

Evaluation the Performance of Artificial Neural Network Method and Deep Learning Method for Prediction of Bed Load in Gravel-Bed Rivers

Kiyoumars Roushangar^{*1}, Samira Joulazadeh²

1. Corresponding Author, Professor, Dept. of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.
E-mail: kroshangar@yahoo.com
2. M.Sc. Graduate of Water and Hydraulic Structures Engineering, Dept. of Civil Engineering, University of Tabriz, Tabriz, Iran.
E-mail: samirajj98@ms.tabrizu.ac.ir

Article Info

Article type:
Research Full Paper

Article history:
Received: 11.19.2021
Revised: 04.18.2022
Accepted: 04.27.2022

Keywords:
Artificial Neural Network,
Bed Load,
Classical Experimental
Formula,
Deep Learning,
Sediment Prediction

ABSTRACT

Background and Objectives: Assessing and estimating sediment transport from a long time ago is one of the major issues for hydraulic and river engineers. Determining the amount of bed load carried in rivers depends on various factors, and this factor has complicated this phenomenon. Studies on different rivers show that the amount of bed load in different hydraulic and hydrological conditions is different. In addition, the physical properties of bed load particles have a significant effect on the accuracy of model prediction. On the other hand, despite the emphasis on the unreliability of experimental equations that have been extended over a specific area, unfortunately, limited studies have been conducted on temporary changes in bed load. Therefore, Investigating the predictability of this phenomenon is of great importance. In this study, we will try to estimate the bed load in gravel bed rivers using classical and intelligent methods.

Materials and Methods: Machine learning methods due to their high accuracy in predicting various issues have been noted in recent years. Therefore, in the present study, two methods of classical artificial neural network (ANN) and deep learning of long short-term memory (LSTM), which is a kind of artificial neural network with layers and amplification algorithms to improve network performance; have been used to predict the bed load of 19 gravel-bed rivers. To define suitable models for networks, the results of 10 experimental formulas in bed load prediction have been evaluated and the parameters of superior formulas have been used as the input of intelligent networks.

Results: The results showed that all experimental formulas had very poor results; As most formulas have predicted the bed load with a Discrepancy index of r greater than 100. However, machine methods with input parameters obtained from experimental formulas have acceptable accuracy in predicting bed load. And in comparison with machine methods, LSTM method has provided more accurate results than ANN method. Finally, the model related to the parameters of Begnold formula in LSTM method with $DC= 0.900$ and $RMSE= 0.024 \text{ Kg m}^{-1} \text{ s}^{-1}$ for the test data is the best model obtained from this research and The average diameter of sediment particles (D_{50}), which is a common parameter of the top three models, has been selected as the most effective parameter in predicting bed load.

Conclusion: Despite the very poor performance of experimental formulas in predicting sediment transport, intelligent networks with input parameters

derived from experimental formulas have had good results. Also, LSTM network is more efficient than artificial neural network (ANN) in predicting bed load transfer, which indicates that Maintaining training memory during the training process and adding reinforcement layers to the network improves network performance and increases network accuracy in subsequent training.

Cite this article: Roushangar, Kiyoumars, Joulazadeh, Samira. 2022. Evaluation the Performance of Artificial Neural Network Method and Deep Learning Method for Prediction of Bed Load in Gravel-Bed Rivers. *Journal of Water and Soil Conservation*, 29 (1), 75-94.



© The Author(s).

DOI: 10.22069/jwsc.2022.19695.3515

Publisher: Gorgan University of Agricultural Sciences and Natural Resources

ارزیابی عملکرد روش‌های شبکه عصبی مصنوعی و یادگیری عمیق در تخمین بار بستر در رودخانه با بستر شنی

کیومرث روشنگر*^۱، سمیرا جولازاده^۲ 

۱. نویسنده مسئول، استاد گروه مهندسی آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران. رایانامه: kroshangar@yahoo.com
۲. دانش‌آموخته کارشناسی ارشد مهندسی آب و سازه‌های هیدرولیکی، دانشکده عمران، دانشگاه تبریز، تبریز، ایران.
رایانامه: samirajj98@ms.tabrizu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله کامل علمی- پژوهشی	سابقه و هدف: ارزیابی و برآورد میزان انتقال رسوب، از دیرباز یکی از مسائل عمده و اصلی مهندسان هیدرولیک و رودخانه بوده است. تعیین میزان بار بستری که در رودخانه‌ها حمل می‌شود، به عوامل متفاوتی بستگی داشته و همین عامل باعث پیچیدگی این پدیده شده است. مطالعات انجام‌شده بر روی رودخانه‌های مختلف نشانگر این مسأله است که مقدار بار بستر انتقالی در شرایط مختلف هیدرولیکی و هیدرولوژیکی متفاوت است، علاوه بر این خصوصیات فیزیکی ذرات بار بستر هم تأثیر به‌سزایی در میزان دقت مدل‌های پیش‌بینی دارد از طرفی علی‌رغم تأکید بر غیرقابل‌اعتماد بودن معادلات تجربی که بر روی یک ناحیه خاص گسترش یافته‌اند، متأسفانه مطالعات محدودی بر روی تغییرات موقتی بار بستر انجام‌شده است. از این رو بررسی قابلیت پیش‌بینی این پدیده از اهمیت بالایی برخوردار است. در این مطالعه سعی بر برآورد بار بستر در رودخانه‌های با بستر شنی با استفاده از روش‌های کلاسیک و هوشمند شده است.
تاریخ دریافت: ۰۰/۰۸/۲۸ تاریخ ویرایش: ۰۱/۰۱/۲۹ تاریخ پذیرش: ۰۱/۰۲/۰۷	مواد و روش‌ها: روش‌های یادگیری ماشین به دلیل دقت زیاد در پیش‌بینی مسائل مختلف در سال‌های اخیر مورد توجه زیادی قرار گرفته است. از این رو در مطالعه حاضر، از دو روش شبکه عصبی مصنوعی کلاسیک (ANN) و یادگیری عمیق از نوع حافظه طولانی کوتاه‌مدت (LSTM) که نوعی شبکه عصبی مصنوعی با لایه‌ها و الگوریتم‌های تقویتی برای بهبود عملکرد شبکه است؛ برای پیش‌بینی انتقال بار بستر ۱۹ رودخانه با بستر شنی استفاده شده است. برای تعریف مدل‌های مناسب برای شبکه‌ها، نتایج حاصل از ۱۰ فرمول تجربی در پیش‌بینی بار بستر مورد ارزیابی قرار گرفته و از پارامترهای فرمول‌های برتر به‌عنوان ورودی شبکه‌های هوشمند استفاده شده است.
واژه‌های کلیدی: بار بستر، پیش‌بینی رسوب، روابط کلاسیک تجربی، شبکه عصبی مصنوعی، یادگیری عمیق	

یافته‌ها: نتایج نشان داد همه فرمول‌های تجربی از نتایج بسیار ضعیفی برخوردار بوده‌اند؛ به طوری که اکثر فرمول‌ها، بار بستر را با شاخص اختلاف r بیش‌تر از ۱۰۰ پیش‌بینی کرده‌اند. با این حال روش‌های ماشینی با پارامترهای ورودی حاصل از فرمول‌ها تجربی از دقت قابل‌قبولی در پیش‌بینی بار بستر برخوردار بوده است و در مقایسه روش‌های ماشینی، روش LSTM نتایج دقیق‌تری را نسبت به روش ANN ارائه داده است. در نهایت مدل مربوط به پارامترهای فرمول بگنولد در روش LSTM با $DC=0/900$ و $RMSE=0/024 \text{ Kg m}^{-1} \text{ s}^{-1}$ برای داده‌های قسمت صحت‌سنجی برترین مدل حاصل از این پژوهش می‌باشد و پارامتر قطر متوسط ذرات رسوب (D_{50}) که پارامتر مشترک سه مدل برتر می‌باشد مؤثرترین پارامتر در پیش‌بینی بار بستر انتخاب شده است.

نتیجه‌گیری: با وجود عملکرد خیلی ضعیف فرمول‌های تجربی در پیش‌بینی انتقال رسوب، شبکه‌های هوشمند با پارامترهای ورودی حاصل از فرمول‌های تجربی از نتایج مطلوبی برخوردار بوده‌اند. همچنین شبکه یادگیری عمیق LSTM نسبت به شبکه عصبی مصنوعی ANN در پیش‌بینی انتقال بار بستر از کارایی بالاتری برخوردار بوده که بیانگر این است که حفظ حافظه آموزش در طول روند آموزش و اضافه کردن لایه‌های تقویتی به شبکه، باعث بهبود عملکرد شبکه شده و دقت شبکه را در آموزش‌های بعدی افزایش می‌دهد.

