلق

نتایج همبستگی بین متغیرهای ورودی با رسوب معلق در جدول ۳ ارائه شده است. به طور کلی در هر دو ایستگاه مقادیر همبستگی اسپیرمن برای متغیرهای رواناب، دما و شاخص پوشش گیاهی نسبت به مقادیر همبستگی پیرسون بیشتر بود. در حالی که در خصوص بارندگی مقادیر همبستگی نوع پیرسون بیشتر بودند. بر این اساس، می توان نتیجه گرفت که رابطه بین متغیرهای رواناب، دما و پوشش گیاهی با مقادیر

سنجی، عملکرد هر سه مدل به هم نزدیک بود. با این حال مدل شبکه عصبی مصنوعی از نظر شاخص $RMSE$ ، NSE و MAE از دو مدل دیگر وضعیت بهتری را نشان داد. برتری مدل شبکه عصبی مصنوعی نسبت به سایر تکنیک‌های هوش مصنوعی توسط محققین زیادی از جمله لی و همکاران^۱ (۱۹) گزارش شده است. کیسی (۱۵) در گزارش خود بیان کرده که تکنیک شبکه عصبی مصنوعی برای مدل‌سازی روابط غیرخطی موجود در مجموعه داده‌های کیفیت آب ابزار بسیار موثر و نیرومندی است. در این پژوهش از میانگین مقادیر برآورد شده نیز به عنوان معیاری برای مقایسه مدل‌ها استفاده شد. میانگین مقادیر واقعی رسوبات در مجموعه داده‌های آزمون برابر با ۳۹۱۰ تن در روز بود که نتایج مدل نروفازی کمترین اختلاف را با آن داشت. در کل، بر اساس شاخص درصد اریب و همچنین میانگین مقادیر برآورد شده هر سه مدل کم‌برآوردی نشان دادند.

پارامترهای بهینه مدل‌های مختلف در جدول ۴ ارائه شده است. ساختار بهینه مدل شبکه عصبی برای ایستگاه ماشین شامل ۵ ورودی، یک لایه میانی با ۴ نرون و یک خروجی بود. توابع فعال در بخش لایه‌های پنهان و خروجی هر دو از نوع تانژانت هایپربولیک انتخاب شدند. ورودی‌های بهینه در مدل شامل دبی متوسط روزانه تعدیل شده با ضریب شکل حوضه، بارندگی روزانه، بارندگی روز گذشته، حداقل دمای روزانه و حداکثر دمای روزانه بودند (جدول ۶). نتایج آزمون اهمیت نسبی متغیرهای ورودی نشان داد که مقدار دبی تعدیل شده با ضریب شکل حوضه در بالاترین سطح و شاخص $NDVI$ و پارامترهای دمایی در پایین‌ترین سطح اهمیت قرار داشتند. بارندگی همان روز و بارندگی روز قبل نیز در سطح متوسط قرار گرفتند. شاخص $NDVI$ به دلیل اهمیت کم، از مدل حذف شد.

هر چند که سیستم استنتاج عصبی فازی تطبیقی (ANFIS) نیز در تشخیص روابط پیچیده خطی و غیرخطی پنهان در مجموعه داده‌ها توانایی بالایی دارد، اما در این مطالعه

که رسوبات بسیار کمی را حمل می‌کنند. از بین متغیرهای بارندگی، بیشترین همبستگی رسوب ($R^2 = 0.55$) با مقادیر بارندگی همان روز ($p24$) بدست آمد، و با بارندگی روز قبل (py) همبستگی بسیار ضعیف ($R^2 = 0.22$) بود. علت آن را می‌توان در زمان تمرکز، پوشش گیاهی و منابع تولید رسوب جستجو کرد. احتمالاً به دلیل وضعیت خاک و پوشش گیاهی منطقه، عمده رسوبات رسیده به خروجی از مناطق نزدیک به خروجی نشات می‌گیرند و بنابراین هنگام بارندگی پس از مدت کوتاهی رسوبات به خروجی می‌رسند، در حالی که رسوبات تولید شده در بالادست به دلیل پوشش گیاهی و وجود موانع طبیعی و مصنوعی در طول مسیر ممکن است هیچگاه به خروجی حوضه نرسند و در طول مسیر ته‌نشین شوند.

