



Kharazmi University



Proposing a Deep Learning Algorithm for Estimating the Brittleness Index Using Conventional Log Data in the Asmari Formation of a Southwestern Iranian Oil Field

Farhad Mollaei¹, Reza Mohebian²✉, Ali Moradzadeh³

1. PhD student of Petroleum Engineering, School of Mining, College of Engineering, University of Tehran, Tehran, Iran. E-mail: mollaeifarhad@ut.ac.ir

2. Assistant Professor, School of Mining, College of Engineering, University of Tehran, Tehran, Iran. E-mail: mohebian@ut.ac.ir

3. Professor, School of Mining, College of Engineering, University of Tehran, Tehran, Iran. E-mail: a_moradzadeh@ut.ac.ir

Article Info**Article type:**
Research Article**Article history:**

Received 10 August 2024

Received in revised form 3 November 2024

Accepted 5 November 2024

Keywords:

brittleness index, petrophysical data, deep learning, evaluation model.

ABSTRACT

The brittleness index is one of the most important parameters in geomechanical analysis and modeling. Many methods have been proposed to estimate the brittleness index. One of the recently used methods is the intelligent method. In this paper, firstly the aim is to introduce a new algorithm using deep learning algorithms to predict the brittleness index in one of the wells of the hydrocarbon field in southwest Iran. In this article, first, the effective features for the input of the algorithms were determined using Pearson's correlation coefficient, and then using (recurrent neural network + multi-layer perceptron neural network) (LSTM + MLP) and (convolutional neural network + recurrent neural network) (CNN+LSTM) brittleness index was estimated and the mean error value (MSE) and coefficient of determination (R^2) were calculated for the training and test data. For both training and test data, both algorithms have a coefficient of determination close to 1 and a very low error. Also, in order to ensure the results of the algorithms, a part of the data was set aside as blind data, and the error and coefficient of determination were calculated for this data, and the error was $MSE_{CNN+LSTM} = 26.0425$, $MSE_{LSTM+MLP} = 32.0751$ and the coefficient of determination was $R^2_{CNN+LSTM} = 0.8064$, $R^2_{LSTM+MLP} = 0.7615$. The results show the effectiveness of the introduced deep learning algorithms as a new method in predicting the brittleness index, and comparing the two algorithms presented, the CNN+LSTM algorithm has higher accuracy and less error.

Introduction

Brittleness is one of the most obvious properties of rock mechanics, that has a major impact on the process of rock failure and the general response of the rock to drilling and construction activities. In general, rocks with more brittle characteristics show lower plastic deformation values at the time of failure compared to softer rocks (Morley, 1954). In other words, in rock mechanics, brittleness refers to a type of fracture in which there is little or no permanent deformation, as opposed to soft failure, in which significant plastic deformation occurs prior to

failure (Ramsay, 1976). There are many definitions of the brittleness index, including (Morley, 1954; Havel, 1970; Hetenyi, 1966; Ramsay, 1976; Obert and Duvall, 1967; Hucka and Das, 1974; Altindag, 2003) pointed out. In general, brittleness is expressed as a function of rock strength (Altindag, 2010). However, so far there is no direct and standard method for measuring brittleness, but indirectly it can be used to determine the concept of brittleness by using some relationships about stone, such as different ratios of compressive and tensile strength of rock (Göktan, 1991; Lawn and

Cite this article: Mollaei, F., Mohebian, R., Moradzadeh, A. (2024). Proposing a Deep Learning Algorithm for Estimating the Brittleness Index Using Conventional Log Data in the Asmari Formation of a Southwestern Iranian Oil Field. Journal of Engineering Geology, 18 (3), 341-364. <https://doi.org/10.22034/JEG.2024.18.3.1019921>

© The Author(s).

DOI: <https://doi.org/10.22034/JEG.2024.18.3.1019921>

Publisher: Kharazmi University.

Marshall, 1979). The brittleness index is determined by three methods: 1- by elastic moduli. 2- from laboratory samples. 3- from the volume of minerals. Dynamic brittleness index is obtained from dynamic Young's modulus and dynamic Poisson's ratio. Equations 1, 2 and 3 respectively show dynamic Young's modulus (E_{dyn}), dynamic Poisson's ratio (v_{dyn}) and dynamic brittleness index (BI_{dyn}) respectively (Valim and Antia, 2021).

$$E_{dyn} = \rho V_s^2 \frac{3V_p^2 - 4V_s^2}{V_p^2 - V_s^2} \quad (1)$$

$$v_{dyn} = \frac{V_p^2 - 2V_s^2}{2(V_p^2 - V_s^2)} \quad (2)$$

$$BI_{dyn} = E_{dyn} + \frac{v_{dyn}}{2} \quad (3)$$

Due to the fact that the brittleness index is one of the important geomechanical parameters that have important applications in hydraulic fracturing and well stability and etc., so its accurate determination becomes very important. In this article, two deep learning algorithms including CNN+LSTM and CNN+MLP are used to predict the dynamic brittleness index. The

purpose of this study is to present an algorithm for predicting the dynamic brittleness index and compare these results with each other, which results show the application of deep learning to predict the brittleness index.

Materials and Methods

In this article, the data of RHOB, CHAL, NEUT, LL7, PEF, Vp, Vs, MLL, GR logs were available to determine the brittleness index using deep learning algorithms.

In order to select the effective features and suitable inputs to the algorithms, the correlation coefficient of the features with the brittleness index should be checked. One of the methods to select the feature is to calculate the Pearson's correlation coefficient. According to Pearson's correlation, Vp, RHOB, NEUT logs were selected as the input of the algorithms, and adding other logs increases the error and decreases the accuracy. Figure 1 shows the selection of features using the Pearson correlation matrix.

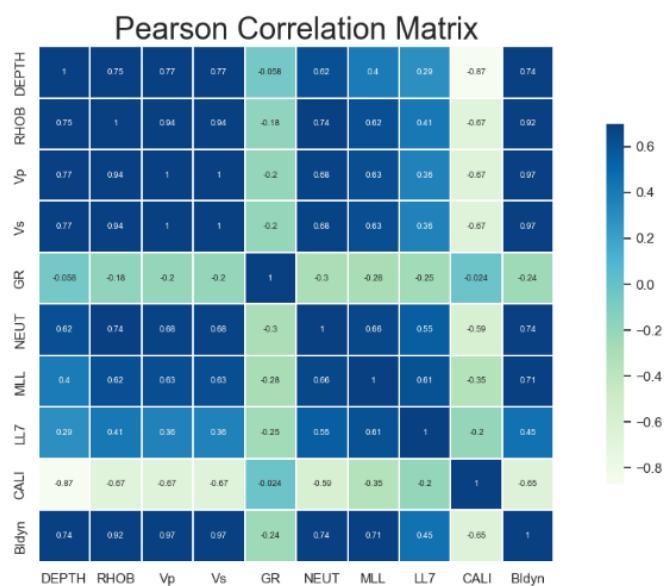


Fig. 1. selection features using Pearson correlation matrix.

In the following, the total data was 8591 data and from the beginning 1634 data were left as blind data to ensure the results of the algorithm and the other data were divided into two parts, training and testing, and 80% of the data (5565 data) were used for training. And 20% of the data (1392

data) were used for testing. In the next step, data normalization was performed to achieve higher accuracy. For normalization, the Min-Max Normalization function is used, which adjusts the available data between zero and one. The Adam optimizer function is then used for

optimization.. To evaluate the model and compare the results of deep learning algorithms, RMSE error, MSE error, and R2 have been used, and their relationships are according to equations 4, 5, and 6.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{predict}})^2 \quad (6)$$

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{predict}})^2}{\sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{average}})^2} = 1 - \frac{\text{MSE}}{\sigma^2} \quad (8)$$

Results and Discussion

Table 1. BI_{dyn} Prediction errors and accuracy for train data records using deep learning algorithm.

Deep Learning models	MSE	RMSE	R ²
LSTM+MLP	0.0048	0.0693	0.9999
CNN+LSTM	0.0191	0.1384	0.9998

Table 2. BI_{dyn} Prediction errors and accuracy for test data records using deep learning algorithm.

Deep Learning models	MSE	RMSE	R ²
LSTM+MLP	0.2201	0.4692	0.9971
CNN+LSTM	0.1802	0.4253	0.9976

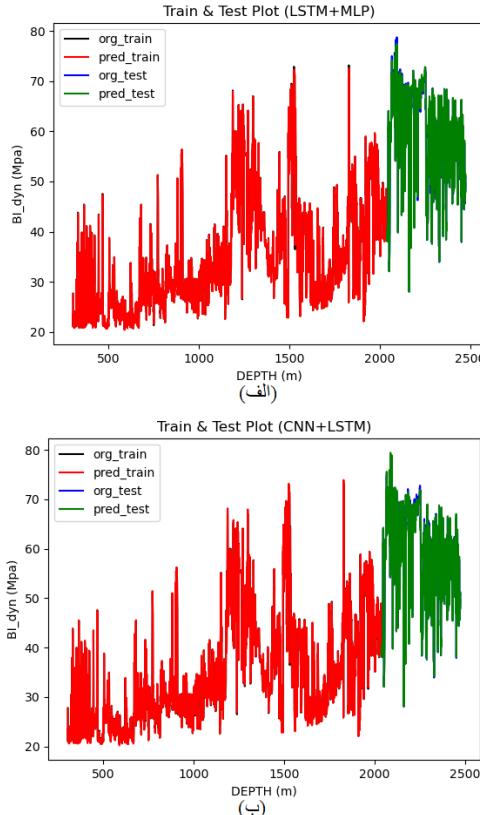


Fig. 2. Display of BI_{dyn} predict using deep learning algorithms for train and test data. (a), BI_{dyn} prediction using LSTM+MLP algorithm. (b), BI_{dyn} prediction using CNN+LSTM. Black log (BI_{dyn} measured for training (original data)), red log (BI_{dyn} predicted for training data), blue log (BI_{dyn} measured for test data (original data)), green log (BI_{dyn} predicted for test data).

In this article, the results of two deep learning algorithms including LSTM+MLP and CNN+LSTM were examined and RMSE error, MSE error and R2 were calculated for training, test and blind data. Tables 1, display BI_{dyn} prediction errors and accuracies based on the training (80%) subsets and Tables 2, display the BI_{dyn} prediction errors and accuracies based on the test (20%) subset, respectively. Figure 2, shows the comparison of BI_{dyn} predicted and BI_{dyn} measured for training and test data.

Tables 3, display the BI_{dyn} prediction errors and accuracies based on the blind subsets, respectively.

Table 3. BI_{dyn} prediction errors and accuracy for blind data records using deep learning algorithm.

Deep Learning models	MSE	RMSE	R^2
LSTM+MLP	32.0751	5.6635	0.7615
CNN+LSTM	26.0425	5.1031	0.8064

Figure 3, shows the comparison of BI_{dyn} predicted and BI_{dyn} measured for blind data.

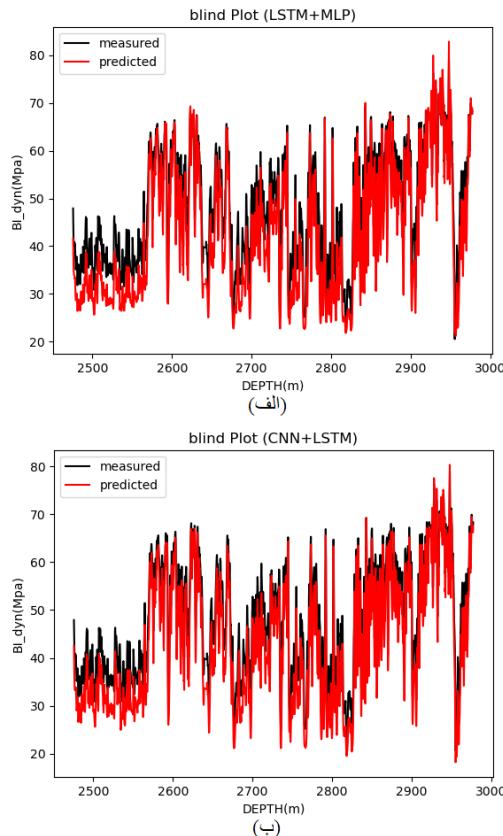


Fig. 3. Display of BI_{dyn} predict using deep learning algorithms for blind data.