استناد: روشنگر، کیومرث، جولزاده، سمیرا (۱۴۰۱). ارزیابی عملکرد روش‌های شبکه عصبی مصنوعی و یادگیری عمیق در تخمین بار بستر در رودخانه با بستر شنی. *پژوهش‌های حفاظت آب و خاک*، ۲۹ (۱)، ۹۴-۷۵.

DOI: 10.22069/jwsc.2022.19695.3515



© نویسندگان.

ناشر: دانشگاه علوم کشاورزی و منابع طبیعی گرگان

مقدمه

در مهندسی هیدرولیک و رودخانه، بارهای جامد رسوبی نقش اساسی را در تعیین رفتار رودخانه و کنترل مورفولوژی را دارند؛ به همین دلیل ارزیابی و برآورد صحیح انتقال بار جامد رسوبی از دیرباز یکی از مسائل عمده و اصلی در علوم مرتبط با مهندسی رودخانه، مدیریت منابع آب و محیط‌زیست است. تعیین میزان بار جامد رسوبی که در رودخانه‌ها حمل می‌شود، به عوامل مختلفی از جمله پارامترهای هیدرولیکی، هیدرولوژیکی و رسوبی بستگی دارد و همین عامل باعث پیچیدگی این پدیده شده است. از طرف دیگر به علت عدم دستیابی به اطلاعات کامل و دقیق پارامترهای تأثیرگذار در فرآیند رسوب و عدم امکان بررسی تغییرات زمانی رسوبات حمل‌شده توسط جریان نمی‌توان مدل جامعی را در برآورد بار رسوب معرفی کرد. در شرایط طبیعی، انتقال بار رسوب یک فرآیند پایدار نیست و تغییرات زمانی و مکانی فراوانی دارد (۱). توانایی پیش‌بینی فرمول‌های انتقال بار بستر برای رودخانه‌های بزرگ به دلیل کمبود اندازه‌گیری‌های میدانی برای آزمایش، تا حد زیادی ناشناخته مانده است. پیش‌بینی بار بستر نیز به دلیل دسترسی و کیفیت داده‌های ورودی، مانند دبی، عمق، شیب و اندازه دانه و ... محدود شده است (۲). فرمول‌های حمل بار بستر بر این فرض بنا شده‌اند که بین متغیرهای هیدرولیکی، پارامترهای رسوب‌شناسی و میزان حمل بار بستر رابطه خاصی وجود دارد (۳). حدادچی و همکاران (۲۰۱۱) با استفاده از معادلات رایج به تخمین بار بستر در رودخانه با بستر درشت‌دانه پرداختند. آن‌ها دریافتند که فرمول‌های آماری توانایی پیش‌بینی بار بستر را نداشته و از میان کل فرمول‌ها، فرمول ون راین و مییر-پیتر و مولر بهترین نتیجه را ارائه داده‌اند (۴). ساسال و همکاران (۲۰۰۹) از شبکه عصبی مصنوعی پیش‌خور پس‌انتشار^۱ (FFNN) برای پیش‌بینی انتقال بار بستر

استفاده کردند؛ که نتایج حاصل نشان‌دهنده عملکرد مطلوب این روش نسبت به روش‌های استاندارد دیگر است (۵). در پژوهش انجام‌شده توسط یانگ و همکاران (۲۰۰۹)، یک مدل شبکه عصبی مصنوعی (ANN) با استفاده از چهار پارامتر غالب فرمول‌های انتقال رسوب: سرعت متوسط جریان، شیب سطح آب، عمق متوسط جریان و قطر متوسط ذره آموزش داده شده است، مطابق نتایج ارائه‌شده مدل ANN با چهار گره ورودی قادر به تخمین دقیق میزان انتقال رسوب است؛ اما یک مدل ANN با سه داده ورودی نیز می‌تواند بار رسوب را به‌اندازه برخی از فرمول‌های شناخته‌شده دقیق تخمین بزند (۶). کیتسیکودیس و همکاران (۲۰۱۴) از سه روش، شبکه‌های عصبی مصنوعی (ANN)، سیستم استنتاج فازی تطبیقی^۲ (ANFIS) و رگرسیون نمادین^۳ (SR) بر پایه برنامه‌ریزی ژنتیکی^۴ (GP) برای پیش‌بینی انتقال بار بستر استفاده کرده‌اند. سه ترکیب ورودی، عمدتاً براساس توان جریان، توان جریان در واحد عرض و تنش برشی مورد آزمایش قرار گرفتند. مدل‌های ANN و ANFIS نتایج بهتری نسبت به SR ارائه داده‌اند (۷). مصفایی و همکاران (۲۰۱۷)، از دو روش شبکه عصبی مصنوعی (ANN) و منحنی‌سنجه رسوب برای برآورد بار بستر استفاده کردند. آن‌ها از داده‌های ۵ ایستگاه هیدرومتری استفاده کردند. نتایج نشان داد که در تمامی ایستگاه‌ها با افزایش مقادیر دبی جریان، رسوبات بار بستر نیز افزایش می‌یابد و ANN نتایج بهتری نسبت به مدل منحنی‌سنجه ارائه داده است (۸). زیتار و عمرانی (۲۰۱۶) یک معماری عمیق شبکه عصبی برای استفاده در سری‌های زمانی داده‌های هواشناسی ارائه دادند که مبتنی بر شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM) بود که نتایج آن‌ها نشان داد که شبکه‌های عصبی مبتنی بر LSTM در مقایسه با روش‌های سنتی عملکرد خوبی داشتند و

2- Adaptive Neuro-Fuzzy Inference System
3- Symbolic Regression
4- Genetic Programming

1- The Feedforward-Backpropagated Artificial Neural Network

مورفولوژی مختلف، ارزیابی قابلیت این روش‌ها در برآورد بار بستر تحت این شرایط ضروری به نظر می‌رسد. بنابراین در مطالعه حاضر به ارزیابی عملکرد دو روش هوشمند ANN و LSTM در پیش‌بینی بار بستر در ۱۹ رودخانه پرداخته می‌شود. LSTM نوعی شبکه عصبی یادگیری عمیق است که توانایی اضافه کردن مفهوم زمان به مدل‌سازی را دارد. هدف از انجام این پژوهش بررسی عملکرد شبکه LSTM در پیش‌بینی بار بستر و مقایسه آن با روش شبکه عصبی کلاسیک ANN می‌باشد تا مشخص شود که حفظ حافظه آموزش در طول روند آموزش و اضافه کردن لایه‌های تقویتی به شبکه چه تأثیری را در عملکرد شبکه داشته و آیا از این روش می‌توان به‌عنوان جایگزینی از روش‌ها کلاسیک و روش ANN استفاده کرد یا نه.

مواد و روش‌ها

در این پژوهش از ۱۱۰۰ داده مربوط به ۱۹ رودخانه با بستر شنی واقع در ایالت آیداهو^۴ آمریکا که توسط سازمان جنگل‌داری ایالات متحده جمع‌آوری شده است؛ برای پیش‌بینی انتقال بار بستر استفاده خواهد شد. تمامی رودخانه‌های مورد مطالعه زیرحوزه رودخانه اسنیک^۵ بوده و از جریان‌ها و رودخانه‌های مختلفی با شرایط مختلف توپوگرافی، زمین‌شناسی، هیدرولیکی و رسوبی تشکیل شده است. بخش اعظمی از این داده‌ها در بین سال‌های ۱۹۹۴ و ۲۰۰۰ اندازه‌گیری شده‌اند که شامل مقادیر مربوط به هندسه کانال، مشخصات هیدرولیکی و مشخصات رسوبی شامل بار بستر، بار معلق و قطر متوسط ذرات رسوبی (D₅₀) است. تمامی داده‌های بار بستر در همه رودخانه‌ها توسط نمونه‌گیر اختلاف فشار هلی اسمیت^۶ اندازه‌گیری شده‌اند. بررسی جامع منطقه مورد مطالعه و جزئیات روش‌های به‌کاررفته برای اندازه‌گیری و

می‌توان از آن به‌عنوان یک روش عمومی برای پیش‌بینی شرایط جوی استفاده کرد (۹). بارونی و زیارتی (۲۰۱۹)، از شبکه عصبی LSTM برای مدل‌سازی دمای حداقل بر روی داده‌های هشت ایستگاه استان فارس استفاده کردند. نتایج به‌دست آمده نشان می‌دهد که این مدل نسبت به مدل‌های تجربی در همان ایستگاه‌ها خطای کم‌تری دارد (۱۰). کاوه و همکاران (۲۰۲۱)، از سه الگوریتم یادگیری LSTM، ANFIS و FFNN برای پیش‌بینی میزان رسوب معلق روزانه استفاده کردند. مقایسه نتایج نشان داد که شبکه LSTM در پیش‌بینی بار معلق توانایی بیشتری دارد به طوری که در مورد مقدار خطای RMSE مدل LSTM ۸/۶۲ درصد بهتر از شبکه‌های دیگر عمل کرده است (۱۱). هم‌چنین در پژوهش آل‌داهول و همکاران (۲۰۲۱) چهار مدل مختلف: رگرسیون خطی^۱ (LR)، شبکه عصبی پرسپترون چندلایه^۲ (MLP)، الگوریتم تقویت شدید گرادیان^۳ (XGB) و LSTM برای پیش‌بینی رسوبات معلق مورد آزمایش قرار گرفتند، مطابق نتایج ارائه شده LSTM نسبت به مدل‌های دیگر دقت بیشتری در پیش‌بینی بار معلق داشته است (۱۲).