در مورد ایستگاه منجنیق نیز بیشترین همبستگی ($R^2=0.90$) مربوط به متغیرهای رواناب و کمترین مربوط به شاخص پوشش گیاهی بود. رابطه بین دما و رسوب نیز منفی بدست آمد. بر خلاف ایستگاه ماشین، بیشترین همبستگی رسوب با بارندگی مربوط به بارندگی روز قبل بود، که دلیل آن احتمالاً دور بودن مناطق اصلی تولید رسوب نسبت به ایستگاه هیدرومتری است. به طوری که رسوبات تولید شده در این مناطق با یک روز تاخیر به ایستگاه هیدرومتری می‌رسند. بررسی حوضه مربوط به ایستگاه منجنیق نشان می‌دهد که در بالادست عمدتاً اراضی مرتعی ضعیف با پوشش رخنمون سنگی وجود دارند و در نواحی نزدیک به ایستگاه پوشش جنگلی بسیار خوب مسقر است. بنابراین، توجیه فوق‌تا حدودی می‌تواند صحیح باشد. از طرفی ارتفاعات ایستگاه منجنیق، معمولاً در فصول سرد پوشیده از برف هستند و ذوب آنها می‌تواند تغییراتی را در الگوی تولید رسوب در ایستگاه ایجاد کند.

ارزیابی مدل‌ها

نتایج صحت‌سنجی مدل‌های مختلف برای هر دو ایستگاه هیدرومتری ماشین و منجنیق در جدول ۵ و ۶ ارائه شده است. به طور کلی، در ایستگاه ماشین بر اساس شاخص‌های صحت

تحلیل رسوب‌دهی حوضه

بر اساس نتایج بدست آمده از مدل‌ها، بررسی میانگین ماهانه مقادیر رسوب نشان می‌دهد که در ایستگاه ماشین بیشترین تولید رسوب مربوط به ماه دسامبر و ژانویه بوده است، در حالی که در ایستگاه منجنیق بیشترین تولید رسوب در ماه آپریل اتفاق افتاده است. علت تفاوت در توزیع زمانی تولید رسوب در ایستگاه‌ها را می‌توان به شرایط متفاوت پوشش گیاهی و توپوگرافی و حتی خاک حاکم در بالادست آنها منتسب کرد. همچنین برف گیر بودن ارتفاعات بالادست ایستگاه منجنیق می‌تواند باعث تغییر الگوی زمانی تولید رسوب شود. تقریباً در نصفی از سال یعنی از ماه جون تا نوامبر مقدار رسوب در حد صفر بود. زیرا در این ماه‌ها، مقدار بارندگی بسیار ناچیز است. بررسی وضعیت تولید رسوب در مقیاس سالانه نشان می‌دهد که بیشترین تولید رسوب در سال‌های ۲۰۰۶ و ۲۰۰۲ اتفاق افتاده و روند تغییرات آن از سال ۲۰۰۷ تا ۲۰۱۸ سیر نزولی را طی کرده است که علت آن احتمالاً وقوع خشکسالی‌های پی‌درپی و کمبود بارش می‌باشد (شکل ۴). زیرا تولید رسوب تابع مستقیم بارش و رواناب است.