Conclusions

Considering the importance of the brittleness index in determining hydraulic fractures and geomechanical models, it is necessary to use a cheap and accurate method to predict the brittleness index. For this purpose, in this study, deep learning and LSTM+MLP and CNN+LSTM algorithms were used to estimate the brittleness index. In order to apply the algorithm on the data, it is necessary to first determine the effective and influential features on the brittleness index. V_p , RHO_B , NEUT were determined as the input to the algorithms. Then, the presented models were applied and RMSE, MSE and R^2 were calculated to evaluate the

results of the models. The comparison of the results obtained from these two algorithms shows that both algorithms have obtained good results for training and test data, and for blind data, the CNN+LSTM algorithm has the LSTM+MLP algorithm has a better performance for predicting the brittleness index, because a lower error and a higher coefficient of determination have been obtained than the LSTM+MLP algorithm. Therefore, it can be said that deep learning algorithms can be used as an efficient, simple and cost-effective method to estimate the brittleness index using conventional logs.



ارائه یک الگوریتمی مبتنی بر یادگیری عمیق برای تخمین شاخص شکنندگی با استفاده از داده‌های لاغهای متداول در سازند آسماری یکی از میادین نفتی جنوب غرب ایران

فرهاد ملائی^۱, رضا محبیان^{۲*}, علی مرادزاده^۳

۱. دانشجوی دکترای مهندسی معدن، دانشکده مهندسی معدن، دانشگاه تهران، تهران، ایران. رایانه: mollaeifarhad@ut.ac.ir
۲. استادیار گروه مهندسی معدن، دانشکده مهندسی معدن، دانشگاه تهران، تهران، ایران. رایانه: mohebian@ut.ac.ir
۳. استاد گروه مهندسی معدن، دانشکده مهندسی معدن، دانشگاه تهران، تهران، ایران. رایانه: a_moradzadeh@ut.ac.ir

اطلاعات مقاله چکیده

شاخص شکنندگی یکی از پارامترهای مهم در بررسی و مدل‌سازی‌های ژئومکانیکی است. روش‌های زیادی برای تخمین شاخص شکنندگی ارائه شده است. یکی از روش‌هایی که امروزه زیاد مورد استفاده قرار می‌گیرد روش‌های هوشمند است. در این مطالعه هدف ارائه الگوریتمی جدید با استفاده از الگوریتم‌های یادگیری عمیق جهت پیش‌بینی شاخص شکنندگی در یکی از چاههای میدان هیدروکربنی در جنوب غرب ایران می‌باشد. در این مقاله ابتدا پارامترهای مؤثر برای ورودی الگوریتم‌ها با استفاده از ضریب همبستگی پیرسون مشخص گردید و در ادامه با استفاده از شبکه عصبی بازگشتی + شبکه عصبی پرسپترون چندلایه (LSTM+MLP) و (شبکه عصبی تبدیلی + شبکه عصبی بازگشتی) (CNN+LSTM) شاخص شکنندگی تخمین زده شد و مقدار خطای (MSE) و ضریب تعیین (R^2) برای داده‌های آموزش و تست محاسبه گردید که برای داده‌های آموزش و تست هر دو الگوریتم دارای ضریب تعیین نزدیک به ۱ و خطای بسیار کم به دست آمده است. همچنین جهت اطمینان از نتایج الگوریتم‌ها بخشی از داده به عنوان روشی جدید در پیش‌بینی شاخص شکنندگی می‌باشد که در نیز محاسبه گردید که خطای $MSE_{CNN+LSTM} = 26.0425$, $MSE_{LSTM+MLP} = 32.0751$ و ضریب تعیین $R^2_{CNN+LSTM} = 0.8064$, $R^2_{LSTM+MLP} = 0.7615$ به دست آمده است. نتایج بیانگر کارآیی الگوریتم‌های یادگیری عمیق معرفی شده به عنوان روشی جدید در پیش‌بینی شاخص شکنندگی می‌باشد که در مقایسه دو الگوریتم ارائه شده، الگوریتم CNN+LSTM دارای دقت بالاتر و خطای کمتری می‌باشد.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۵/۲۰

تاریخ بازنگری: ۱۴۰۳/۰۸/۱۳

تاریخ پذیرش: ۱۴۰۳/۰۸/۱۵

کلیدواژه‌ها:

شاخص شکنندگی، داده‌های پتروفیزیکی، یادگیری عمیق، ارزیابی مدل.

شکست نرم (Ductile) که در آن قبل از شکست، تغییرات شکل پلاستیک قابل توجهی رخ می‌دهد (Ramsay, 1967). از دیگر تعاریف شکنندگی سنگ که به صورت عمده مورد توجه محققان زیادی قرار گرفته است، می‌توان به از بین رفتن انسجام سنگ در تنش‌های بالاتر از میزان حد تسلیم سنگ اشاره کرد. تعاریف زیادی برای شاخص شکنندگی سنگ اشاره کرد. تعریف زیادی برای شاخص شکنندگی (Brittleness index) ارائه شده است که از جمله می‌توان به مورلی (Morley, 1954)، هاول (Havel, 1970)، هتلنی (Hetenyi, 1966)، رمزی (Ramsay, 1967)، اوبرت و

مقدمه

شکنندگی یکی از بارزترین خصوصیات مکانیک سنگ است که تأثیر فراوانی در فرآیند شکست سنگ و پاسخ عمومی سنگ به فعالیت‌های حفاری و عمرانی دارد. شکنندگی نه تنها به عنوان یک خصوصیت، بلکه به عنوان یک ترکیب از ویژگی‌های سنگ مطرح می‌شود که تأثیر زیادی در کنترل فرآیند شکست سنگ دارد. در مکانیک سنگ، شکنندگی به نوعی از شکستگی اطلاق می‌شود که در طی آن تغییر شکل دائمی وجود نداشته باشد یا میزان آن بسیار کم باشد، به رغم

استناد: ملائی، ف، مرادزاده، ع، محبیان، ر. (۱۴۰۳). ارائه یک الگوریتمی مبتنی بر یادگیری عمیق برای تخمین شاخص شکنندگی با استفاده از داده‌های لاغهای متداول در سازند آسماری یکی از میادین نفتی جنوب غرب ایران. مجله زمین شناسی مهندسی، ۱۸ (۳)، ۳۴۱-۳۶۴.

<https://doi.org/10.22034/JEG.2024.18.3.1019921>



$$BI_{dyn} = E_{dyn} + \frac{v_{dyn}}{2} \quad (3)$$

شاخص شکنندگی استاتیک (BI_{st}) را می‌توان از مقاومت فشاری تک محوره (σ_c) و مقاومت کششی (σ_t) به دست آمده در آزمایشگاه تعیین کرد. رابطه^۴, یکی از روابطی است که جهت تعیین شاخص شکنندگی استاتیک مطرح شده است: (Altindag, 2010)

$$BI_{st} = \sqrt{\frac{\sigma_c \times \sigma_t}{2}} \quad (4)$$

همچنین روابطی جهت تعیین شاخص شکنندگی با استفاده از حجم کانی‌ها ارائه شده است که هر کدام از آن‌ها مربوط به یک میدان خاص می‌باشد. رابطه^۵, شاخص شکنندگی بر حسب کانی (BI_{lit}) را بر حسب حجم کوارتز (Sand volume, V_{cl}) و (Clay volume, V_{sand})، حجم رس (volume, V_{ker}) بیان کرده است (Valim and Antia, 2021).

$$BI_{lit} = \frac{V_{sand}}{V_{sand} + V_{cl} + V_{ker}} \quad (5)$$

امروزه روش‌های هوشمند کاربرد ویژه‌ای در تخمین پارامترهای پتروفیزیکی، ژئوفیزیکی و ژئومکانیکی پیدا کرده است که به چند پژوهش جدید اشاره شده است (Afolagboye et al., 2023, Xu et al., 2023, Ibrahim et al., 2023, Kochukrishnan et al., 2024, Daniel et al., 2024, Zhao et al., 2024, Niu et al., 2024, Kalabarige et al., 2024, Ezazi et al., 2024, Mousavi et al., 2024). در ادامه پژوهش‌هایی که جهت پیش‌بینی شاخص شکنندگی انجام شده است اشاره شده است. ریکمن و همکاران (Rickman et al., 2008) یک معادله شکنندگی متوسط را بر اساس پارامترهای الاستیک Perez, (2013) نسبت پواسون و مدول یانگ پیشنهاد کردند. پر ز (2013) شاخص شکنندگی (BI) برآورد شده از حجم کانی‌ها و شاخص شکنندگی برآورد شده از پارامترهای الاستیک را مقایسه کرد. دا سیلو (Dasilva, 2013) دریافت که BI

دوال (Obert and Duvall, 1967)، هوکا و داس (Hucka, 1974 and Altindag, 2003) اشاره کرد. به طور کلی خاصیت شکنندگی تأثیر قابل توجهی بر روی فرایند شکست سنگ‌ها دارد و در مواردی مانند شکست هیدرولیکی و فرآیندهای حفاری اهمیت بسزایی دارد. شاخص شکنندگی و مقاومت فشاری سنگ از پارامترهای مؤثر در عملکرد دستگاه‌های حفاری می‌باشند. سنگ‌ها عمدها در اثر فشار و کشش رفتار شکنندگی سنگ جهت استفاده در پروژه‌های مکانیکی سنگ اهمیت بسزایی دارد (Yagiz, 2009). به صورت کلی شکنندگی را تابعی از مقاومت سنگ بیان می‌کنند (Altindag, 2010). با این حال و با تحقیقات و مطالعاتی که در رابطه با شاخص شکنندگی انجام شده، تاکنون روش مستقیم و استانداردی برای اندازه‌گیری شکنندگی موجود نیست ولی به طور غیرمستقیم می‌توان با استفاده از بعضی روابط در خصوص سنگ مانند نسبت‌های مختلف مقاومت فشاری و کششی سنگ برای تعیین مفهوم شکنندگی استفاده کرد (Göktan, 1991; Lawn and Marshall, 1979).

شاخص شکنندگی از طریق سه روش تعیین می‌شود: ۱- از طریق مدول‌های الاستیک (Elastic modulus). ۲- با استفاده از نمونه‌های آزمایشگاهی. ۳- با استفاده از حجم کانی‌ها (Minerals). شاخص شکنندگی دینامیک از مدول یانگ دینامیک و نسبت پواسون دینامیکی به دست می‌آید. رابطه‌های ۱، ۲ و ۳ به ترتیب مدول یانگ دینامیک (E_{dyn})، نسبت پواسون دینامیک (v_{dyn}) و شاخص شکنندگی دینامیک Valim and Antia, (2021) را نشان می‌دهد (

$$E_{dyn} = \rho V_s^2 \frac{3V_p^2 - 4V_s^2}{V_p^2 - V_s^2} \quad (1)$$

$$v_{dyn} = \frac{V_p^2 - 2V_s^2}{2(V_p^2 - V_s^2)} \quad (2)$$

شاخص‌های شکنندگی با مدل چفرمگی (Toughness) ارائه کردند. اور و جائو (Ore and Gao, 2021) با استفاده از شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان، شاخص شکنندگی را پیش‌بینی کرد. ژانگ و همکاران (Zhang et al., 2022) با استفاده از انرژی کرنش الاستیک شاخص شکنندگی سنگ را پیش‌بینی کردند. در تحقیق قبادی و همکاران (Ghobadi et al., 2023) رابطه بین شکنندگی سنگ با استفاده از نسبت شاخص نقطه‌ای به تخلخل (PMP) در ماسه سنگ‌های سازند قم بررسی شده است. همچنین در این مقاله، روش‌های برآورد موجود برای شاخص شکنندگی سنگ مورد مقایسه و ارزیابی قرار گرفته است. وانگ و همکاران (Wang et al., 2023) یک روش حفاری دیجیتال برای ارزیابی ناهمسانگردی مکانیکی سنگ پیشنهاد داده است. اصطکاک بحرانی، راندمان برش و تنش تماسی از مدل حفاری برای مشخص کردن فرآیند حفاری تعیین شد. در ادامه نویسندها شاخص شکنندگی را بر حسب منحنی‌های تنش - کرنش و تغییرات و افت این پارامترها و مدل حفاری دیجیتال با در نظر گرفتن اثر اصطکاک و سیال تخمین زدند. ژانگ و همکاران (Zhang et al., 2024) از معادله ضریب بازتاب برای وارون‌سازی مستقیم شاخص شکنندگی استفاده کردند. این مقاله با توجه به اینکه روش وارون‌سازی حوزه فرکانس (FDI) دارای وضوح عالی و روش وارون‌سازی حوزه زمانی (TDI) از مصنوبیت نویز خوبی برخوردار است، یک روش وارون‌سازی دامنه مختلط زمان‌فرکانس (TFDI) را معرفی می‌کند. عاصمی و همکاران (Asemi et al., 2024) شاخص جدیدی را برای توصیف شکنندگی سنگ با استفاده از آستانه تنش شروع ترک معرفی کردند. همچنین آزمون‌های مقاومت فشاری تک محوری (UCS) بر روی نمونه‌های سنگ دولومیت دانه‌ریز، متوسط و درشت دانه به منظور ارزیابی عملکرد این شاخص در توصیف شکنندگی انجام شد.