از بررسی منابع ذکر شده مشخص می‌گردد که به‌دلیل کمبود داده‌های اندازه‌گیری شده برای رودخانه‌های شنی، پژوهش‌های انجام شده در این راستا محدود بوده و پژوهش‌چندانی در زمینه امکان‌سنجی کاربرد روش‌های هوشمند برای تخمین بار کل رسوب در رودخانه‌های شنی وجود ندارد. این در حالی است که پیچیدگی‌های حاکم بر پدیده انتقال رسوب، فرآیند پیش‌بینی با استفاده از روش‌های هوشمند و کلاسیک را در شرایط مختلف هیدرولیکی تحت‌تأثیر قرار داده و موجب کاهش دقت مدل‌سازی می‌شود؛ هم‌چنین با توجه به گسترش به‌کارگیری روش‌های هوشمند در برآورد بار رسوبی رودخانه‌ها با شرایط هیدرولیکی و

4- Idaho
5- Snake river
6- Helley-Smith Bedload Sampler

1- ElasticNet Linear Regression
2- Multi-Layer Perceptron neural network
3- Extreme Gradient Boosting

وانگ و پارکر (۲۰۰۶) و باتاچاریا و همکاران (۲۰۰۷) به پیش‌بینی میزان انتقال بار بستر پرداخته می‌شود (۱۴، ۱۵، ۱۶، ۱۷، ۱۸، ۱۹، ۲۰، ۲۱، ۲۲ و ۲۳)، روابط مذکور در جدول ۱ شرح داده شده‌اند. به‌استثناء فرمول پارکر و همکاران (۱۹۸۲) که از داده‌های میدانی حاصل شده است (۱۹)، بقیه همه فرمول‌های به‌کاررفته در این پژوهش از داده‌های آزمایشگاهی به‌دست آمده‌اند. به‌دلیل ماهیت منحصر به فرد هر رودخانه، عملکرد فرمول‌ها برای هر رودخانه به‌صورت جداگانه بررسی شده است.

جمع‌آوری داده‌های مختلف به‌تفصیل در پژوهش‌های کینگ و همکاران (۲۰۰۴) آمده است (۱۳). تاکنون روابط بسیاری براساس تئوری‌ها و روش‌های مختلف از جمله: تئوری تنش برشی، تئوری دبی بحرانی، تئوری قدرت جریان، تئوری تعادل انرژی، احتمالات، تحلیل رگرسیونی و... برای پیش‌بینی انتقال بار رسوب در شرایط خاص هیدرولیکی توسعه داده شده‌اند. در این پژوهش با استفاده از ۱۰ فرمول انتقال بار بستر: میسر-پیتر و مولر (۱۹۴۸)، شوکلیچ (۱۹۵۰)، انیشتین و براون (۱۹۵۰)، روتنر (۱۹۵۹)، بگنولد (۱۹۸۰)، پارکر و همکاران (۱۹۸۲)، ون راین (۱۹۸۴)، ویلکاک و کرو (۲۰۰۳)،

جدول ۱- فرمول‌های بار بستر.

Table 1. Bed load formulas.

رابطه Equation	تئوری Approach	نام Name
$q_s = 8 \left[\frac{\gamma_s}{\gamma_s - \gamma} \right] \left[\frac{g}{\gamma} \right]^{\frac{1}{2}} \left[\left(\frac{K'}{K} \right)^{\frac{3}{2}} \gamma R S - 0.047(\gamma_s - \gamma) D_{50} \right]^{\frac{3}{2}}$	تئوری تعادل شیب انرژی Energy slope method	میسر - پیتر و مولر (۱۹۴۸) Meyer-Peter Müller (1948)
$q_s = 2.5 \rho_s \left[\frac{\gamma_s}{\gamma} \right]^{-1} S^{\frac{3}{2}} (q - q_c)$ $q_c = 0.26 \left[\frac{\gamma_s}{\gamma} - 1 \right]^{\frac{5}{3}} D_{50}^{\frac{3}{2}} S^{-\frac{7}{6}}$	تئوری دبی بحرانی Discharge method	شوکلچ (۱۹۵۰) Schoklitsch (1950)
$q_s = \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \left[\left[\frac{2}{3} + \frac{36v^2}{g(s-1)D^3} \right]^{0.5} - \left[\frac{36v^2}{g(s-1)D^3} \right]^{0.5} \right] f'$ $f' = \begin{cases} 2.15 \exp\left(-\frac{0.391}{\theta}\right) & \theta < 0.182 \\ 40\theta^3 & \theta \geq 0.182 \end{cases}$	تئوری احتمالاتی Probabilistic method	انیشتین و براون (۱۹۵۰) Einstein and Brown (1950)
$q_s = \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g y^3 \right]^{\frac{1}{2}} \left[\frac{V}{\left[\frac{\gamma_s - \gamma}{\gamma} g y \right]^{\frac{1}{2}}} \left[\frac{2}{3} \left(\frac{D_{50}}{y} \right)^{\frac{2}{3}} + 0.14 \right] - 0.78 \left(\frac{D_{50}}{y} \right)^{\frac{2}{3}} \right]^3$	تحلیل رگرسیونی Regression method	روتنر (۱۹۵۹) Rottner (1959)
$q_s = q_{sr} \rho_s \frac{\rho_s}{\rho_s - \rho} \left[\frac{\omega - \omega_c}{(\omega - \omega_c)_r} \right]^{\frac{3}{2}} \left[\frac{\gamma}{\gamma_r} \right]^{-\frac{2}{3}} \left[\frac{D_{50}}{D_{50r}} \right]^{-\frac{1}{2}}$ $\omega = \rho \gamma S V, \quad \omega_c = 290 D_{50}^{\frac{3}{2}} \log\left(\frac{12\gamma}{D_{50}}\right), \quad (\omega - \omega_c)_r = 0.5 \text{ km}^{-1} \text{ s}^{-1}$ $q_{sr} = 0.1 \text{ km}^{-1} \text{ s}^{-1}, \quad \gamma_r = 0.1 \text{ m}, \quad D_{50r} = 0.0011 \text{ m}.$	تئوری قدرت جریان Stream Power method	بگنولد (۱۹۸۰) Bagnold (1980)

ادامه جدول ۱-

Continue Table 1.