میانگین سالانه تولید رسوب (Sa) هر دو ایستگاه بر اساس مقادیر روزانه برآورد شده توسط مدل‌ها محاسبه گردید. بر اساس مدل شبکه عصبی به عنوان مدل برتر در این تحقیق، میانگین تولید رسوب ویژه (Ss) ایستگاه ماشین برابر با ۱ تن در هکتار در سال و در ایستگاه منجنیق برابر با ۰/۲۷ تن در هکتار در سال برآورد شد (جدول ۷). در ایستگاه منجنیق بر اساس مدل شبکه عصبی سالانه حدود ۹۷۵۵ تن و در ایستگاه ماشین حدود ۸۰۱۷ تن رسوب تولید می‌شود. پیش‌بینی مدل فازی-عصبی در ایستگاه منجنیق چندین برابر دو مدل دیگر بود که احتمالاً ناشی از ضعف این مدل در پیش‌بینی مقادیر حدی است. باتوجه به این که ایستگاه منجنیق زیرمجموعه ایستگاه ماشین است، طبیعتاً تولید رسوب کمتری خواهد داشت. لذا، نتایج دو مدل شبکه عصبی و جنگل تصادفی به واقعیت نزدیک تر می‌باشد.

از نظر عملکرد بعد از شبکه عصبی مصنوعی قرار گرفت. علت آن را می‌توان در محدودیت‌های این روش جستجو کرد. مدل نروفازی به داده‌های حدی بسیار حساس است و چنانچه دامنه اعداد در مجموعه داده‌های آموزش و آزمون متفاوت باشند خطاهای بزرگی را ایجاد کند (۸). علاوه بر این، مدل نروفازی به تعداد متغیر نیز بسیار حساس است و با افزایش تعداد متغیر عملکرد آن کاهش می‌یابد. لذا، کمترین تعداد ورودی مربوط به این مدل بود. این نتایج با یافته‌های ریاحی و همکاران^۱ (۳۱)، اولیایی و همکاران^۲ (۲۳) و رجبی و همکاران^۳ (۲۷) مطابقت داشته، اما با نتایج تیفور و همکاران^۴ (۳۴) و کیسی و همکاران (۱۶) ناسازگار است.

وضعیت عملکرد مدل‌ها در ایستگاه منجنیق نیز مشابه ایستگاه ماشین بود و در مجموع شبکه عصبی مصنوعی نسبت به دو مدل دیگر عملکرد بهتری را نشان داد (جدول ۵). به جزء شاخص MAE، در بقیه شاخص‌ها مدل شبکه عصبی وضعیت مطلوب‌تری داشت. مدل جنگل تصادفی و نروفازی در مجموع عملکرد یکسانی را نشان دادند. بر اساس شاخص درصد اربب مشابه با ایستگاه ماشین، تمام مدل‌ها نسبت به مقادیر واقعی کم-برآوردی داشتند.

ساختار بهینه شبکه عصبی مصنوعی ایجاد شده برای داده-های ایستگاه منجنیق شامل ۵ ورودی، یک لایه میانی با ۲ نرون و یک خروجی بود. ورودی‌های مدل شامل دبی متوسط روزانه، بارندگی روزانه، بارندگی روز گذشته، بارندگی جمعی ۴۸ ساعته و بارندگی جمعی ۷۲ ساعته بودند (جدول ۴). تابع فعال در بخش لایه‌های پنهان از نوع تانژانت هایپربولیک و برای بخش خروجی مدل از نوع تابع همانی بود. نتایج آزمون اهمیت نسبی متغیرهای ورودی نشان داد که مقدار دبی در بالاترین سطح اهمیت و پارامترهای دما و شاخص NDVI در پایین‌ترین سطح قرار داشتند. بارندگی روزانه و روز قبل در سطح متوسط اهمیت قرار گرفتند.

- 1 Riahi *et al.*
- 2- Olyaie *et al.*
- 3- Rajabi *et al.*
- 4- Tayfur *et al.*

غفاری و عامری خواه: شبیه‌سازی رسوب معلق روزانه رودخانه...