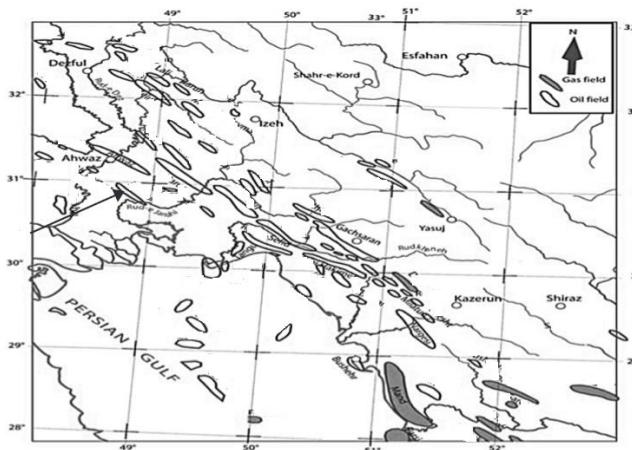
محاسبه شده از حجم کانی‌ها با $\mu\rho$ (Mu-rho) همبستگی مثبت و با $\lambda\rho$ (Lambda-rho) همبستگی منفی دارد. کاراکول و اولوسای (Karakul and Ulusay, 2013) نشان دادند که افزایش درجه اشباع، ویژگی‌های مقاومتی و تغییر شکل‌پذیری سنگ‌ها کاهش می‌یابند. در حالی که سرعت موج فشاری روند متغیری را نشان می‌دهد. جین و همکاران (Jin et al., 2014) تخمین شکنندگی را از ملاحظات ژئومکانیکی و پتروفیزیک بررسی می‌کند. ژانگ و همکاران (Zhang et al., 2016) شاخص شکنندگی را با استفاده از پتروفیزیک و تجزیه و تحلیل داده‌های لرزه‌ای پیش‌بینی کرد. شی و همکاران (Shi et al., 2016) شاخص شکنندگی را با استفاده از یادگیری ماشینی شبکه عصبی مصنوعی تخمین زدند. قبادی و ناصری (Ghobadi and Naseri, 2016) شاخص شکنندگی را با عنوان تخمین شاخص شکنندگی سنگ‌های مدل‌های رگرسیون چندگانه پیش‌بینی کردند. محمدی و توسلی (Mohammadi and Tavassoli, 2015) در مطالعه‌ای با عنوان تخمین شاخص شکنندگی سنگ‌های آهکی سازند قم با استفاده از خصوصیات فیزیکی نشان دادند که ویژگی‌های فیزیکی با پارامترهای شکنندگی سنگ‌های منطقه مورد مطالعه رابطه منطقی و قابل قبولی دارند. کایوندا و آسیوری (Kaunda and Asbury, 2016) با استفاده از روش‌های غیر مخرب برای تونل زدن در سنگ‌های سخت شکنندگی سنگ را پیش‌بینی کردند. در این مقاله با استفاده از سرعت موج تراکمی و برشی و با استفاده از شبکه عصبی مصنوعی، شاخص شکنندگی تخمین زده شد. لشکری پور و همکاران (Lashkaripour et al., 2018) در پژوهشی تحت عنوان بررسی ضریب شکست و همبستگی تجربی بین پارامترهای فیزیکی و مکانیکی سنگ آهک آسماری انجام دادند. در این مقاله روابط تجربی برای تخمین شاخص‌های شکنندگی سنگ آهک آسماری برقرار شده است. کراری و همکاران (Karrari et al., 2019) روابط آماری بین

کشف شد و از نظر جغرافیایی طول این میدان در حدود ۳۹ کیلومتر و عرض آن ۵ کیلومتر می‌باشد و از میدان‌های تحت مدیریت شرکت ملی مناطق نفت خیز جنوب است، که عملیات تولید از آن توسط شرکت بهره‌برداری نفت و گاز کارون انجام می‌گیرد. این میدان از نظر جغرافیایی در فاصله ۵۰ کیلومتری از جنوب شهر اهواز در استان خوزستان واقع شده و شامل دو مخزن نفتی آسماری و بنگستان است. مخزن آسماری این میدان دارای ابعاد ۳۰ کیلومتر طول و ۳ کیلومتر عرض می‌باشد (Motiei, 2009). از نظر زمین‌شناسی سازند مذکور به ۸ لایه تقسیم‌بندی شده است که با توجه به سطح تماس آب و نفت، فقط لایه‌های ۱، ۲ و ۳ در ناحیه نفتی مخزن قرار گرفته‌اند. مخزن بنگستان از دو سازند ایلام و سروک تشکیل شده است. سازند ایلام از ۳ لایه تشکیل شده که لایه ۳ تولیدی آن می‌باشد. سازند سروک دارای ۲ لایه تولیدی ۴ و ۶ بوده و لایه ۵ در تولید مشارکتی ندارد. تاکنون تعداد ۳۵۳ حلقه چاه در مخزن آسماری این میدان، حفاری و ۲۰۰ حلقه چاه فعال در این مخزن دارد و از مخزن بنگستان آن تاکنون ۱۷ حلقه چاه حفاری شده است. در این مقاله از یکی از چاه‌های مخزن آسماری جهت تخمین شاخص شکنندگی استفاده شده است. داده‌های موجود در این چاه ۸۵۹۱ داده است که در محدوده عمق ۳۰۵/۲۶ تا ۲۹۷۷/۲۹ متر قرار دارند و لاغ‌های قطرسنگی (GR)، سرعت موج فشاری (Vp)، گامای طبیعی (CALI)، چگالی (RHOB)، نوترون (NEUT)، میکرولاترولوگ (MLL)، لاترولوگ ۷ (LL7)، سرعت موج برشی (Vs) موجود هستند. شکل ۱، موقعیت میدان هیدروکربنی مذکور و میدان‌های مجاور و شکل ۲، لاغ‌های موجود در محدوده عمقی را نشان داده است (Gholipour and Haghi, 1990).

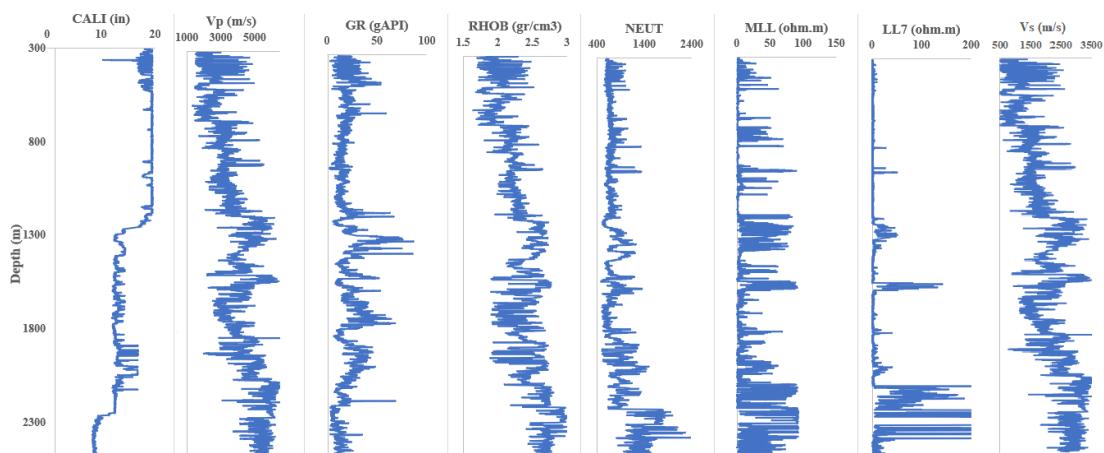
با توجه به این که شاخص شکنندگی یکی از پارامتری مهم ژئومکانیکی می‌باشد که تخمین مناسب و دقیق آن دید مناسبی برای تصمیم‌گیری‌های بعدی مانند بررسی شکاف هیدرولیکی به ما می‌دهد، لذا تعیین دقیق آن اهمیت بسزایی پیدا می‌کند. امروزه روش‌های متفاوتی برای تخمین دقیق تر شاخص شکنندگی به کار گرفته شده است که یکی از روش‌هایی که امروزه جایگاه ویژه‌ای در تخمین پارامترهای ژئومکانیکی پیدا کرده است روش‌های هوشمند است. با بررسی پژوهش‌های قبلی انجام شده، ارائه روشی که بتواند تخمین مناسب و دقیقی از شاخص شکنندگی ارائه دهد احساس می‌شود. هدف از این مطالعه ارائه الگوریتمی جهت پیش‌بینی شاخص شکنندگی می‌باشد. در این مقاله سعی شده است با استفاده از تلفیقی از الگوریتم‌های یادگیری عمیق گامی جهت تخمین شاخص شکنندگی برداشته شود. در این پژوهش ابتدا ویژگی‌های مؤثر جهت انتخاب ورودی الگوریتم‌ها با استفاده از ضریب همبستگی پیرسون تعیین و در ادامه از دو الگوریتم یادگیری عمیق شامل CNN+MLP و LSTM+MLP جهت پیش‌بینی شاخص شکنندگی دینامیک در یکی از میدانین هیدروکربنی در جنوب غرب ایران استفاده است، که نتایج بیان کننده کاربرد یادگیری عمیق برای پیش‌بینی شاخص شکنندگی می‌باشد.

زمین‌شناسی منطقه

حوضه زاگرس، در محدوده جنوب غرب ایران و شمال عراق قرار دارد که دارای میدانین هیدروکربنی بسیاری می‌باشد. این حوضه از همگرایی ممتد و طولانی مدت بین صفحه عربستان و اوراسیا در طی بسته شدن حوضه اقیانوسی نئوتیس به وجود آمده است. میدان مورد مطالعه از میدان‌های نفتی ایران است که توسط شرکت ملی نفت ایران



شکل ۱. موقعیت میدان هیدروکربنی موردنظر (Gholipour and Haghi, 1990)
Fig. 1. Hydrocarbon field location (Gholipour and Haghi, 1990)



شکل ۲. نمایش داده لگ‌های موجود در چاه موردنظر از چپ به راست: قطرسنجی (CALI)، سرعت موج فشاری (Vp)، گامای طبیعی (GR)، چگالی (RHOB)، نوترون (NEUT)، میکرولاترولگ (MLL)، لاترولگ ۷ (LL7)، سرعت موج برنشی (Vs).