رابطه Equation	تئوری Approach	نام Name
$q_s = \frac{W^* u_*^3 \rho_s}{(\gamma_s - 1) g}, \quad \phi_{50} = \frac{\theta}{\theta_c}, \quad \theta = \frac{\gamma RS}{(\gamma_s - \gamma) D_{50}}, \quad \theta_c = 0.0876$ $W^* = \begin{cases} 11.2 \left(1 - \frac{0.822}{\phi_{50}}\right)^{4.5} & \phi_{50} > 1.65 \\ 0.0025 \exp[14.2(\phi_{50} - 1) - 9.3(\phi_{50} - 1)^2] & 0.95 < \phi_{50} < 1.65 \\ 0.0025 \phi_{50}^{14.2} & \phi_{50} < 0.95 \end{cases}$	تئوری جابه‌جایی مساوری Equal Mobility method	پارکر و همکارانش (۱۹۸۲) Parker et al. (1982)
$q_s = 0.053 \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \frac{T^{2.1}}{D_*^{0.3}}$ $T = \frac{\theta - \theta_c}{\theta_c}, \quad \theta = \frac{\gamma RS}{(\gamma_s - \gamma) D_{50}}, \quad D_* = D_{50} \left[\frac{(\gamma_s - \gamma) g}{v^2} \right]^{1/3}$	تحلیل رگرسیونی Regression method	ون راین (۱۹۸۴) Van Rijn (1984)
$q_s = \frac{W^* u_*^3 \rho_s}{(\gamma_s - 1) g}, \quad \phi_{50} = \frac{\theta}{\theta_c}, \quad \theta = \frac{\gamma RS}{(\gamma_s - \gamma) D_{50}}$ $W^* = \begin{cases} 14 \left(1 - \frac{0.894}{\phi_{50}^{0.5}}\right)^{4.5} & \phi_{50} \geq 1.35 \\ 0.002 \phi_{50}^{7.5} & \phi_{50} < 1.35 \end{cases}$	تئوری جابه‌جایی مساوری Equal Mobility method	ویلکاک و کرو (۲۰۰۳) Wilcock and Crowe (2003)
$q_s = 4.93 \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \left[\frac{\gamma RS}{(\gamma_s - \gamma) D_{50}} - 0.047 \right]^{1.6}$	تئوری تنش برشی Shear stress method	وانگ و پارکر (۲۰۰۶) Wong and Parker (2006)
$q_s = \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \Phi_b, \quad T_* = \frac{\theta - \theta_c}{\theta_c}, \quad \theta = \frac{\gamma RS}{(\gamma_s - \gamma) D_{50}}$ $\Phi_b = \begin{cases} 0.072078 \frac{T_*^{0.893}}{D_*^{0.353}} & T_* > 0.04 \\ 0.000182 \frac{T_*^{0.13}}{D_*^{0.0673}} & T_* \leq 0.04 \text{ and } D_* \leq 181.3 \\ 0.0000124 \frac{T_*^{0.13}}{D_*^{0.0673}} & T_* \leq 0.04 \text{ and } D_* > 181.3 \end{cases}$	تحلیل رگرسیونی و یادگیری ماشین Regression analysis via Machine learning	باتاچاریا و همکاران (۲۰۰۷) Bhattacharya et al. (2007)

q_s^* دبی بار بستر در واحد عرض ($\text{kg s}^{-1} \text{m}^{-1}$), y عمق جریان (m), V سرعت متوسط جریان (m s^{-1}), S شیب بستر (m m^{-1}), D_{50} قطر متوسط ذرات رسوب (m), u_*^* سرعت برشی (m s^{-1}), Θ پارامتر شیلدز, Θ_c پارامتر شیلدز بحرانی, q دبی جریان در واحد عرض ($\text{m}^3 \text{s}^{-1} \text{m}^{-1}$), R شعاع هیدرولیکی (m), γ_s و γ وزن مخصوص رسوب و آب (N m^{-3}), ρ_s و ρ چگالی رسوب و آب (kg m^{-3}), g شتاب جاذبه (m s^{-2}), K مقاومت بستر ($\text{s m}^{-1/3}$), K' مقاومت ناشی از زبری دانه‌ها ($\text{s m}^{-1/3}$), ω قدرت جریان در واحد عرض ($\text{kg s}^{-1} \text{m}^{-1}$), ω_c قدرت جریان بحرانی در ابتدای حرکت ($\text{kg s}^{-1} \text{m}^{-1}$), W^* نرخ بی‌بعد انتقال رسوب, D^* قطر بی‌بعد ذرات و T پارامتر حرکت

و محوشدگی^۷ تدریجی می‌شود (۲۶). شبکه حافظه طولانی کوتاه‌مدت^۸ LSTM یک نسخه بهبودیافته از RNN هستند که توانایی یادگیری وابستگی‌های بلندمدت را دارند. عنصر اصلی شبکه LSTM، سلول حالت^۹ است. LSTM این توانایی را دارد که اطلاعات جدیدی را به سلول حالت اضافه یا اطلاعات آن را حذف کند. این کار توسط ساختارهایی به نام گیت انجام می‌شود. گیت‌ها مسیر ورودی اطلاعات هستند (۲۶). آن‌ها از یک لایه شبکه عصبی سیگموئید به همراه یک عملگر ضرب نقطه به نقطه تشکیل شده‌اند خروجی لایه سیگموئید عددی بین صفر و یک است که نشان می‌دهد چه مقدار از ورودی باید به خروجی ارسال شود. مقدار صفر یعنی هیچ اطلاعاتی نباید به خروجی ارسال شود در حالی که مقدار یک یعنی تمام ورودی به خروجی ارسال شود. LSTM دارای ۳ گیت: ورودی، خروجی و گیت فراموشی^{۱۰} برای کنترل مقدار سلول حالت است (۲۵). گیت فراموشی تشخیص می‌دهد چه میزان از اطلاعات را باید از سلول حالت حذف کرد. این موضوع توسط تابع سیگموئید تصمیم‌گیری می‌شود. تابع سیگموئید، با توجه به مقادیر h_{t-1} و x_t برای هر عدد در سلول حالت C_{t-1} مقدار بین صفر الی یک را به خروجی می‌برد (۲۷). شبکه LSTM به صورت شکل ۱ توصیف می‌شود؛ و در هر گام زمانی t توسط معادلات ۱ الی ۶ به‌روزرسانی می‌شود.

انواع مختلفی شبکه عصبی مصنوعی^۱ (ANN) برحسب کاربرد آن‌ها وجود دارد که در این پژوهش از شبکه معمول و پرکاربرد پرسپترون چندلایه^۲ که از نوع مدل‌های شبکه عصبی با الگوریتم انتشار برگشتی می‌باشد با سه لایه (لایه ورودی و خروجی و یک لایه پنهان) و با تابع فعال‌ساز سیگموئید استفاده شده است. از میان روش‌های مختلف آموزش، الگوریتم لونیگ-مارکوورت^۳، به دلیل همگرایی سریع‌تر در آموزش شبکه‌های با اندازه متوسط، برای استفاده در پژوهش حاضر انتخاب شده است. مدل‌سازی این شبکه در نرم‌افزار متلب انجام گرفته است.

لفظ یادگیری عمیق^۴ عموماً در حوزه شبکه‌های عصبی مصنوعی به کار می‌رود؛ که نخستین بار توسط ایگور آیزنبرگ و همکاران (۲۰۰۰) در حوزه یادشده استفاده شد (۲۴). شبکه عصبی بازگشتی^۵ (RNN) نوعی شبکه عصبی در زمینه یادگیری عمیق است که در آن خروجی مرحله قبلی به عنوان ورودی به مرحله فعلی داده می‌شود. در شبکه‌های عصبی سستی، همه ورودی‌ها و خروجی‌ها از یکدیگر مستقل هستند و شبکه قادر به یادآوری اطلاعات قبلی نیست، در حالی که شبکه RNN این مشکل را با کمک یک لایه مخفی حل می‌کند. در واقع اصلی‌ترین و مهم‌ترین ویژگی RNN این است که به دلیل حافظه داخلی خود می‌تواند موارد مهمی را در مورد ورودی دریافت شده به خاطر بسپارند که به آن‌ها اجازه می‌دهد در پیش‌بینی موارد بعدی بسیار دقیق باشند (۲۵). مشکل اصلی شبکه‌های RNN، حافظه کوتاه‌مدت آن‌ها است؛ که شبکه با گذشت زمان دچار مشکل انفجار گرادیان^۶

7- Vanishing

8- Long Short-Term Memory

9- Cell State

10- Forgate gate

1- Artificial Neural Network

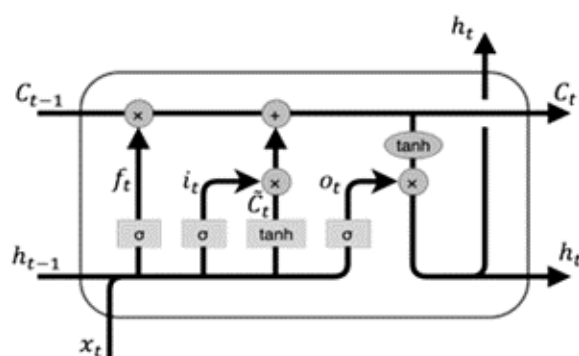
2- Multi-Layer Perceptron (MLPs)

3- Levenberg-Marquardt

4- Deep Learning

5- Recurrent Neural Network

6- Exploding Gradient



شکل ۱- سلول شبکه LSTM.