جدول (۴) پارامترهای بهینه در ساختار نهایی مدل‌ها
Table(4) Optimal parameters in the final structure of the models

Manjeniq st.	پارامترهای بهینه Optimal parameters ایستگاه منجنیق	Mashin st.	ایستگاه ماشین	نوع مدل Model type
	P72 ,P48 ,Py ,P24 ,Qm	qff ,Tmax ,Tmin ,Py ,P24		شبکه عصبی مصنوعی ANN
	qff	qff , Py ,P24 ,Qm		نرو فازی ANFIS
	Py , Qm	NDVI ,Tmax ,Tmin ,P72 ,P48 ,Py ,P24 ,Qm		جنگل تصادفی RF

جدول (۵) شاخص‌های صحت‌سنجی مدل‌های مختلف مربوط به ایستگاه ماشین
Table (5) The validation indices of different models at Mashin station

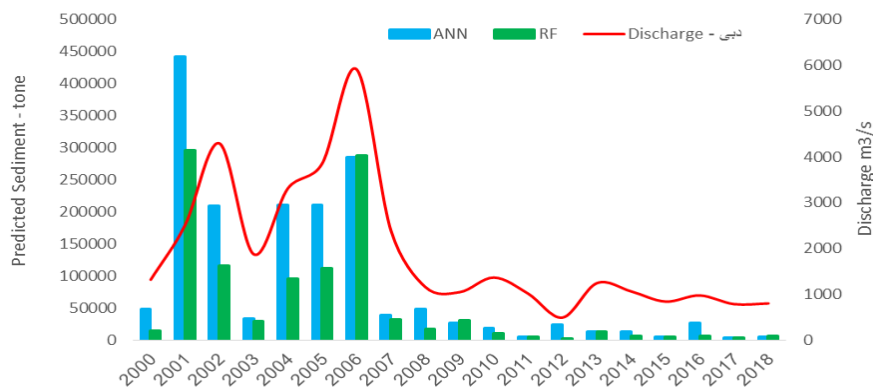
میانگین برآوردها * ton/day Average of estimated Sediment (ton/day)	PBIAS %	MAE ton/day	NSE	RMSE ton/day	R ²	نوع داده Data type	نوع مدل Model type
1063	-32.36	541.2	0.87	4867.1	0.75	آموزش Train	شبکه عصبی مصنوعی Neural network
1944	-50.54	2288.4	0.24	15996.9	0.86	آزمون Test	
1930	22.78	3320.6	0.06	16400.4	0.54	آموزش Train	نرو-فازی Neuro-fuzzy
2334	-40.60	2392.3	0.21	16293.2	0.70	آزمون Test	
285	-81.8	1295.5	0.17	12479.9	0.93	آموزش Train	جنگل تصادفی Random forest
676	-82.7	3283.2	0.19	16521.4	0.90	آزمون Test	

*: میانگین مشاهدات برای مجموعه داده‌های آموزش و آزمون به ترتیب ۱۵۸۶ و ۳۹۱۰ تن در روز بود

جدول (۶) شاخص‌های صحت‌سنجی مدل‌های مختلف مربوط به ایستگاه منجنیق
 Table(6) The validation indices of different models at Manjeniq station

میانگین برآوردها * ton/day Average of estimated Sediment (ton/day)	PBIA S %	MAE ton/day	NSE	RMSE ton/day	R ²	نوع داده Data type	نوع مدل Model type
47	-53.77	61.67	0.58	314.3	0.79	آموزش Train	شبکه عصبی مصنوعی Neural network
32	-58.92	109.68	0.01	315.6	0.71	آزمون Test	
76	-24.72	63.44	0.82	206.5	0.74	آموزش Train	نرو-فازی Neuro-fuzzy
29	-63.25	76.71	-0.01	368.6	0.68	آزمون Test	
37	-65.03	61.16	0.40	389.2	0.92	آموزش Train	جنگل تصادفی Random forest
31	-61.18	91.11	0.02	309.9	0.58	آزمون Test	

* میانگین مشاهدات برای مجموعه داده های آموزش و آزمون به ترتیب ۱۰۱ و ۷۹ تن در روز بود



شکل (۴) تغییرات سالانه رسوب معلق برآورد شده با مدل شبکه عصبی و جنگل تصادفی در ایستگاه ماشین
 Figure (4) Annual changes of suspended sediment estimated by neural network and random forest models at Machine station