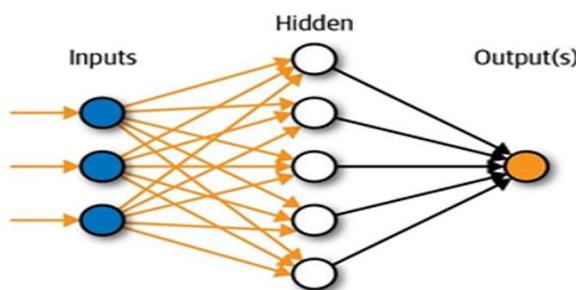
Fig. 2. The logs in the well. From left to right: column 1: CALIPER, column 2: Vp, column 3: GR, column 4: RHOB, column 5: NEUT, column 6: MLL, column 7: LL7, column 8: Vs.

حاصل خواهد شد. در چنین شبکه‌ای چند لایه از نورون‌ها را خواهیم داشت. شکل ۳، یک نمونه از یک شبکه عصبی پرسپترون چند لایه است: لایه اول با عنوان لایه‌ی ورودی (Input) شناخته می‌شود. داده‌ها با انجام یک سری عملیات ریاضی از لایه اول به لایه‌های میانی منتقل می‌شوند و در نهایت می‌توان خروجی (Output) را در لایه نهایی دید (Alavi et al., 2010). شکل ۳، شماتیک شبکه MLP را نمایش می‌دهد.

مواد و روش‌ها

در این پژوهش از دو الگوریتم LSTM+MLP و CNN+LSTM جهت تخمین شاخص شکنندگی دینامیک استفاده شده است به همین جهت ابتدا به معرفی مختصی از الگوریتم‌های مورد استفاده پرداخته شده است.

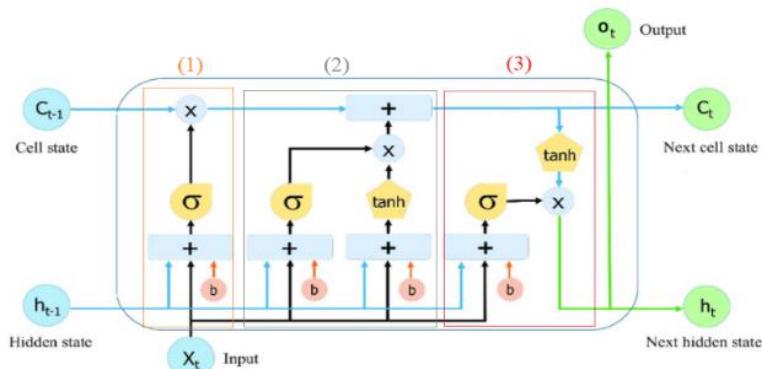
شبکه عصبی پرسپترون چندلایه: یک شبکه عصبی پرسپترون چندلایه از پشت هم قرار دادن چند پرسپترون



شکل ۳. شماتیک شبکه (Alavi et al., 2010) MLP
Fig. 3. Schematic diagram of MLP (Alavi et al., 2010)

تقسیم نمود. با توجه به شکل ۴، به بخش (۱)، درگاه فراموشی (Forget gate) گفته می‌شود. بخش (۲): این بخش تصمیم می‌گیرد که چه اطلاعات جدیدی باید به وضعیت سلول (c) برای استفاده‌های بعدی اضافه شود. در بخش (۳) در شکل ۴، درگاه خروجی وجود دارد که خروجی‌ها را مشخص می‌کند. (Hochreiter and Schmidhuber, 1997).

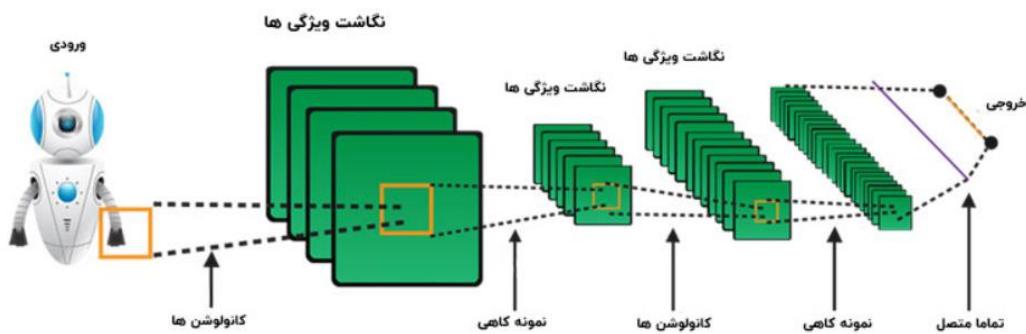
شبکه‌های عصبی بازگشتی با حافظه‌ی بلند کوتاه مدت LSTM (Long short-term memory) می‌شوند که تغییری در بلوک شبکه‌های عصبی بازگشتی هستند که تغییری در بلوک آن‌ها ایجاد شده است. این تغییر باعث می‌شود که شبکه‌های LSTM بتوانند مدیریت حافظه‌ی بلند مدت را داشته باشند و مشکل محوشدن را نیز نداشته باشند. یک بلوک LSTM را می‌توان به سه بخش اصلی



شکل ۴. ساختار یک بلاک LSTM (Hochreiter and Schmidhuber, 1997)
Fig. 4. The structure of an LSTM block (Hochreiter and Schmidhuber, 1997)

محاسبات نسبت به سایز تصویر است. بعد از مرحله پولینگ، ویژگی‌های دو بعدی ایجاد شده در مرحله اتصال کامل به یک بردار تک بعدی تبدیل می‌شود. این لایه همانند شبکه عصبی MLP امکان اجرای آموزش پیش‌رو را برای فراهم می‌کند (Greff et al., 2017). شکل ۵، شماتیکی از مراحل یک شبکه عصبی کانولوشنی را نشان می‌دهد.

شبکه عصبی تبدیلی: یک شبکه CNN از سه لایه کانولوشن (Convolution)، پولینگ (Pooling) و اتصال کامل (Fully connected) تشکیل شده است. لایه کانولوشن از کانولوشن تصویر ورودی به کمک ناحیه‌های دریافت محلی به وجود می‌آید. در لایه پولینگ، کاهش سایز تصویر انجام می‌شود. علت اصلی اعمال این اپراتور، کاهش حجم



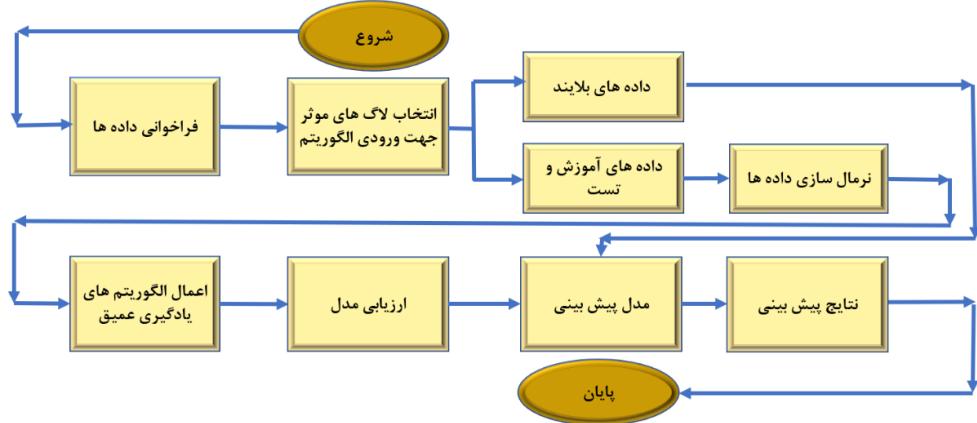
شکل ۵. پردازش تصویر توسط روش CNN (Geo et al., 2015)

Fig. 5. Image processing by CNN method (Geo et al., 2015)

شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق در دسترس بودند. فلوچارت پیش‌بینی شاخص شکنندگی با استفاده از روش یادگیری عمیق در شکل ۶، نمایش داده شده است.

پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم یادگیری عمیق

در این مقاله داده‌های لگ‌های RHOB, CALI, NEUT, LL7, PEF, Vp, Vs, MLL, GR برای تعیین شاخص



شکل ۶. فلوچارت پیش‌بینی شاخص شکنندگی با استفاده از یادگیری عمیق

Fig. 6. Workflow schematic for BI prediction using Deep Learning algorithms

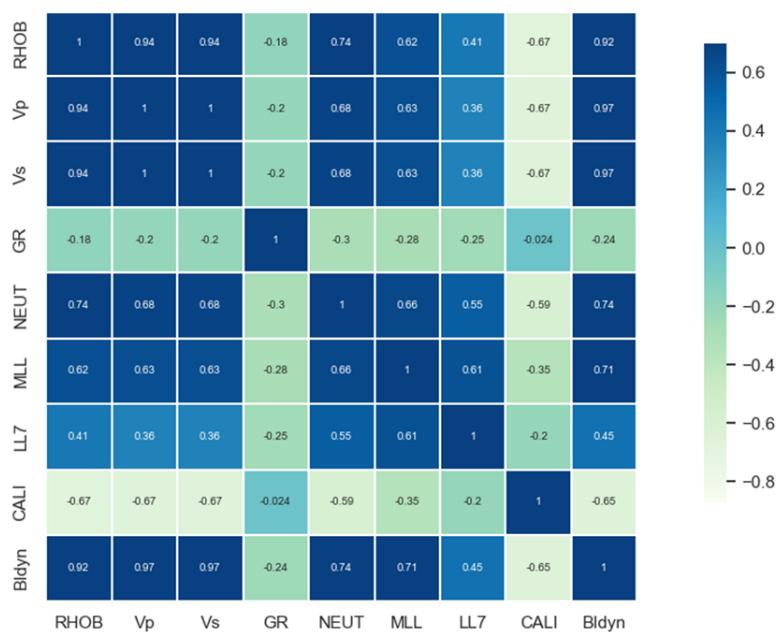
میزان همبستگی خطی بین دو متغیر تصادفی را می‌سنجد. مقدار این ضریب بین ۱-تا ۱ تغییر می‌کند که «۱» به معنای همبستگی مثبت کامل، «۰» به معنای نبود همبستگی، و «-۱» به معنای همبستگی منفی کامل است. ضریب همبستگی پیرسون بین دو متغیر تصادفی برابر با کوواریانس آن‌ها تقسیم بر انحراف معیار آن‌ها تعریف می‌شود. در این مطالعه لگ‌های RHOB, CALI, NEUT, LL7, PEF, Vp, Vs, MLL, GR

برای انتخاب ویژگی‌های مؤثر و ورودی‌های مناسب به الگوریتم‌ها باید ضریب همبستگی ویژگی‌ها را با شاخص شکنندگی بررسی کرد. یکی از روش‌های انتخاب ویژگی محاسبه ضریب همبستگی پیرسون است. این شاخص توسط کارل پیرسون (Karl Pearson) آماردان انگلیسی در سال ۱۹۰۰ طی مقاله‌ای معرفی شد. او از این شاخص برای بررسی علمی روی علوم زیستی و حتی جمعیتی استفاده کرد و به نتایج جالب توجهی رسید. ضریب همبستگی پیرسون

مؤثر از طریق ماتریس همبستگی پیرسون را نشان می‌دهد. با توجه به شکل ۷ و جدول ۱ بیشترین ضریب همبستگی V_p , RHOB, NEUT بین شاخص شکنندگی و لاغ‌های وجود دارد که این لاغ‌ها به عنوان ورودی الگوریتم‌ها انتخاب شدند و اضافه کردن لاغ‌های دیگر باعث افزایش خطا و کاهش دقت می‌شود.