Figure 1. LSTM network cell.

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (3)$$

$$\tilde{c}_t = \sigma_h(W_z x_t + U_z h_{t-1} + b_z) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (5)$$

$$h_t = o_t \odot \sigma_h(c_t) \quad (6)$$

مدل‌های هوشمند باشد. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود بنابراین نرمالیزه کردن داده‌ها به خصوص زمانی که دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. به همین دلیل در این پژوهش ابتدا داده‌ها به روش لگاتس و مک کابه (۱۹۹۸) در بازه بین ۰/۱ و ۱ مطابق رابطه ۷ نرمال‌سازی می‌شوند (۲۸). برای رسیدن به نتایج بهتر و دقیق‌تر روند آموزش چند بار تکرار گردیده و در نهایت ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد نیز برای قسمت صحت‌سنجی استفاده شده است.

در روابط بالا، x_t بردار ورودی، h_t بردار حالت مخفی یا بردار خروجی نهایی، f_t بردار فعال‌ساز گیت فراموشی، i_t بردار فعال‌ساز گیت ورودی، o_t بردار فعال‌ساز گیت خروجی، \tilde{c}_t بردار فعال‌ساز ورودی سلول، h_t بردار فعال‌ساز خروجی سلول، c_t بردار حالت سلول، W ماتریس وزنی قابل‌یادگیری، U ماتریس وزنی قابل‌یادگیری با یک واحد تاخیر زمانی، b بردار بایاس، σ و σ_h تابع فعال‌ساز سیگموئید و تانژانت هیپربولیک و \odot ضرب نقطه‌ای دو بردار را نشان می‌دهد.

یکی از مراحل پیش‌پردازش داده‌ها، نرمال‌سازی آن‌ها می‌باشد که می‌تواند باعث افزایش کارایی

$$x_n = 0.1 + 0.9 \times \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (7)$$

مربعات خطاها (RMSE) مورد استفاده قرار خواهند گرفت؛ که هرچقدر R و DC بیشتر و به یک نزدیک‌تر و برعکس RMSE کم‌تر و به صفر نزدیک‌تر باشد بیانگر مطلوب بودن مدل و دقت قابل قبول آن می‌باشد.

$$R = \frac{\sum_{i=1}^n (Q_{oi} - Q_{om}) \times (Q_{pi} - Q_{pm})}{\sqrt{\sum_{i=1}^n (Q_{oi} - Q_{om})^2 \times \sum_{i=1}^n (Q_{pi} - Q_{pm})^2}} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{oi} - Q_{pi})^2}{n}} \quad (9)$$

$$DC = 1 - \frac{\sum_{i=1}^n (Q_{oi} - Q_{pi})^2}{\sum_{i=1}^n (Q_{oi} - Q_{om})^2} \quad (10)$$

نسبت دبی رسوب پیش‌بینی شده به دبی رسوب مشاهداتی می‌باشد (۲۹)؛ که هرچه مقدار آن به عدد یک نزدیک باشد بیانگر دقت بیشتر مدل می‌باشد.

$$r = \frac{Q_{pi}}{Q_{oi}} \quad (11)$$

ضعیف ۱۰ فرمول در پیش‌بینی بار بستر می‌باشد. به طوری که درصد شاخص اختلاف (r) برای هر ۱۰ فرمول در بازه ۰/۵ الی ۲ کم‌تر از ۱۰ درصد می‌باشد؛ و اکثر فرمول‌ها، بار بستر را با شاخص اختلاف r بیشتر از ۱۰۰ پیش‌بینی کرده‌اند. تمامی ۱۰ فرمول مقدار ضریب DC منفی و خطای RMSE زیاد و نامطلوبی ارائه داده‌اند. دلیل عملکرد ضعیف این فرمول‌ها می‌تواند مربوط به شرایط توسعه این فرمول‌ها باشد که از چندین داده‌های آزمایشگاهی و برای شرایط خاص رودخانه‌ها توسعه داده شده‌اند. فرمول روتنر با شاخص اختلاف ۱۳/۳ درصد در بازه

در این رابطه، X_{min} و X_{max} به ترتیب حداقل و حداکثر داده‌ها و X_n داده‌های نرمال شده می‌باشد. به منظور ارزیابی مدل‌ها و پیش‌بینی دقیق آن‌ها، شاخص‌های آماری مختلفی تدوین شده است؛ که در این پژوهش پرکاربردترین آن‌ها عبارتند از: ضریب همبستگی (R)، ضریب تعیین (DC) و جذر میانگین

به منظور ارزیابی عملکرد فرمول‌های کلاسیک و محدوده پیش‌بینی فرمول‌ها از نسبت اختلاف r استفاده گردید. نسبت اختلاف r، مطابق رابطه ۱۱،

در روابط ذکر شده، Q_{oi} بیانگر مقادیر مشاهداتی، Q_{pi} مقادیر پیش‌بینی شده، Q_{om} میانگین مقادیر مشاهداتی، Q_{pm} میانگین مقادیر پیش‌بینی شده و n تعداد کل داده‌ها می‌باشد.

نتایج و بحث

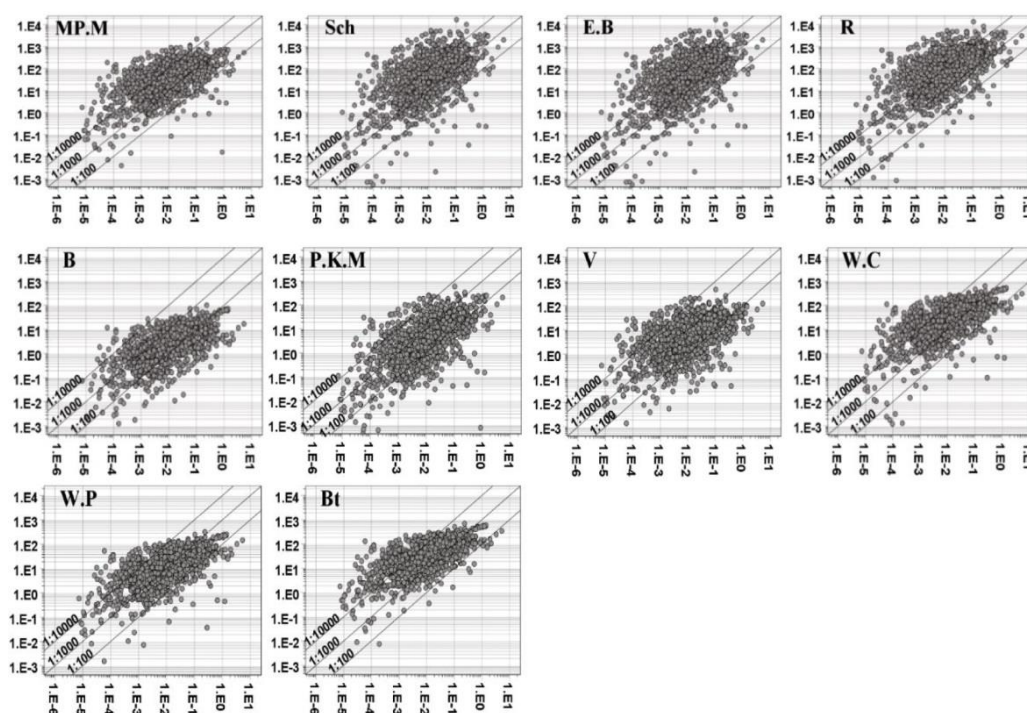
میانگین نتایج کلی ۱۰ فرمول برای ۱۹ رودخانه در جدول ۲ و نمودارهای پراکنش بین داده‌های پیش‌بینی شده و مشاهداتی برای کل داده‌های در شکل ۲ آورده شده است. نتایج حاصل بیانگر عملکرد

به فرمول روتنر با $R=0.513$ و کم‌ترین خطا مربوط
 به فرمول باتاچاریا با $RMSE=1/9 \text{ Kg m}^{-1} \text{ s}^{-1}$ می‌باشد.
 ۰/۱ الی ۱۰ و ۴۱/۹ درصد در بازه ۱۰ الی ۱۰۰ در این
 پژوهش، دقت نسبتاً بهتری نسبت به بقیه فرمول‌ها
 داشته است؛ و همچنین بیش‌ترین همبستگی مربوط

جدول ۲- نتایج حاصل از فرمول‌های کلاسیک تجربی.

Table 2. Results from classical experimental formulas.