جدول (۷) پیش‌بینی میانگین سالانه رسوب با استفاده از مدل‌های مختلف
 Table(7) Prediction of annual average sedimentation using different models

ایستگاه ماشین Mashin st.		ایستگاه منجنیق Manjeniq st.		نوع مدل Model type
Ss	Sa	Ss	Sa	
1.03	88017	0.278	9755	ANN
1.96	166866	1.46	51245	ANFIS
0.67	57558	0.19	6844	RF

نتیجه گیری

یافته‌های این تحقیق نشان داد که روش‌های مبتنی بر یادگیری ماشینی به‌ویژه مدل شبکه‌های عصبی کارایی بسیار خوبی برای مدل‌سازی و پیش‌بینی رسوب در مقیاس روزانه دارند. لذا، استفاده از این روش‌ها می‌تواند خلاء ناشی از کمبود امکانات و تجهیزات رسوب‌سنجی در اکثر ایستگاه‌های هیدرومتری موجود در سطح کشور را تا حدود زیادی جبران نماید و نیاز به داده‌های پیوسته رسوب و سایر پارامترهای کیفی آب را برطرف نماید.

به نظر می‌رسد همواره بخشی قابل توجهی از خطا و عدم قطعیت ایجاد شده در نتایج مدل‌سازی یا شبیه‌سازی فرایندهای هیدرولوژیکی و رسوب در کشور مربوط به کمیت و کیفیت داده‌های مشاهده است. لذا، با توجه به اهمیت موضوع شبیه‌سازی و مدل‌سازی در مطالعات منابع آب و خاک، پیشنهاد می‌شود متولیان امر (وزارت نیرو) این موضوع را به‌طور جدی پیگیری نمایند و راه حلی برای آن ارائه دهند.

بر اساس نتایج شاخص PBIAS هر سه مدل استفاده شده در پیش‌بینی مقادیر اوج دبی رسوب ضعف داشتند و کم‌برآوردی قابل توجهی در نتایج مشاهده شد. به نظر می‌رسد که فراوانی داده‌های با دبی کم رسوب نسبت به تعداد اندک داده‌های با دبی زیاد علت وجود این مشکل می‌باشد. لذا، پیشنهاد می‌شود چنانچه امکان داشته باشد ابتدا داده‌های رسوب به دو گروه دبی کم و دبی زیاد تقسیم شوند و سپس برای هر گروه جداگانه شبیه‌سازی صورت گیرد.

علاوه بر این، از یافته‌های این تحقیق این‌گونه برداشت می‌شود که کارایی مدل‌ها بستگی به شرایط حوضه و رژیم رودخانه دارد و نمی‌توان انتظار داشت که یک مدل معین در تمام شرایط و مناطق بهترین نتیجه را ارائه دهد. لذا، شناسایی بهترین مدل در هر حوضه امر مهمی است. یافته دیگر این تحقیق این بود که نشان داد که استفاده از سایر متغیرهای پیش‌بینی‌کننده مانند خصوصیات

ژئومورفومتریکی یا آب و هوا (بارش) در کنار داده‌های دبی جریان باعث افزایش دقت پیش‌بینی مدل‌ها می‌شود. موضوعی که قبلاً کمتر مورد توجه قرار گرفته و در اکثر مطالعات قبلی تنها داده دبی به عنوان تخمین‌گر استفاده شده است.

سپاس‌گزاری

از معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز بابت حمایت‌کننده مالی این پژوهش تقدیر به عمل می‌آید. لازم به ذکر است که این مقاله از طرح شماره ۱۳۵۳ استخراج شده است.