وجود دارند جهت انتخاب پارامترهای مؤثر ورودی جهت تخمین شاخص شکنندگی دینامیک مورد بررسی قرار گرفته‌اند و با توجه به اینکه لاغ سرعت موج برشی در چاه‌های کمی برداشت می‌شود از داده‌های این لاغ به عنوان پارامتر ورودی جهت انتخاب ویژگی مؤثر و تخمین شاخص شکنندگی استفاده نشده است. شکل ۷، انتخاب ویژگی‌های شکنندگی استفاده نشده است. شکل ۷، انتخاب ویژگی‌های

Pearson Correlation Matrix



شکل ۷. انتخاب ویژگی‌ها از طریق ماتریس همبستگی پیرسون

Fig. 7. Selection of features using the Pearson correlation matrix

جدول ۱. ضریب همبستگی شاخص شکنندگی با لاغ‌ها

Table 1. Correlation coefficient of fragility index with logs

Log	Vp	RHOB	NEUT	MLL	CALI	LL7	GR
BIdyn	0.97	0.92	0.74	0.71	-0.65	0.45	-0.24

نرمال‌سازی داده‌ها برای دستیابی به دقت بالاتر انجام شده است. برای نرمال‌سازی از تابع Min-Max Normalization استفاده شده که داده‌های موجود بین صفر و یک تنظیم می‌گردند. در ادامه برای بهینه‌سازی از تابع بهینه‌ساز Adam استفاده شده است. برای ارزیابی مدل و مقایسه نتایج

در ادامه کل داده‌ها ۸۵۹۱ داده بودند و از ابتدا ۱۶۳۴ داده به عنوان داده کور جهت اطمینان از نتایج الگوریتم کنار گذاشته شد و بقیه داده که به دو قسمت آموزش و تست تقسیم شدند که٪۸۰ داده‌ها (۵۵۶۵ داده) به آموزش و٪۲۰ داده‌ها (۱۳۹۲ داده) به تست تقسیم شدند. در مرحله بعد

نسبت پواسون که از سرعت موج برشی حاصل از لاغ DSI به دست آمده، استفاده شده است. با توجه به اینکه در اکثر چاهها سرعت موج برشی در دسترنس نمی‌باشد سعی شده است بدون استفاده از لاغ سرعت موج برشی و با استفاده از لاغ‌های معمولی این پارامتر تخمین زده شود. جهت اعتبارسنجی نتایج خروجی الگوریتم‌ها شاخص شکنندگی واقعی که با استفاده از مدول یانگ و نسبت پواسون حاصل از سرعت موج برشی واقعی لاغ DSI به دست آمده است با شاخص شکنندگی که از لاغ‌های معمولی تخمین زده شده مقایسه شده است. پارامترهایی که برای دو الگوریتم یادگیری عمیق استفاده شده است مطابق جدول ۲، به شرح زیر می‌باشد:

الگوریتم‌های یادگیری عمیق از میانگین مربعات خطای (MSE)، جذر میانگین مربعات خطای (RMSE) و ضریب تعیین (R^2) استفاده شده است که روابط آن‌ها مطابق معادلات ۶، ۷ و ۸ می‌باشد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{predict}})^2 \quad (6)$$

$$RMSE = \sqrt{MSE} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{predict}})^2}{\sum_{i=1}^n (Z_{\text{measured}} - Z_{\text{average}})^2} = 1 - \frac{MSE}{\sigma^2} \quad (8)$$

نتایج و بحث

در این مقاله نتایج دو الگوریتم یادگیری عمیق شامل CNN+LSTM و LSTM+MLP مورد بررسی قرار گرفته‌اند و RMSE، MSE و R^2 برای داده‌های آموزش، تست و داده کور محاسبه گردیده است. در این مقاله جهت تخمین شاخص شکنندگی دینامیک از داده واقعی مدول یانگ و

جدول ۲. پارامترهای مشترک مربوط به الگوریتم‌های یادگیری عمیق

Table 2. parameters related to deep learning algorithms

الگوریتم \ پارامتر	اندازه دسته	نرخ یادگیری	تکرار	تابع بهینه‌ساز	تعداد لایه‌ها	سایر توضیحات
LSTM+MLP	512	0.0001	100	Adam	4	دولایه اول مربوط به LSTM و دو لایه دوم مربوط به MLP لایه‌های: لایه پنهان اول: 100 گره و Dropout=0.1 لایه پنهان دوم: 200 گره و Dropout=0.1 لایه‌های MLP: لایه پنهان اول: 100 گره لایه پنهان دوم: 200 گره Activation function=Relu
CNN+LSTM	512	0.0001	100	Adam	4	دولایه اول مربوط به CNN و دو لایه دوم مربوط به LSTM لایه‌های: تعداد فیلترهای لایه اول: 128 و 256 Kernel size=3, Padding= same Activation function=Relu, Strides=2 لایه‌های: Dropout=0.2 لایه پنهان اول: 100 گره و Dropout=0.3 لایه پنهان دوم: 200 گره و

CNN+LSTM را نشان می‌دهد. نمودار مشکی رنگ (شاخص شکنندگی اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (شاخص شکنندگی پیش‌بینی شده داده آموزش) است. همچنین شکل‌های سمت چپ قسمت (الف) و (ب) تفکیک شده نمودارهای شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده را نشان می‌دهد. با توجه به شکل‌های (۸) و (۹) و جدول (۳)،

$$MSE_{LSTM+MLP} = 0.0048, MSE_{CNN+LSTM} = 0.0191$$

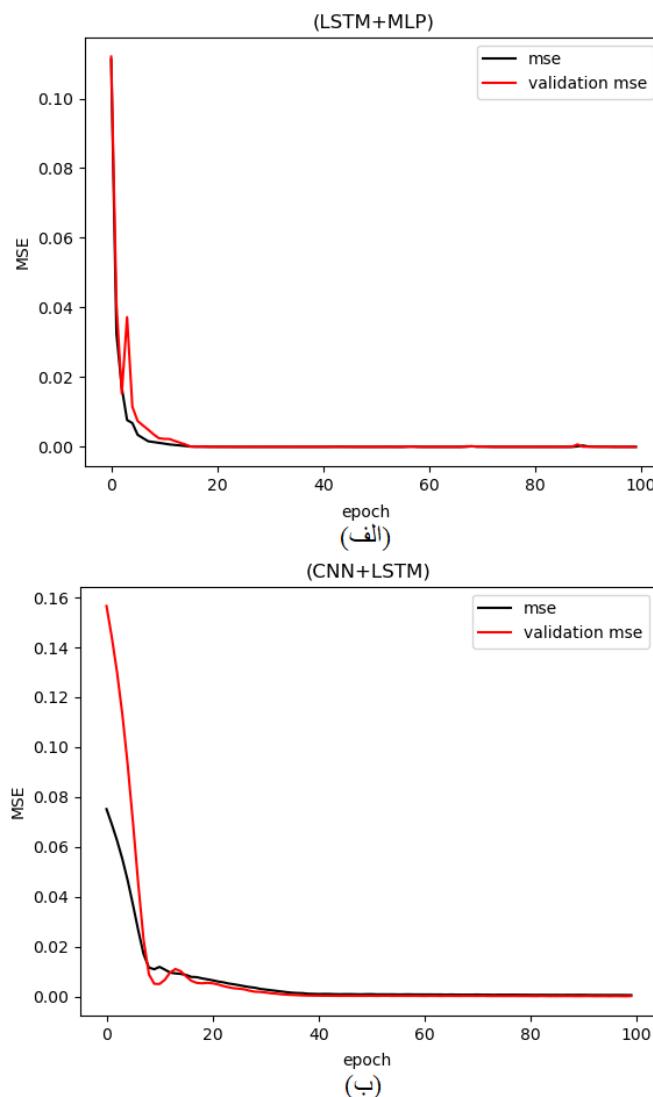
$RMSE_{LSTM+MLP} = 0.0693, RMSE_{CNN+LSTM} = R^2_{LSTM+MLP} = 0.9999, R^2_{CNN+LSTM} = 0.1384$ و ۰.۹۹۹۸ به دست آمده است. نتایج حاصل از داده‌های آموزش بیانگر خطای پایین و ضریب تعیین بالا برای هر دو الگوریتم ارائه شده می‌باشد.

جدول ۳، MSE، RMSE و R^2 برای داده‌های آموزش جهت پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق نمایش داده است. شکل ۸، خطای MSE و validation را برای هر کدام از الگوریتم‌ها نمایش داده است. شکل (۸-الف)، الگوریتم LSTM+MLP، شکل (۸-ب)، الگوریتم CNN+LSTM. شکل ۹، شاخص شکنندگی دینامیکی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم‌های CNN+LSTM و LSTM+MLP برای داده‌های آموزش را نشان داده است. شکل (۹-الف)، شاخص شکنندگی پیش‌بینی شده با استفاده از الگوریتم LSTM+MLP برای داده‌های آموزش، شکل (۹-ب)، پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم

جدول ۳. محاسبه خطاهای و ضریب تعیین داده‌های آموزش جهت تخمین شاخص شکنندگی

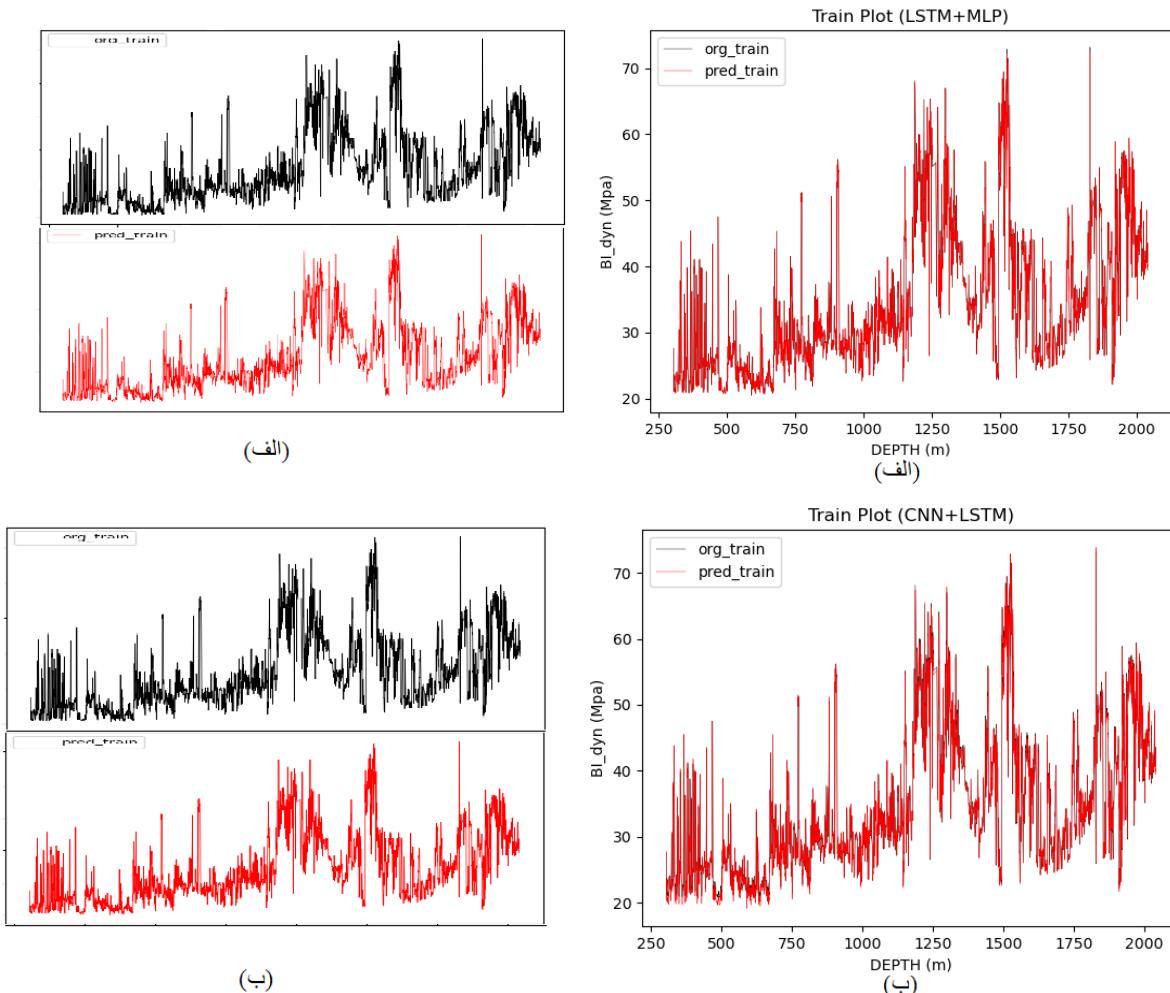
Table 3. BI Prediction errors and accuracy for train data records

Deep Learning models	MSE	RMSE	R^2
LSTM+MLP	0.0048	0.0693	0.9999
CNN+LSTM	0.0191	0.1384	0.9998



شکل ۸. نمایش خطای MSE (نمودار مشکی رنگ) و خطای validation MSE (نمودار قرمز رنگ) با دو الگوریتم ارائه شده. برای داده آموزش (الف)، الگوریتم LSTM+MLP (ب)، الگوریتم CNN+LSTM

Fig. 8. display the MSE (black log) and validation MES (red log) with two algorithms for train data (a), LSTM+MLP algorithm. (b), CNN+LSTM algorithm



شکل ۹. تخمین شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق برای داده‌های آموزش. (الف)، با استفاده از الگوریتم LSTM+MLP (ب)، با استفاده از الگوریتم CNN+LSTM. نمودار مشکی رنگ (شاخص شکنندگی اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (شاخص شکنندگی پیش‌بینی شده داده آموزش).