فرمول Formula	r(0/5-2)%	r(0/2-5)%	r(0/1-10)%	r(10-100)%	r(>100)%	DC	R	RMSE (Kg m ⁻¹ s ⁻¹)
میبر- پیتر و مولر MP-M	0.2	0.3	0.4	3.4	95.0	-188955.7	0.487	55.8
شوکلج Sch	0.7	2.3	5.2	26.4	63.5	-6441.3	0.401	10.3
انیشتین و براون E-B	0.0	0.6	1.5	3.9	94.3	-31167903.5	0.205	716.5
روتنر R	2.6	6.9	13.3	41.9	38.9	-1427.7	0.513	4.9
بگنولد B	0.7	2.6	5.8	26.5	64.8	-11193.5	0.328	13.6
پارکر و همکاران P-K-M	0.3	1.2	1.8	1.6	93.8	-413000.4	0.477	82.5
ون راین V	0.9	2.8	4.9	18.0	75.6	-43031.5	0.229	26.6
ویلکاک و کرو W-C	1.2	2.4	4.2	13.4	79.8	-83353.5	0.372	37.1
وانگ و پارکر W-P	0.1	0.4	0.8	6.1	91.8	-75549.3	0.469	35.3
باتاچاریا و همکاران Bt	0.4	1.3	5.3	38.6	55.2	-221.1	0.475	1.9



شکل ۲- نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده با استفاده از روابط کلاسیک برای کل رودخانه‌ها.

Figure 2. Distribution diagram between observational and predicted data using classical relationships for all rivers.

(۲۳ و ۲۰). و در چهار مدل دیگر از پارامترهای فرمول‌های روتنر (۱۹۵۹) شامل عمق متوسط جریان (Y)، سرعت متوسط جریان و قطر متوسط ذرات رسوب (D_{50})، فرمول بگنولد (۱۹۸۰) شامل عمق متوسط جریان (Y)، قدرت جریان در واحد عرض (ω) و قطر متوسط ذرات رسوب (D_{50})، فرمول شوکلیج (۱۹۵۰) شامل دبی جریان در واحد عرض (q)، قطر متوسط ذرات رسوب (D_{50}) و فرمول ویلکاک و کرو (۲۰۰۳) شامل سرعت برشی (u^*) و نسبت پارامتر شیلدز به پارامتر شیلدز بحرانی (ϕ_{50}) بهره گرفته شده است (۱۷، ۱۸، ۱۵ و ۲۱).

برای تعیین پارامترهای ورودی مدل‌ها از نتایج بخش‌های قبلی بهره گرفته شده است. مطابق جدول ۳ از پارامترهای به‌کاررفته در ۶ فرمول تجربی استفاده می‌شود. از مدل‌سازی چهار فرمول میبیر- پیتر و مولر (۱۹۴۸)، انیشتین و براون (۱۹۵۰)، پارکر و همکاران (۱۹۸۲) و وانگ و پارکر (۲۰۰۳) که نتایج ضعیفی نسبت به فرمول‌های دیگر داشته‌اند، صرف‌نظر شده است (۱۴، ۱۶، ۱۹ و ۲۲). و دو فرمول باتاچاریا و همکاران (۲۰۰۷) و ون راین (۱۹۸۴) که دارای پارامترهای مشترک، قطر بی‌بعد ذرات (D^*) و پارامتر حرکت (T) می‌باشند، به‌صورت یک مدل ارائه شده‌اند

جدول ۳- مدل‌های تعریف شده برای روش‌های ماشینی.

Table 3. Defined models for machine methods.

پارامترها Parameters	فرمول Formula	مدل Model
(Y, V, D ₅₀)	روتنر Rottner	مدل ۱ Model 1
(D*, T)	باتاچاریا Bhattacharya	مدل ۲ Model 2
(Y, ω, D ₅₀)	بگنولد Bagnold	مدل ۳ Model 3
(q, S, D ₅₀)	شوکلچ Schoklitsch	مدل ۴ Model 4
(Ø ₅₀ , u*)	ویلکاک و کرو Wilcock and Crowe	مدل ۵ Model 5

به صورت تصادفی رها می‌شوند. این بدین معنا است که یادگیری بر روی معماری‌های متفاوت با مجموعه نرون‌های متفاوت صورت می‌گیرد. برای لایه رهاساز باید درصد داده‌های رهاساز مشخص گردد که مقدار آن ۵ درصد انتخاب شده است. در این پژوهش از تابع بهینه‌ساز ADAM جهت به‌روزرسانی وزن‌ها استفاده شده است. فلوچارت روند مدل‌سازی در شبکه LSTM در شکل ۴ و مشخصات مربوط به آموزش این شبکه در جدول ۴ ارائه شده است. برای ANN نیز تعداد تکرارهای بین ۳۰۰ در نظر گرفته شده است؛ و تعداد نرون‌های لایه میانی با روش سعی و خطا بهینه می‌شود.

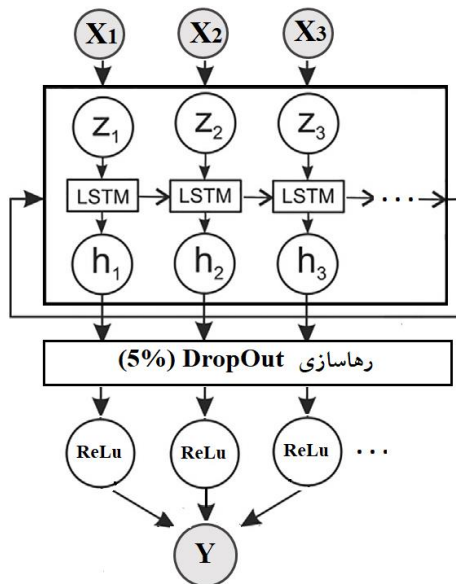
مدل‌سازی این شبکه به دلیل دقت بیشتر با کدنویسی در محیط پایتون با استفاده از کتابخانه یادگیری عمیق کراس^۱ انجام شده است. در شبکه‌های LSTM علاوه بر تعداد نرون‌ها و تکرارها^۲، مقادیر مربوط به اندازه بسته‌ها^۳ و نرخ یادگیری^۴ نیز در دقت شبکه دارای اهمیت می‌باشند؛ و باید مقادیر مربوط به آن‌ها با سعی و خطا بهینه شود. تعداد و نوع لایه‌های به‌کاررفته در این شبکه با ارزیابی دقت شبکه به صورت بهینه انتخاب شده‌اند. ساختار کلی شبکه به این گونه طراحی شده است که ابتدا داده‌های ورودی وارد شبکه LSTM همراه با یک لایه رهاساز^۵ شده سپس وارد لایه میانی با یک تابع فعال‌ساز RELU می‌شود؛ و در نهایت به خروجی شبکه متصل می‌شود (شکل ۳)؛ رهاسازی داده‌ها یک فن است که مانع بیش‌برازش شبکه می‌شود. عملکرد آن به این صورت است که در هنگام یادگیری، برخی از نرون‌ها

- 1- Keras
- 2- Epoch
- 3- Batch size
- 4- Learning rate
- 5- DropOut

جدول ۴- مشخصات مربوط به ساختار شبکه LSTM.

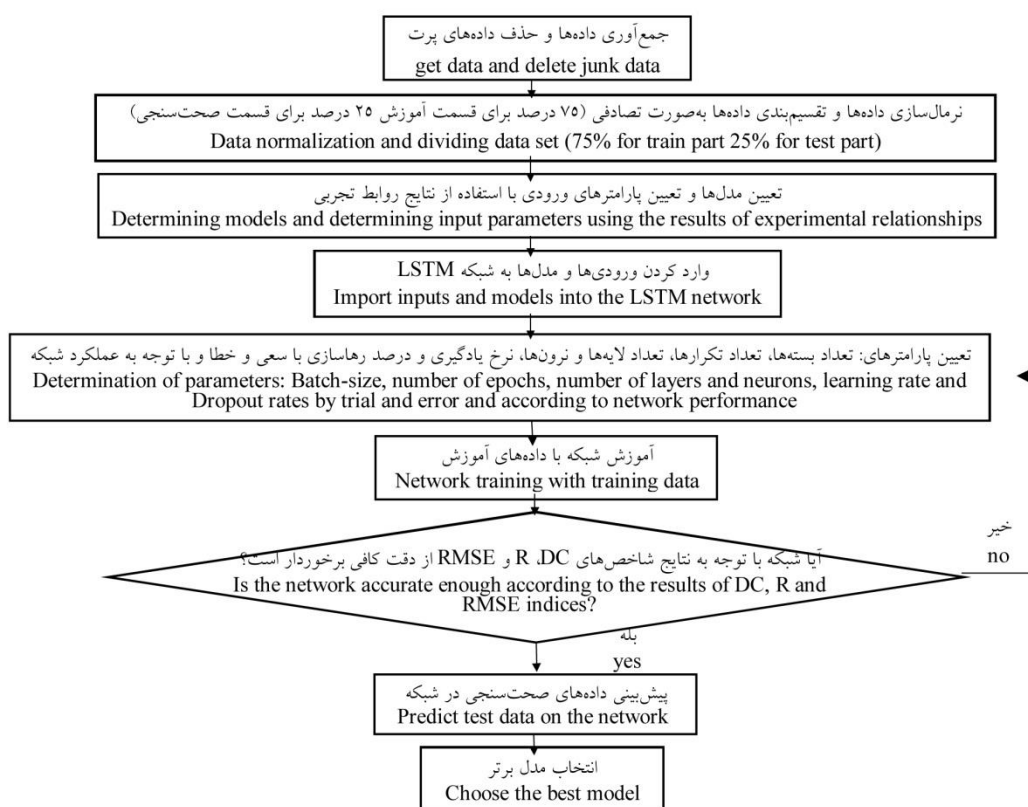
Table 4. LSTM network structure features.