References

- 1- Al-Mukhtar, M., 2019. Random forest, support vector machine, and neural networks to modelling suspended sediment in Tigris River-Baghdad. *Environ Monit Assess* 191, 673.
- 2- Arabkhedri, M., 2005. Investigation of suspended load in Iran's watershed basin. *Iranian J. Water Resour. Res.* 1: 2. 51-60. (In Persian)
- 3- Chen XY, Chau K.W., 2016. A hybrid double feedforward neural network for suspended sediment load estimation. *Water Resour Manag* 30: 2179–2194
- 4- Doğan E, Yüksel İ, Kişi Ö., 2007. Estimation of total sediment load concentration obtained by experimental study using artificial neural Networks. *Environ Fluid Mech* 7:271–288
- 5- Duan Y, Edwards JS, Dwivedi YK., 2019. Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. *Int J Inf Manag* 48:63–71
- 6- Ebrahimi Heravi B., Rangzan K., Kabolizadeh M., Daneshian H. 2017. Comparing Methods of Artificial Neural Network and Fuzzy System in Determining Pre-flooding Warning (Case Study: Zard River Sub-basin- Khuzestan Province). *Journal of Geography and Environmental Planning*, Vol 28, No. 1, Ser No. (65) Spring 2017. (in Persian with English abstract)
- 7- Ebtehaj I, Bonakdari H., 2014. Performance evaluation of adaptive neural fuzzy inference system for sediment transport in sewers. *Water Resour Manag* 28:4765–4779
- 8- Fu Z., Yang M. Batista J. R., 2020. "Using Fuzzy Models and Time Series Analysis to Predict Water Quality", *International Journal of Intelligent Systems and Applications (IJISA)*, Vol.12, No.2, pp.1-10,.
- 9- Gupta D., Hazarika B. B., Berlin M., Sharma U. M., and Mishra K. 2021. "Artificial intelligence for suspended sediment load prediction: a review" *Environmental earth sciences* 80, no. 9: 346. doi: 10.1007/s12665-021-09625-3
- 10- Hassan M, Shamim MA, Sikandar A, Mehmood I, Ahmed I, Ashiq SZ, Khitab A., 2015. Development of sediment load estimation models by using artificial neural networking techniques. *Environ Monit Assess* 187:686
- 11- Hayatzadeh M., Chezgi J., Dastorani M.T. 2015. Evaluation of Sediments Using Rating Curve and Artificial Neural Network Methods by Combining Morphological Parameters of Basin (Case Study: Bagh Abbas Basin). *Journal of Water and Soil Science* 19(72): 217-228. (in Persian with English abstract)
- 12- Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23 (3): 665–685.
- 13- Karimzadeh, H.; Alizadeh, M. 2018. Spatial Estimation of Soil Erosion in Iran Using RUSLE Model. *Iran. J. Echologyology.*, 5, 551–569. (in Persian with English abstract)
- 14- Khazayi, M., Dastranj A, Kazemi M, Falah S, Adeli, B. 2014. Assessment corrective methods for estimating suspended sediment (Case Study: Beshaar Watershed). *E.E.R.*, 2014; 4 (3) :47-57 (in Persian with English abstract)
- 15- Kisi O. 2005. Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrol Sci J* 50 (4):683–696
- 16- Kisi, O., Haktanir, T., Ardiclioglu, M., Ozturk, O., Yalcin, E. and Uludag, S. 2009. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software*, 40(6): 438-444.