Fig. 9. Display of BI predict using deep learning algorithms for train data. (a) BI prediction for train data using LSTM+MLP algorithm, (b) BI prediction using CNN+LSTM algorithm. Black log (BI measured for training data (org_train)), red log (BI predicted for training data (pred_train)).

استفاده از الگوریتم LSTM+MLP برای داده‌های تست.

شکل (۱۰-ب)، پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم CNN+LSTM را نشان می‌دهد. نمودار آبی رنگ (شاخص شکنندگی اندازه‌گیری شده داده تست)، نمودار سبز رنگ (شاخص شکنندگی پیش‌بینی شده داده تست) است. همچنین شکل‌های سمت چپ قسمت (الف) و (ب) تفکیک شده نمودارهای شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده را نشان می‌دهد. با توجه به جدول ۴ و شکل ۱۰:

در ادامه الگوریتم‌های ارائه شده بر روی داده‌های تست اعمال گردیده است. جدول ۴، MSE و R^2 برای داده‌های تست جهت پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق نمایش داده است. شکل ۱۰، شاخص شکنندگی دینامیکی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM برای داده‌های تست را نشان داده است. شکل (۱۰-الف)، شاخص شکنندگی پیش‌بینی شده با

0.9976 به دست آمده است. نتایج حاصل از داده‌های تست بیانگر خطای پایین و ضریب تعیین بالا برای هر دو الگوریتم رائیه شده می‌باشد.

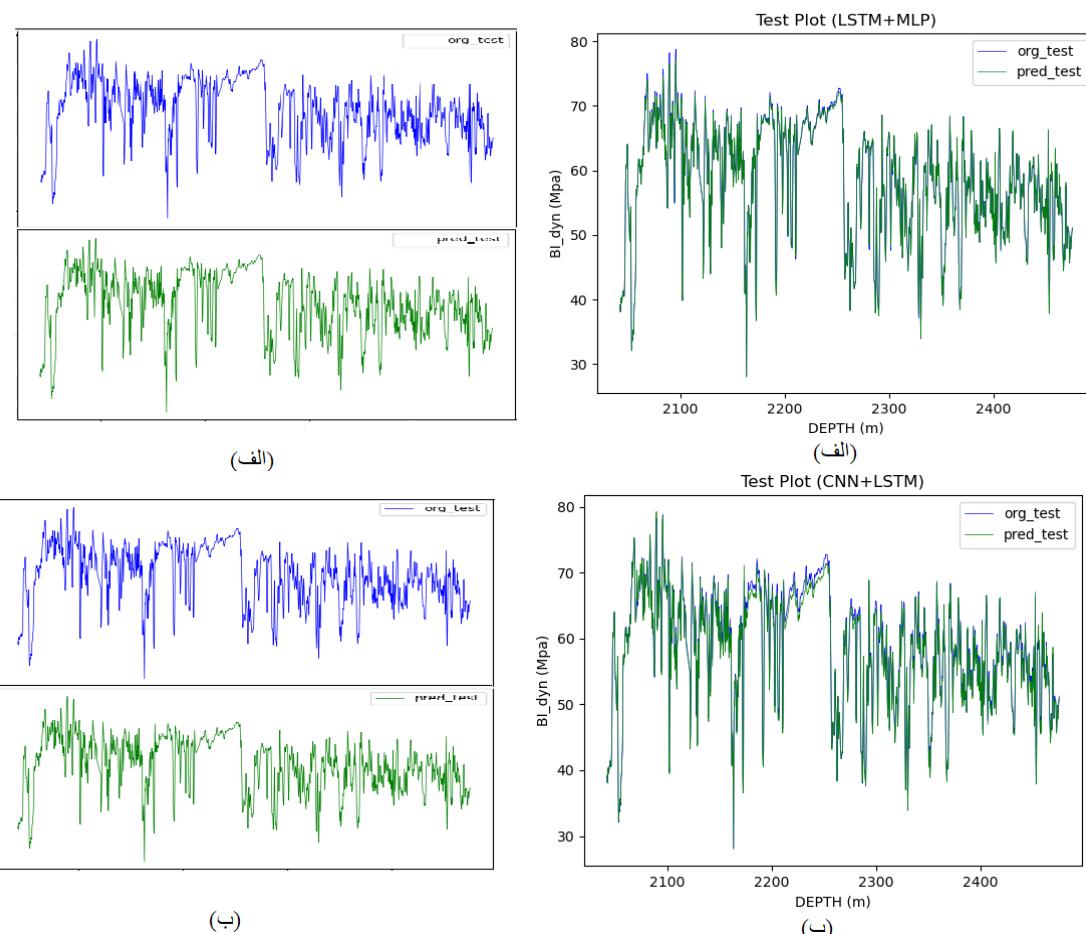
$$MSE_{LSTM+MLP} = 0.2201, MSE_{CNN+LSTM} = 0.1802$$

$$RMSE_{LSTM+MLP} = 0.4692, RMSE_{CNN+LSTM} = R^2_{LSTM+MLP} = 0.9971, R^2_{CNN+LSTM} = 0.4253$$

جدول ۴. محاسبه خطاهای و ضریب تعیین داده‌های تست جهت تخمین شاخص شکنندگی

Table 4. BI Prediction errors and accuracy for test data records

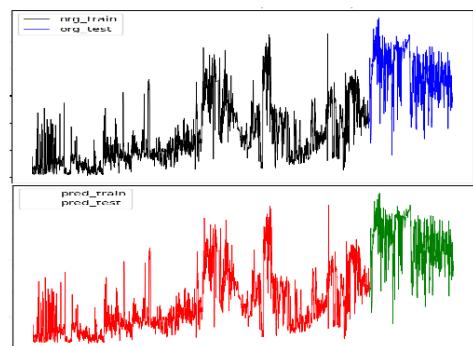
Deep Learning models	MSE	RMSE	R ²
LSTM+MLP	0.2201	0.4692	0.9971
CNN+LSTM	0.1802	0.4253	0.9976



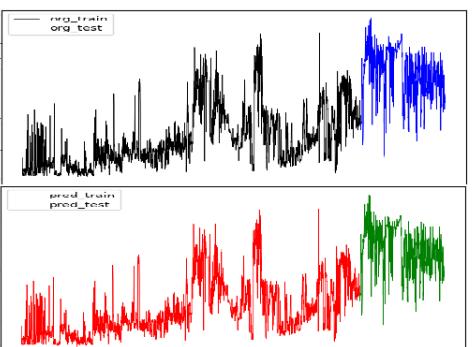
شکل ۱۰. تخمین شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق برای داده‌های تست. (الف)، با استفاده از الگوریتم LSTM+MLP. (ب)، با استفاده از الگوریتم CNN+LSTM. نمودار آبی رنگ (شاخص شکنندگی اندازه‌گیری شده داده تست)، نمودار سبز رنگ (شاخص شکنندگی پیش‌بینی شده داده تست).

Fig. 10. Display of BI predict using deep learning algorithms for test data. (a) BI prediction for test data using LSTM+MLP algorithm, (b) BI prediction using CNN+LSTM algorithm. Blue log (BI measured for test data (org_test)), red log (BI predicted for test data (pred_test)).

(شاخص شکنندگی اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (شاخص شکنندگی پیش‌بینی شده داده آموزش)، نمودار آبی رنگ (شاخص شکنندگی اندازه‌گیری شده داده تست) و نمودار سبز رنگ (شاخص شکنندگی پیش‌بینی شده داده تست) است. همچنان شکلهای سمت چپ قسمت (الف) و (ب) تفکیک شده نمودارهای شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده را نشان می‌دهد.

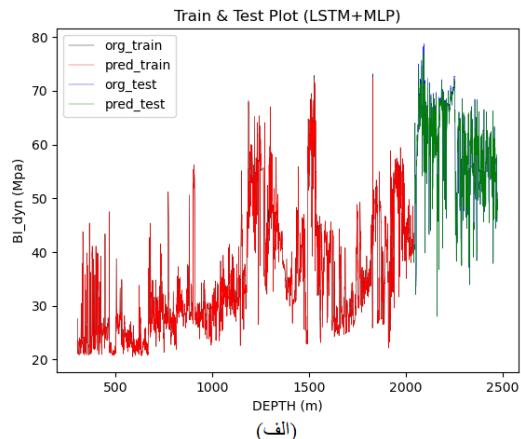


(الف)

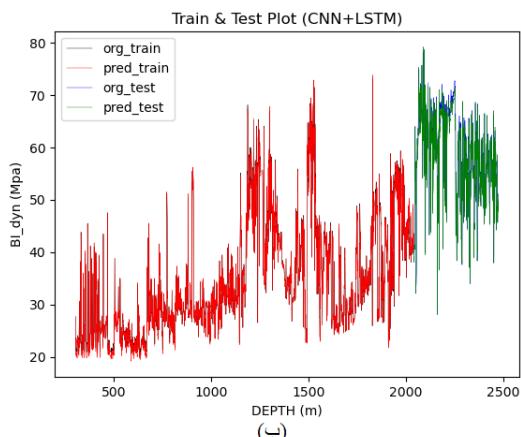


(ب)

شکل ۱۱، شاخص شکنندگی دینامیکی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM برای داده‌های آموزش و تست را نشان داده است. شکل (۱۱-الف)، شاخص شکنندگی پیش‌بینی شده با استفاده از الگوریتم LSTM+MLP برای داده‌های آموزش و تست، شکل (۱۱-ب)، پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم CNN+LSTM را برای داده‌های آموزش و تست نشان می‌دهد. نمودار مشکی رنگ



(الف)



(ب)

شکل ۱۱. تخمین شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق برای داده‌های آموزش و تست. (الف)، با استفاده از الگوریتم LSTM+MLP (ب)، با استفاده از الگوریتم CNN+LSTM. نمودار مشکی رنگ (شاخص شکنندگی اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (شاخص شکنندگی پیش‌بینی شده داده آموزش)، نمودار آبی رنگ (شاخص شکنندگی اندازه‌گیری شده داده تست) و نمودار سبز رنگ (شاخص شکنندگی پیش‌بینی شده داده تست).

Fig. 11. Display of BI predict using deep learning algorithms for train and test data. (a) BI prediction for train and test data using LSTM+MLP algorithm, (b) BI prediction using CNN+LSTM. black log (BI measured for training (org_train)), red log (BI predicted for training data(pred_train)), blue log (BI measured for test data (org_test)), green log (BI predicted for test data (pred_test)).