مقدار Value	مشخصه Property
ADAM	تابع بهینه‌ساز Optimizer function
300	تعداد تکرار Number of epochs
32	تعداد بسته Batch-size
0.005	نرخ یادگیری Learning rate
5%	درصد رهاسازی Dropout rates
RMSE	تابع ارزیابی Evaluation function



شکل ۳- ساختار شبکه LSTM مورد استفاده در این پژوهش.

Figure 3. The structure of the LSTM network used in this research.



شکل ۴- ساختار شبکه LSTM مورد استفاده در این پژوهش.

Figure 4. The structure of the LSTM network used in this research.

می‌باشند نیز از دقت قابل‌قبولی برخوردارند. پارامتر مشترک این ۳ مدل ذکر شده پارامتر قطر متوسط ذرات رسوب (D_{50}) است که نشان‌دهنده نقش کلیدی این پارامتر در پیش‌بینی بار بستر است. فرمول باتاچاریا با این که در قسمت فرمول‌های کلاسیک کم‌ترین خطای RMSE را ارائه داده بود ولی پارامترهای مربوط به این فرمول به‌عنوان ورودی شبکه‌های ماشینی ضعیف‌ترین عملکرد را داشته است. دو مدل ۲ و ۵ که مربوط به فرمول‌های باتاچاریا و ویلکاک و کرو می‌باشد. ضعیف‌ترین نتایج را نسبت به مدل‌های دیگر داشته‌اند؛ دلیل آن می‌تواند تعداد و نوع پارامترهای به‌کاررفته در مدل‌ها باشد. به‌طوری‌که در سه فرمول برتر از ۳ پارامتر ورودی استفاده شده ولی در مدل‌های ۲ و ۵ فقط از ۲ پارامتر ورودی

نتایج حاصل از دو روش یادگیری ماشین با معیارهای ارزیابی DC، R، و RMSE در جدول ۵ ارائه شده است. در شکل ۵ نیز نتایج ۵ مدل حاصل از دو روش به‌صورت نمودار میله‌ای با ضریب ارزیابی DC مقایسه شده است. نتایج حاصله قابلیت و کارایی بالای روش‌های ماشینی را در برآورد میزان انتقال بار بستر را به اثبات رساند. به‌طوری‌که از ۵ مدل به‌کار رفته در این پژوهش ۳ مدل از دقت قابل‌قبولی برخوردار می‌باشند. همان‌طور که مشاهده می‌شود، در تمامی ۵ مدل مذکور روش LSTM نتایج دقیق‌تری را نسبت به روش ANN ارائه داده است؛ و مدل ۳ که مربوط به پارامترهای فرمول بگنولد است برترین مدل حاصل از دو روش مذکور است. هم‌چنین مدل‌های ۱ و ۴ که مربوط به فرمول‌های شوکلیچ و روتنر

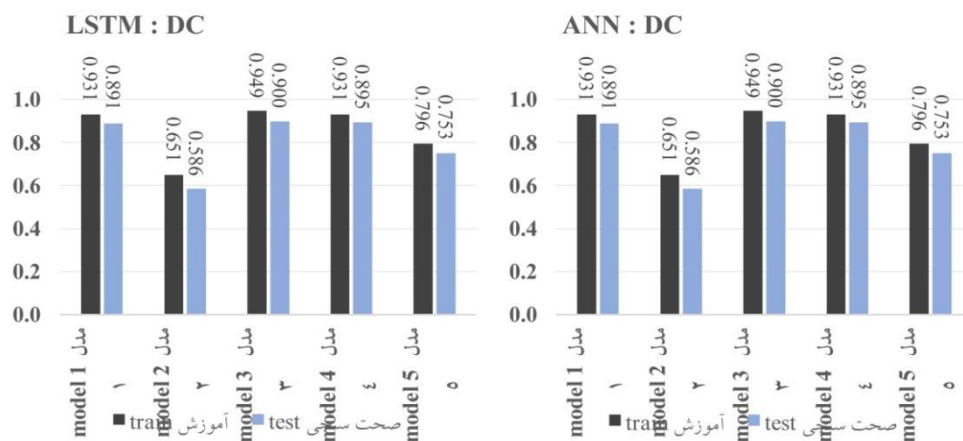
روند آموزش و اضافه کردن لایه‌های تقویتی به شبکه، باعث بهبود عملکرد شبکه شده و دقت شبکه را در آموزش‌های بعدی افزایش می‌دهد. نمودارهای مربوط به پراکنش داده‌های مشاهداتی و پیش‌بینی شده برای مدل برتر در شکل ۶ نشان داده شده است. با توجه به پراکنندگی بالای داده‌ها جهت مشاهده بهتر پراکنندگی داده‌ها از نمودار لگاریتمی استفاده گردید.

استفاده شده است. در نهایت مدل فرمول بگنولد حاصل از روش LSTM با $DC=0/900$ و $Kg\ m^{-1}\ s^{-1}$ و $RMSE=0/024$ برای قسمت صحت‌سنجی برترین مدل حاصل از این پژوهش است؛ و نتایج کل مدل‌ها که عملکرد بهتر شبکه LSTM را نسبت به شبکه ANN در پیش‌بینی انتقال بار بستر به اثبات رساند؛ بیانگر این است که حفظ حافظه آموزش در طول


جدول ۵- نتایج حاصل از روش‌های یادگیری ماشین.

Table 5. Results from machine methods.

LSTM			ANN				تعداد نرون Number of neurons	مدل Model
RMSE ($Kg\ m^{-1}\ s^{-1}$)	R	DC	RMSE	R	DC			
0.027	0.965	0.931	0.041	0.941	0.886	8	آموزش Train مدل ۱ Model 1	
0.029	0.948	0.891	0.047	0.938	0.880	8	آزمون Test	
0.054	0.809	0.651	0.077	0.760	0.576	7	آموزش Train مدل ۲ Model 2	
0.066	0.782	0.586	0.068	0.733	0.519	7	آزمون Test	
0.025	0.974	0.949	0.038	0.956	0.914	7	آموزش Train مدل ۳ Model 3	
0.024	0.950	0.900	0.046	0.945	0.892	7	آزمون Test	
0.026	0.965	0.931	0.041	0.943	0.889	9	آموزش Train مدل ۴ Model 4	
0.036	0.950	0.895	0.051	0.928	0.854	9	آزمون Test	
0.052	0.892	0.796	0.058	0.846	0.713	5	آموزش Train مدل ۵ Model 5	
0.055	0.874	0.753	0.064	0.820	0.666	5	آزمون Test	



شکل ۵- نمودار میله‌ای مربوط به ضریب DC برای ۵ مدل در دو شبکه ANN و LSTM.
Figure 5. DC coefficient bar diagram for 5 models in ANN and LSTM networks.



شکل ۶- نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده در مدل برتر برای داده‌های صحت‌سنجی.
Figure 6. Distribution diagram between observational and predicted data in superior model for test data.