- 17-Lafdani EK, Nia AM, Ahmadi A., 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *J Hydrol* 478:50–62
- 18-Leal Filho W, Skanavis C, Kounani A, Brandli LL, Shiel C, do Paco A, Salvia AL., 2019. The role of planning in implementing sustainable development in a higher education context. *J Clean Prod* 235:678–687
- 19-Li, L., Jiang P., Guang H., Dong L., Wu G., and Wu H. 2019. "Water quality prediction based on recurrent neural network and improved evidence theory: a case study of Qiantang River, China," *Environmental Science and Pollution Research*, vol. 26, no. 19, pp. 19879-19896, Mar.. London, UK, 2017; pp. 39–82.
- 20-Misra D, Oommen T, Agarwal A, Mishra SK, Thompson AM., 2009. Application and analysis of support vector machine based simulation for runoff and Sediment Yield. *Biosyst Eng* 103:527–535
- 21-Nourani V, Andalib G., 2015. Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches. *J Mt Sci* 12:85–100
- 22-Nourani, V., 2009. Using Artificial Neural Network (ANNs) For Sediment Load Forecasting of Talkherood River Mouth. *Urban and Environmental Engineering*, 3(1): 1- 6. (in Persian with English abstract)
- 23-Olyaie E, Banejad H, Kw C, Am 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* 187:189
- 24-Pimentel, D. and Kounang, N., 1998. Ecology of soil erosion in ecosystems. *Ecosystem* 1, 418–426.
- 25-Pimentel, D., Burgess, M., 2013. Soil Erosion Threatens Food Production. *Agriculture* 3, 443-463.
- 26-Pohlert, T. 2015. Projected climate change impact on soil erosion and sediment uield in the River Elbe catchment. Springer International Publishing Switzerland, 97-108.
- 27-Rajabi M. Feyzolahpour M., Roostaiee S., 2015. Estimating Suspended Sediment Concentration by a Neural Differential Evolution and Comparison it with ANFIS and RBF Models (Case study: Givi Chay River). 13-39. P 1-16. (in Persian with English abstract)
- 28-Rajaei T, Jafari H., 2020. Two decades on the artificial intelligence models advancement for modeling river sediment concentration: state-of-the-art. *J Hydrol* 588:125011
- 29-Rajpurkar, P., Chen, E., Banerjee, O., 2022. AI in health and medicine. *Nat Med* 28, 31–38. <https://doi.org/10.1038/s41591-021-01614-0>
- 30-Rezaei, K., Pradhan, B., Vadiati, M., 2021. Suspended sediment load prediction using artificial intelligence techniques: comparison between four state-of-the-art artificial neural network techniques. *Arab J Geosci* 14, 215.
- 31-Riahi S, M Nasrabadi and SM Mosavi. 2013. Application of the Intelligent Systems and Statistical Models in Estimation of Suspended Sediment Distribution. *Water and Soil Science journal*. 24-3. P. 231-242. (in Persian with English abstract)
- 32-Sadeghi, H. 2005. Development of sediment rating curve equations for rising and falling limbs of hydrograph using regression models. *Iran. J. Water Res.* 1: 1. 101-103. (In Persian)
- 33-Shamaei E, Kaedi M., 2016. Suspended sediment concentration estimation by stacking the genetic programming and neuro-fuzzy predictions. *Appl Soft Comput* 45:187–196

- 34-Tayfur, G., Ozdemir, S. and Singh, V. P., 2003. Fuzzy logic algorithm for runoff-induced sediment transport from bare soil surfaces. *Advances in water Resource*, 26(12): 1249-1256.
- 35-Vinutha, D.N. and Janardhana, M.R., 2014. Morphometry of the Payaswini Watershed, Coorg District, Karnataka, India, Using Remote Sensing and GIS Techniques. *International Journal of Innovative Research in Science, Engineering and Technology (IJIRSET)*, 3, 516-524.
- 36-Walling, D.E. 2011. Human impact on the sediment loads of Asian rivers. *Sediment Problems and Sediment. Management in Asian River Basins. IAHS Publ.*, 349, 37-51.
- 37-Walling, D.E. 2017. Measuring sediment yield from river basins. In *Soil Erosion Research Methods*; Routledge: London, UK,; pp. 39-82.
- 38-Yosefi, M. 2014. Suspended sediment estimation using neural network and algorithms assessment, case study: Lorestan Province. *Journal of Watershed Management Research*, 5(10): 85-97 (in Persian with English abstract)
- 39-Zounemat-KermaniM, Kişi Ö, Adamowski J, Ramezani-Charmahineh A., 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *J Hydrol* 535:457-472
- 40-Zhou, Shangguan & Zhao. 2006. Zhou Z, Shangguan Z, Zhao D. Modeling vegetation coverage and soil erosion in the Loess Plateau Area of China. *Ecological Modelling*. 2006;198(1-2):263-268.