شکنندگی اندازه‌گیری شده مربوط به داده‌های کور و نمودار قرمز رنگ مربوط به شاخص شکنندگی پیش‌بینی شده می‌باشد. همچنین شکل‌های سمت چپ قسمت (الف) و (ب) تفکیک شده نمودارهای شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده را نشان می‌دهد. شکل ۱۳، ضریب تعیین شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده داده‌های کور با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM نشان داده است. شکل (۱۳-الف)، ضریب تعیین شاخص شکنندگی پیش‌بینی شده با استفاده از الگوریتم LSTM+MLP برای داده‌های کور، شکل (۱۳-ب)، ضریب تعیین شاخص شکنندگی پیش‌بینی شده با استفاده از الگوریتم CNN+LSTM می‌باشد. با توجه به جدول ۵ و شکل‌های ۱۲ و ۱۳،
 $MSE_{LSTM+MLP} = 32.0751$,
 $MSE_{CNN+LSTM} = 26.0425$
 $RMSE_{LSTM+MLP} = 5.6635$,
 $RMSE_{CNN+LSTM} = 5.1031$
 $R^2_{LSTM+MLP} = 0.7615$,
 $R^2_{CNN+LSTM} = 0.8064$ به دست آمده است. با توجه به جدول ۵ و شکل‌های ۱۲ و ۱۳، الگوریتم LSTM+MLP نسبت به الگوریتم CNN+LSTM برای داده‌های کور دارای خطای بیشتر و دقیق‌تر می‌باشد.

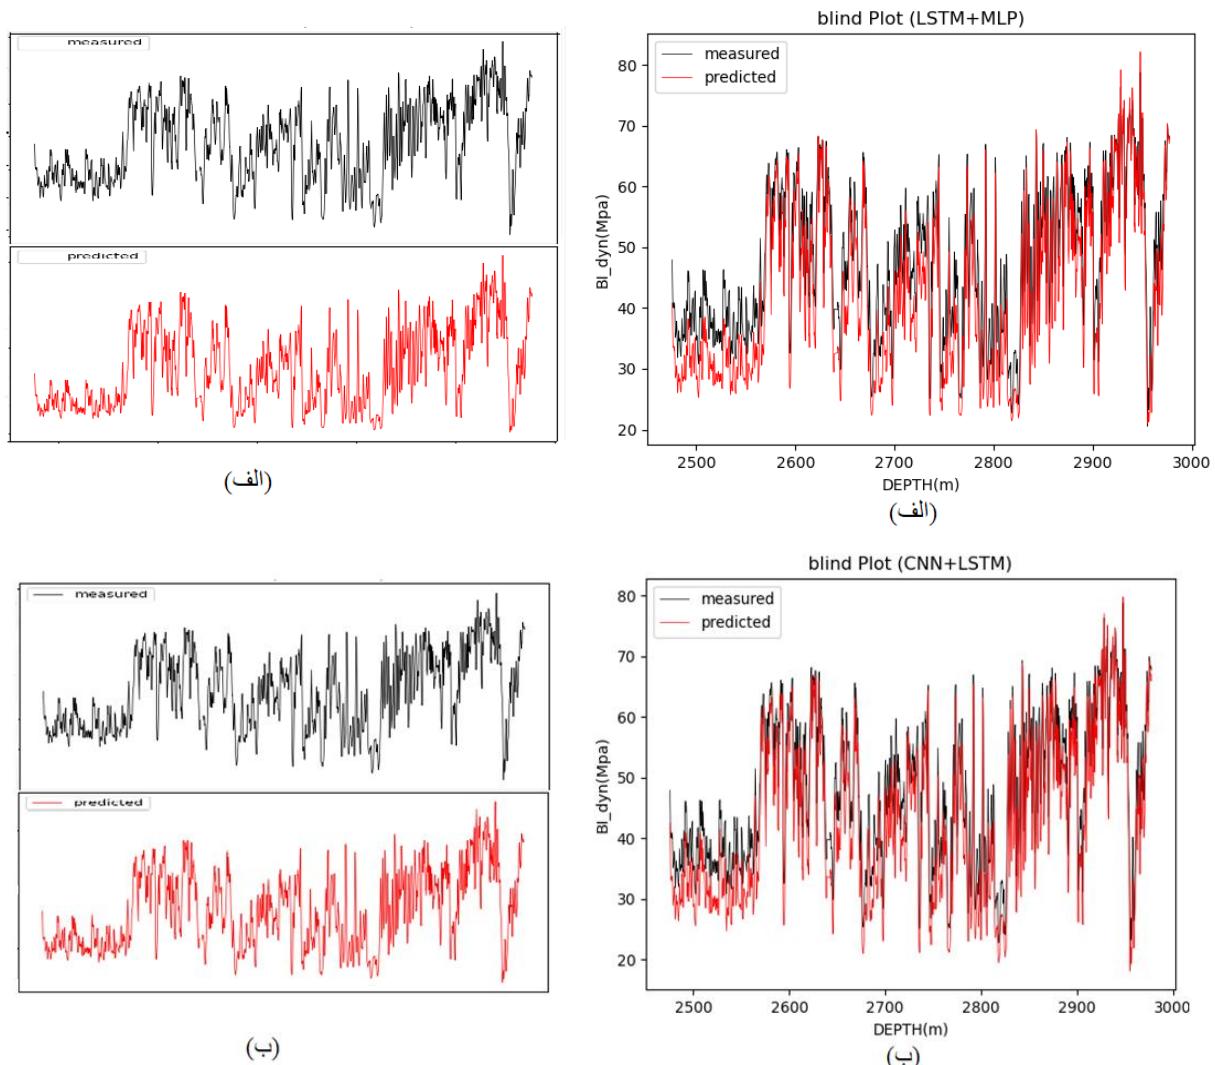
با توجه به شکل‌های ۸ تا ۱۱ و جدول ۳ و ۴، الگوریتم CNN+LSTM و LSTM+MLP برای داده‌های آموزش و داده‌های تست دارای خطای بسیار کم و دقیق‌تر می‌باشد.

جهت اطمینان از نتایج الگوریتم‌ها بخشی از داده‌ها از ابتدا به عنوان داده کور کنار گذاشته شد که در نهایت جهت تخمین شاخص شکنندگی به الگوریتم داده شود و شاخص شکنندگی پیش‌بینی شده با شاخص شکنندگی اندازه‌گیری شده مقایسه شود. جهت ارزیابی نتایج از پارامترهای RMSE، MSE و R^2 استفاده شده است. جدول ۵،
 R^2 برای داده‌های کور جهت پیش‌بینی شاخص شکنندگی LSTM+MLP با استفاده از الگوریتم‌های یادگیری عمیق (CNN+LSTM) نمایش داده است. شکل ۱۲، مقایسه شاخص شکنندگی اندازه‌گیری شده و پیش‌بینی شده داده‌های کور با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM نشان داده است. شکل (۱۲-الف)، شاخص شکنندگی پیش‌بینی شده با استفاده از الگوریتم LSTM+MLP برای داده‌های کور، شکل (۱۲-ب)، پیش‌بینی شاخص شکنندگی با استفاده از الگوریتم CNN+LSTM می‌باشد. نمودار مشکی رنگ شاخص

جدول ۵. محاسبه خطاهای کور جهت پیش‌بینی شاخص شکنندگی

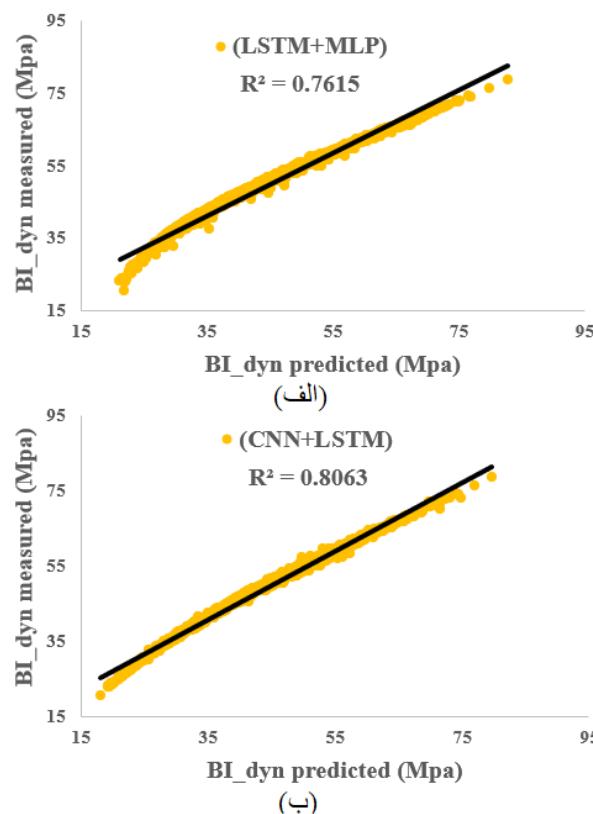
Table 5. BI Prediction errors and accuracy for blind data records

Deep Learning models	MSE	RMSE	R^2
LSTM+MLP	32.0751	5.6635	0.7615
CNN+LSTM	26.0425	5.1031	0.8064



شکل ۱۲. تخمین شاخص شکنندگی با استفاده از الگوریتم‌های یادگیری عمیق برای داده‌های کور. (الف)، با استفاده از الگوریتم LSTM+MLP (ب)، با استفاده از الگوریتم CNN+LSTM. نمودار مشکی رنگ (شاخص شکنندگی اندازه‌گیری شده داده کور)، نمودار قرمز رنگ (شاخص شکنندگی پیش‌بینی شده داده کور)

Fig. 12. Display of BI predict using deep learning algorithms for blind data. (a) BI prediction with LSTM+MLP algorithm, (b) BI prediction with CNN+LSTM algorithm. Black log (BI measured for blind data), red log (BI predicted for blind data)



شکل ۱۳. ضریب تعیین شاخص شکنندگی اندازه‌گیری شده و شاخص شکنندگی پیش‌بینی شده داده‌های کور با استفاده از الگوریتم‌های یادگیری عمیق. (الف)، با استفاده از الگوریتم LSTM+MLP (ب)، با استفاده از الگوریتم CNN+LSTM

Fig. 13. Display of coefficient of determination of blind data for BI measured and BI predicted with deep learning algorithms. (a) R^2 with LSTM+MLP algorithm, (b) R^2 with CNN+LSTM algorithm

روشی جدید جهت پیش‌بینی شاخص شکنندگی با استفاده از لاغ‌های متداول را به کار گرفت.

نتیجه‌گیری

با توجه به جایگاه ویژه‌ای که امروزه شاخص شکنندگی در مطالعات ژئومکانیکی پیدا کرده است در این مقاله تلاش شده است با استفاده از الگوریتم جدیدی از روش‌های هوشمند، این پارامتر پیش‌بینی گردد. در این مطالعه از یادگیری عمیق و الگوریتم‌های CNN+LSTM و LSTM+MLP برای تخمین شاخص شکنندگی در یکی از چاههای موجود در یکی از میدانین جنوب غرب ایران استفاده شده است. جهت اعمال الگوریتم روی داده‌ها نیاز هست که ابتدا ویژگی‌های مؤثر بر

مقایسه نتایج حاصل از دو الگوریتم یادگیری عمیق جهت پیش‌بینی شاخص شکنندگی با استفاده از لاغ‌های متداول، نشان می‌دهد که برای داده‌های آموزش و تست مقادیر خطای تقریباً نزدیک به هم بوده و در داده‌های کور گرچه نتایج دو روش نسبت مناسب است اما مقایسه نتایج حاصل از الگوریتم‌های روش یادگیری عمیق برای داده‌های کور حکایت از برتری الگوریتم CNN+LSTM نسبت به الگوریتم LSTM+MLP دارد و خطای بالاتر و دقت کمتری در الگوریتم LSTM+MLP نسبت به الگوریتم دیگر به دست آمده است. پس با توجه به نتایج این مطالعه می‌توان روش یادگیری عمیق و الگوریتم‌های مطرح شده به عنوان

نتایج به دست آمده از این دو الگوریتم نشان دهنده آن است که هر دو الگوریتم برای داده های آموزش و تست نتایج خوبی حاصل شده است و برای داده های کور مقدار

$$\text{MSE}_{\text{CNN+LSTM}} = 26.0425, \text{ MSE}_{\text{LSTM+MLP}} = \text{RMSE}_{\text{CNN+LSTM}} = 5.1035, \quad \text{and} \quad \text{RMSE}_{\text{LSTM+MLP}} = 32.0751$$

$R^2_{\text{CNN+LSTM}} = 0.8064$, $\text{RMSE}_{\text{LSTM+MLP}} = 5.6635$ $R^2_{\text{LSTM+MLP}} = 0.7615$ به دست آمد که نتایج بیانگر کارآیی بیشتر الگوریتم CNN+LSTM نسبت به الگوریتم LSTM+MLP برای پیش بینی شاخص شکنندگی می باشد. پس می توان روش یادگیری عمیق و الگوریتم های ارائه شده را به عنوان روشی جدید جهت تخمین شاخص شکنندگی با استفاده از لگ های متداول معرفی کرد.