۱۰۰ پیش‌بینی کرده‌اند. فرمول روتنر نسبت به فرمول‌های دیگر نسبت پیش‌بینی کم‌تری داشته و همبستگی بیش‌تری را با مقادیر مشاهداتی ارائه داده است. نتایج حاصل از دو روش ANN و LSTM نشان‌دهنده کارایی این دو روش در پیش‌بینی بار بستر بوده است. در همه ۵ مدل مورد مطالعه، روش LSTM از دقت بالاتری نسبت به ANN برخوردار بوده است؛ و در مقایسه مدل‌های به‌کاررفته، مدل مربوط به فرمول بگنولد برترین مدل حاصل از این پژوهش هست. ولی دو مدل مربوط به فرمول‌های میپر-پیترو و مولر و روتنر نیز دارای دقت کافی در پیش‌بینی بار

نتیجه‌گیری کلی

در این پژوهش با استفاده از داده‌های ۱۹ رودخانه با بستر شنی سعی بر پیش‌بینی بار بستر شد. ۱۰ فرمول کلاسیک و دو روش شبکه عصبی مصنوعی (ANN) و یادگیری عمیق از نوع LSTM مورد آزمایش قرار گرفتند. برای تعریف مدل‌های ورودی شبکه‌ها از پارامترهای مربوط به فرمول‌های برتر حاصل از این پژوهش استفاده شده است. در همه فرمول‌های بار بستر، معیارهای ارزیابی مقادیر خیلی ضعیفی را به همراه داشته است. به طوری که اکثر فرمول‌ها، دبی بار بستر را با شاخص اختلاف بیش از

مشارکت نویسندگان

این مقاله برگرفته از پایان‌نامه کارشناسی‌ارشد نویسنده دوم می‌باشد. نویسنده اول در طرح تحقیق و روش‌شناسی، اصلاح، نهایی‌سازی مقاله، مشارکت در آنالیزها و در نظارت تحقیق مشارکت داشته است و مشارکت نویسنده دوم در آماده‌سازی داده‌ها، انجام محاسبات و تهیه پیش‌نویس مقاله می‌باشد.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر عملی رعایت نموده‌اند و این موضوع مورد تأیید همه آن‌ها می‌باشد.

حمایت مالی

این پژوهش از حمایت مستقیم مالی برخوردار نبوده است ولی از امکانات دانشگاه تبریز استفاده گردیده است.

بستر بوده‌اند. پارامتر مشترک ۳ مدل برتر این پژوهش، پارامتر قطر متوسط ذرات رسوب است که نشان‌دهنده نقش کلیدی این پارامتر در پیش‌بینی بار بستر است.

تقدیر و تشکر

نویسندگان از تمامی حمایت‌های دانشگاه تبریز در فراهم نمودن تمام امکانات لازم جهت انجام پایان‌نامه دانشجو و در نهایت استخراج مقاله مذکور کمال تشکر و قدردانی را دارند.

داده‌ها و اطلاعات

منبع داده‌های مورد استفاده در این پژوهش مربوط به پایان‌نامه کارشناسی‌ارشد عمران گرایش آب و سازه‌های هیدرولیکی نویسنده دوم فارغ‌التحصیل از دانشگاه تبریز می‌باشد.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسأله مورد تأیید همه نویسندگان است.

منابع

1. Batalla, R.J. 1997. Evaluating bed-material transport equations from field measurements in a sandy gravel-bed river. *Earth Surf. Process. Landf.* 21: 121-130.
2. Martin, Y., and Ham, D. 2005. Testing bed load transport formulae using morphologic transport estimates and field data: lower Fraser River, British Columbia. *Earth Surf. Process. Landf.* 30: 1265-1282.
3. Gomez, B., and Church, M. 1989. An assessment of bed load sediment transport formulae for gravel bed rivers. *Water Resour.* 25: 6. 1161-1186.
4. Haddadchi, A., Omid, M.H., and Dehghani, A.A. 2011. Assessment of bedload predictors based on sampling in a gravel bed river. *Journal of Hydrodynamic.* 24: 1. 145-151.
5. Sasal, M., Kashyap, S., Rennie, C.D., and Nistor, I. 2009. Artificial neural network for bedload estimation in alluvial rivers. *Journal of Hydraulic Research.* 47: 2. 223-232.
6. Yang, C.T., Marsooli, R., and Aalami, M.T. 2009. Evaluation of total load sediment transport formulas using ANN. *International Journal of Sediment Research.* 24: 3. 274-286.
7. Kitsikoudis, V., Sidiropoulos, E., and Hrissanthou, V. 2014. Machine learning utilization for bed load transport in gravel-bed rivers. *Water Resources Management.* 28: 11. 3727-3743.
8. Mosfaei, J., Salehpour Jam, A., and Tabatabai, M.R. 2017. Comparison of the efficiency of sediment rating curves model and artificial neural network in the study of river bed load. *Geography and environmental sustainability.* 24: 7. 33-44. (In Persian)

9. Zaytar, M.A., and El Amrani, C. 2016. Sequence to sequence weather forecasting with long short-term memory recurrent neural networks. *International Journal of Computer Applications*. 143: 11. 7-11.
10. Baroni, A., and Ziarati, K. 2019. Modeling of minimum temperature in Fars province using LSTM recurrent neural network model. 4th International Congress of Developing Agriculture, Natural Resources, Environment and Tourism of Iran, Tehran, Iran. (In Persian)
11. Kaveh, K., Kaveh, H., Duc Bui, M., and Rutschmann, P. 2021. Long short-term memory for predicting daily suspended sediment Concentration. *Engineering with Computers*. 37: 1. 2013-2027.
12. AlDahoul, N., Essam, Y., Kumar, P., Ahmed, A.N., Sherif, M., Sefelnasr, A., and Elshafie, A. 2021. Suspended sediment load prediction using long short-term memory neural network. *Scientific Reports*. 11: 7826.
13. King, J.G., Emmett, W.W., Whiting, P.J., Kenworthy, R.P., and Barry, J.J. 2004. Sediment transport Data and Related Information for Selected Coarse-Bed Streams and Rivers in Idaho, Gen. Tech. Rep. RMRS-GTR-131. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station, 26p.
14. Meyer-Peter, E., and Müller, R. 1948. Formulas for bed-load transport. In *Proceedings of the 2nd Meeting of the International Association for Hydraulic Structures Research*. pp. 39-64.
15. Schoklitsch, A. 1950. *Handbuch des wasserbaues*. Springer, New York, 478p.
16. Brown, C.B. 1950. Sediment transportation. *Engineering hydraulic*, edited by H. Rouse, John Wiley, New York. pp. 769-857.
17. Rottner, J. 1959. A formula for bed load transportation. *La Houille Blanche*. 3: 4. 301-307.
18. Bagnold, R.A. 1980. An empirical correlation of bed load transport rates in flumes and natural rivers. *Proc. Roy. Soc. Lond. Ser. A*. 372: 453-473.
19. Parker, G., Klingeman, P.C., and McLean, D.G. 1982. Bedload and the size distribution of paved gravel-bed streams. *Journal of the Hydraulics Division*. 108: 4. 544-571.
20. VanRijn, L.C. 1984a. Sediment transport, Part I: Bedload transport. *Journal of Hydraulic Engineering*. 110: 10. 1431-1456.
21. Wilcock, P.R., and Crowe, J.C. 2003. Surface-based transport model for mixed-size sediment. *Journal of Hydraulic Engineering*. 129: 2. 120-128.
22. Wong, M., and Parker, G. 2006. Reanalysis and correction of bed-load relation of Meyer- Peter and Müller using their own database. *Journal of Hydraulic Engineering*. 132: 11. 1159-1168.
23. Bhattacharya, B., Price, R.K., and Solomatine, D.P. 2007. Machine learning approach to modeling sediment transport. *Journal of Hydraulic Engineering*. 133: 4. 440-450.
24. Igor Aizenberg, Naum N., Aizenberg, Joos P.L., Vandewalle. 2000. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*. Springer Science and Business Media, New York, 276p.
25. Graves, A., and Schmidhuber, J. 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*. 12: 5-6.
26. Bengio, Y., Simard, P., and Frasconi, P. 1994. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*. 5: 2. 157-166.
27. Gers, F.A., Schmidhuber, J., and Cummins, F. 2000. Learning to forget: Continual prediction with LSTM. *Neural Computation*. 12: 10. 2451-2471.
28. Legates, D.R., and McCabe, G.J. 1999. Evaluating the Use of "Goodness-of-Fit" Measures in Hydrologic and Hydroclimatic Model Validation. *Water Resources Research*. 35: 233-241.
29. López, R., Vericat, D., and Batalla, R.J. 2013. Evaluation of bed load transport formulae in a large regulated gravel bed river: the lower Ebro (NE Iberian Peninsula). *Journal of Hydrology*. 510: 164-181.