شاخص شکنندگی تعیین شوند که ویژگی های مناسب جهت ورودی های این الگوریتم ها با استفاده از ضریب همبستگی پیرسون تعیین شد و از بین داده لگ های موجود، لگ-های Vp, RHOB, NEUT دارای بیشترین همبستگی بودند و به عنوان ورودی الگوریتم ها انتخاب شدند. در ادامه الگوریتم های CNN+LSTM و LSTM+MLP بر روی داده های آموزش، تست و داده های کور اعمال شد که برای MLP الگوریتم LSTM+MLP دو لایه LSTM و دو لایه CNN+LSTM دو لایه CNN و دو لایه MLP و برای الگوریتم CNN+LSTM دو لایه LSTM اعمال شده است. جهت ارزیابی نتایج مدل ها میانگین مربعات خطأ (MSE)، جذر میانگین مربعات خطأ (RMSE) و ضریب تعیین (R^2) محاسبه گردید. مقایسه

References

- Afolagboye L.O., Ajayi, D.E, & Afolabi, I.O. (2023). Machine learning models for predicting unconfined compressive strength: A case study for Precambrian basement complex rocks from Ado-Ekiti, Southwestern Nigeria, Scientific African . <https://doi.org/10.1016/j.sciaf.2023.e01715>.
- Alavi, A.H., Gandomi, A.H., Mollahasani, A., Heshmati, A.A.R., & Rashed, A. (2010). Modeling of maximum dry density and optimum moisture content of stabilized soil using artificial neural networks.
- Altindag, R. (2003). Correlation of specific energy with rock brittleness concepts on rock cutting. J. South Afr. Inst. Min. Metall. 103 (4), 163e171.
- Altindag, R. (2010). Assessment of some brittleness indexes in rock-drilling efficiency. Rock mechanics and rock engineering, 43(3), 361-370.
- Asemi, F., Lakirouhani A., Nicksiar, M., & Zohdi, A. (2024). A New Rock Brittleness Index Based on Crack Initiation and Crack Damage Stress Thresholds, International Journal of Geomechanics, Volume 24, <https://doi.org/10.1061/IJGNAI.GMENG-9151>.
- Daniel, C., Yin, X., Huang, X., Busari, J.A., Daniel, A.I., Yu, H., & Pan, Y. (2024). Bayesian optimization-enhanced ensemble learning for the uniaxial compressive strength prediction of natural rock and its application, Geohazard Mechanics, <https://doi.org/10.1016/j.ghm.2024.05.002>.
- Da Silva, M. (2013). Production correlation to 3D seismic attributes in the Barnett Shale. Texas: M.S. thesis, The University of Oklahoma.
- Ezazi, M., Ghorbani, E., Shafiei, A., Sharifi Teshnizi, E., & O'Kelly, B.C. (2024). Laboratory Hydraulic Tensile Strength Correlation with Strength-Based Brittleness Indices for Carbonate Reservoirs. Geosciences, 14, 52. <https://doi.org/10.3390/geosciences14020052>.
- Ghobadi, M. H., & Naseri, F. (2016). Rock Brittleness Prediction Using Geomechanical Properties of Hamekasi Limestone: Regression and Artificial Neural Networks Analysis. JGeope 6 (1), PP. 19-33.
- Ghobadi, M.H., Amiri, M. & Rahimi Shahid, M. (2023). The estimation of Brittleness indexes of Qom Formation sandstones in northern Hamedan using the ratio between point load index and porosity. New finding in applied geology, DOI:10.22084/NFAG.2022.25272.1493.
- Gholipour, M.A. & Hagh, A. (1990). Geological study of Maron oil field, Report No. P-4210,

- General Directorate of Extension Geology, National Company of South Oil-bearing Regions, 55 pages.
- Göktan, R. M. (1991). Brittleness and micro-scale rock cutting efficiency. *Mining Science and Technology*, 13(3), 237-241.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. *Ieee Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M.S. (2015). Deep learning for visual understanding: A review. *Neurocomputing*, vol. 187, pp. 27–48, Apr. 2016, doi: 10.1016/j.neucom.2015.09.116.
- Havel, S. (1970). Irradiation embrittlement and surveillance programmers of reactor pressure vessel steels (No. IAEA--117).
- Hetenyi, M. (1966). *Handbook of experimental stress analysis*. Wiley, New York, 15.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Comput.* 9 (8), 1735–1780.
- Hucka, V., & Das, B., 1974. Brittleness determination of rocks by different methods. In *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 11(10), 389-392. Pergamon.
- Ibrahim, A.F., Hiba, M., Elkhatatny, S., & Ali, A. (2024). Estimation of tensile and uniaxial compressive strength of carbonate rocks from well-logging data: artificial intelligence approach, Vol.: (0123456789)1 3Journal of Petroleum Exploration and Production Technology, <https://doi.org/10.1007/s13202-023-01707-1>.
- Jin, X., Shah, S., Roegiers, J., & Zhang, B. (2014). Fracability evaluation in shale reservoirs — An integrated petrophysics and geomechanics approach. Presented at the SPE Annual Technical Conference and Exhibition.
- Kalabarige, L.R., Sridhar, J., Subbaram, S., Prasath, P., & Gobinath, R. (2024). Machine Learning Modeling Integrating Experimental Analysis for Predicting Compressive Strength of Concrete Containing Different Industrial Byproducts, *Advances in Civil Engineering*, <https://doi.org/10.1155/2024/7844854>.
- Karakul, H., & Ulusay, R. (2013). Empirical Correlations for Predicting Strength Properties of Rocks from P-Wave Velocity Under Different Degrees of Saturation. *Rock Mech. Rock Eng*, 46 (5): 981-999.
- Karari, S.M., Heydari, M., Khademi-Hamidi, J., & Sharifi Tashnezi, A. (2019). Evaluation of the brittleness indices of rocks to estimate the toughness modulus. *Journal of the Engineering Geological Society of Iran*, Volume 13, Number 3, pp. 51-65.
- Kaunda, R.B., & Asbury, B. (2016). Prediction of rock brittleness using nondestructive methods for hard rock tunneling, *JRMGE*, 8 (4): 533-540.
- Kochukrishnan, S., Krishnamurthy, P., Yuvarajan, D., & Kaliappan, N. (2024). Comprehensive study on the Python-based regression machine learning models for prediction of uniaxial compressive strength using multiple parameters in Charnockite rocks, *Scientific Reports*, <https://doi.org/10.1038/s41598-024-58001-1>.
- Lashkaripour, G. R., Rastegarnia, A., & Ghafoori, M. (2018). Assessment of brittleness and empirical correlations between physical and mechanical parameters of the Asmari limestone in Khersan 2 dam site, in southwest of Iran. *Journal of African Earth Sciences*, 138: 124-132.
- Lawn, B.R, & Marshall, D.B. (1979). Hardness, toughness, and brittleness: an indentation Analysis. *Journal of the American ceramic society*, 62(7-8), 347-350.
- Mohammadi, D., & Tavasoli Elin, N. (2015). Estimation of brittleness index of limestones of Qom Formation using physical characteristics. 9th National Conference of Engineering Geology and Environment of Iran.
- Morley, A. (1954). *Strength of materials*, 11th ed. Longmans, Green, London, 532.
- Motiei, H. (2009). *Petroleum geology of the Persian Gulf*. Tehran University Press.
- Mousavi, Z., Bayat, M., & Feng, W. (2024). Machine Learning Models for Predicting Shear Wave Velocity of Soils, *IOP Conf. Series: Earth and Environmental Science*, doi:10.1088/1755-1315/1334/1/012039.
- Niu, I., Cui, Q., Luo, J., Huang, H., & Zhang, J. (2024). Unconfined compressive strength prediction of rock materials based on machine

- learning, Journal of Engineering and Applied Science, <https://doi.org/10.1186/s44147-024-00472-0>.
- Obert, L., & Duvall, W.I. (1967). Rock mechanics and the design of structures in rock (No. BOOK). J. Wiley.
- Ore, T., Gao, D., 2021. Supervised machine learning to predict brittleness using well logs and seismic signal attributes: Methods and application in an unconventional reservoir. *Applied Geoscience & Energy*. DOI:10.1190/segam2021-3594773.1.
- Özfirat, M.K., Yenice, H., Şimşir, F., & Yaralı, O. (2016). A new approach to rock brittleness and its usability at prediction of drillability. *Journal of African Earth Sciences*, 119, 94-101.
- Perez Altamar, R. (2013). Brittleness estimation from seismic measurements in unconventional reservoirs: Application to the Barnett Shale: Ph.D. dissertation, The University of Oklahoma.
- Ramsay, J.G. (1967). *Folding and fracturing of rocks*. McGraw Hill Book Company, 568.
- Rickman, R.M., Mullen, J., Petre, W., Grieser, D., & Kundert, A. (2008). A practical use of shale petrophysics for stimulation design optimization: All shale plays are not clones of the Barnett Shale. Presented at the SPE Annual Technical Conference and Exhibition.
- Shi, X., Liu, G., Cheng, Y., Yang, L., Jiang, H., Chen, L., Jiang, Sh., & Wang, J. (2016). Brittleness index prediction in shale gas reservoirs based on efficient network models. *Journal of Natural Gas Science and Engineering*, <http://dx.doi.org/10.1016/j.jngse.2016.09.009>.
- Valim, S.M., & Antia, L.S. (2021). The Use of Well-Log Data in the Geomechanical Characterization of Middle Cambrian Tight Sandstone Formation: A Case Study from Eastern Pomerania. Poland, *energies*. <https://doi.org/10.3390/en14196022>.
- Wang, J., Du, J., Li, W., Chen, X., Zhang, H., Tao, W., Li, Z., & Hao, R. (2023). Brittleness index evaluation of gas-bearing sandstone under triaxial compression conditions, *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*, <https://doi.org/10.1007/s40948-023-00713-1>.
- Xu, B., Tan, Y., Sun, W., Ma, T., Liu, H., & Wang, D. (2023). Study on the Prediction of the Uniaxial Compressive Strength of Rock Based on the SSA-XGBoost Model, *Sustainability*, <https://doi.org/10.3390/su15065201>.
- Yagiz, S. (2009). Assessment of brittleness using rock strength and density with punch penetration test. *Tunnelling and Underground Space Technology*, 24(1), 66-74.
- Zhang, D.C., Ranjith, P.G., & Perera, M.S.A. (2016). The brittleness indices used in rock mechanics and their application in shale hydraulic fracturing: a review. *J Pet. Sci. Eng.* 143, 158e170.
- Zhang, X., Xu, J., Shaikh, F., Sun, L., & Cao, Y. (2022). Rock Brittleness Evaluation Index based on Ultimate Elastic Strain Energy. *Research square*. DOI: <https://doi.org/10.21203/rs.3.rs-1688680/v1>.
- Zhang, T., Lin, K., Wen, X., Zhang, Y., & Zhao, L. (2024). Direct inversion of brittleness index in time-frequency mixed domain, *Geoenergy science and engineering*, volume 238, <https://doi.org/10.1016/j.geoen.2024.212920>.
- Zhao, J., Li, D., Jiang, J., & Luo, P. (2024). Uniaxial Compressive Strength Prediction for Rock Material in Deep Mine Using Boosting-Based Machine Learning Methods and Optimization Algorithms, *Computer Modeling in Engineering and Sciences*, DOI: 10.32604/cmes.2024.046960.