



Imam Khomeini International University
Vol. 10, No. 2, Summer 2025



نشریه مهندسی منابع معدنی
Journal of Mineral Resources Engineering
(JMRE)

Research Paper

Estimation of Young's Modulus Using Petrophysical Logs and Deep Learning Algorithms in One of Iran's Hydrocarbon Fields

Mollaei F.¹, Moradzadeh A.^{2*}, Mohebian R.³

1- Ph.D Student, School of Mining, College of Engineering, University of Tehran, Tehran, Iran

2- Professor, School of Mining, College of Engineering, University of Tehran, Tehran, Iran

3- Assistant Professor, School of Mining, College of Engineering, University of Tehran, Tehran, Iran

Received: 20 May 2024

Accepted: 11 Feb. 2025

Abstract: Young's modulus is one of the important parameters in geomechanical and petrophysical modelling, which is an indicator of rock hardness. Calculation of this parameter is one of the basic prerequisites for analyzing the stability of the well wall during the drilling of oil and gas wells. Many experimental models have been introduced to determine Young's modulus; each of them is used for a specific area. One of the recently used methods is intelligent methods. In this study, an attempt has been made to predict dynamic Young's modulus using deep learning algorithms in one of the hydrocarbon reservoir wells in southwest Iran. In order to use deep learning algorithms, it is first necessary to determine the effective features to estimate the Young's modulus as input of the algorithms. In this article, Pearson's correlation coefficient was used to select these features. In the following, Young's modulus was estimated using CNN+LSTM and LSTM+MLP hybrid networks, and their coefficient of determination (R²) values were determined to be close to 1, and the prediction error of both algorithms was very low for training and test data. Moreover, to ensure the results of the algorithms, a part of the data was set aside as blind data, and the error and R² values were calculated for it. The mean square error (MSE) of the LSTM+MLP and CNN+LSTM hybrid algorithms was obtained as equal to 30.51 and 25.99, and their R² values were determined as 0.77 and 0.81, respectively. The results show the effectiveness of deep learning algorithms introduced in predicting Young's modulus, but comparing the two presented algorithms, the CNN+LSTM algorithm has higher accuracy and less error.

Keywords: Young's modulus, petrophysical data, CNN+LSTM algorithm, LSTM+MLP algorithm, Model evaluation.

How to cite this article

Mollaei, F., Moradzadeh, A., and Mohebian, R. (2025). "Estimation of Young's modulus using petrophysical logs and deep learning algorithms in one of Iran's hydrocarbon fields". Journal of Mineral Resources Engineering, 10(2): 53-70.

DOI: 10.30479/jmre.2025.20402.1693

*Corresponding Author Email: a_moradzadeh@ut.ac.ir

COPYRIGHTS



©2025 by the authors. Published by Imam Khomeini International University.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>)

INTRODUCTION

Information on rock mechanical properties of hydrocarbon reservoirs has an impact on decision-making in drilling operations, well completion, well stimulation, etc. [1]. One of the important parameters in rock mechanics is Young's modulus, which is actually an indicator of the rock's strength against strain, or in other words, an indicator of the rock's hardness [2]. Young's modulus is one of the elastic parameters of rock, which is divided into two types, static and dynamic, depending on the method of its determination. The static tests that are performed on the samples taken from the formations obtain the values of the static Young's modulus by measuring the deformation of the rock under pressure. Static tests require direct sampling from the desired area, and special laboratory equipment is needed to achieve good results [3]. Therefore, due to the high cost and time required in this method, it is not possible to obtain the static Young's modulus values for all depths of underground formations directly using laboratory methods. On the other hand, the dynamic method is simpler, less costly and requires less time. In this method, a continuous profile of elastic parameters under in-situ conditions is obtained according to seismography or well drilling. In addition to Young's modulus, he obtained some other rock-mechanic parameters, such as shear modulus, bulk modulus and Lamé coefficient, by using the velocity of longitudinal and shear waves [4]. Equation 1 shows dynamic Young's modulus (E_{dyn}) using logs of density (ρ), shear wave velocity (V_s) and compressional wave velocity (V_p) [5].

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

METHODS

In this article, the data of RHOB, CHAL, NEUT, LL7, PEF, V_p , V_s , MLL, and GR logs were available to determine the Young's modulus using deep learning algorithms.

In order to select the effective features and suitable inputs for the algorithms, the correlation coefficient of the features should be checked with the Young's modulus. One of the methods of selecting the feature is to calculate the Pearson correlation coefficient. According to Pearson's correlation, V_p , RHOB, and NEU 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.




Figure 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 divided into tests. In the next step, data normalization has been done to achieve higher accuracy. For normalization, the min-max normalization function is used, which adjusts the available data between zero and one. In the following, the Adam optimizer function is used for optimization. To evaluate the model and compare the results of deep learning algorithms, RMSE error, MSE error and R^2 have been used, and their relationships are according to equations 2, 3 and 4.

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

$$RMSE = \sqrt{MSE} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Z_{measured} - Z_{predict})^2}{\sum_{i=1}^n (Z_{measured} - Z_{average})^2} = 1 - \frac{MSE}{\sigma^2} \quad (4)$$

FINDINGS AND ARGUMENT

In this article, the results of two deep learning algorithms, including LSTM+MLP and CNN+MLP, were investigated, MSE error, RMSE error and R^2 were calculated for training, testing and blind data. Table 1 displays Young's modulus prediction errors and accuracies based on the test (20%) subset, respectively.

Figure 2 shows the comparison of Young's modulus predicted and Young's modulus measured for training and test data.

Tables 2 displays the Young's modulus prediction errors and accuracies based on the blind subsets, respectively.

Table 1. Young's modulus prediction errors and accuracy for test data records using a deep learning algorithm

Deep learning models	MSE	RMSE	R^2
LSTM+MLP	1.0650	1.0320	0.9857
CNN+LSTM	0.5760	0.7589	0.9923

Table 2. Young's modulus prediction errors and accuracy for blind data records using deep learning algorithms

Deep learning models	MSE	RMSE	R^2
LSTM+MLP	30.5101	5.5235	0.7733
CNN+LSTM	25.9923	5.0982	0.8069




Figure 2. Display of Young's modulus prediction using deep learning algorithms for training and testing data; **A:** Young's modulus prediction for train and test data using the LSTM+MLP algorithm, **B:** Young's modulus prediction using CNN+LSTM [Black log (Young's modulus measured for training (original data)), red log (Young's modulus predicted for training data), blue log (Young's modulus measured for test data (original data)), and green log (Young's modulus predicted for test data)]

Figure 3 shows the comparison of Young's modulus predicted and Young's modulus measured for blind data.




Figure 3. Display of Young's modulus prediction using deep learning algorithms for blind data; **A:** Young's modulus prediction using LSTM+MLP, **B:** Young's modulus prediction using CNN+MLP [Black log (Young's modulus predicted), red log (Young's modulus measured)]

CONCLUSIONS

Considering the importance of Young's modulus in determining geomechanical and petrophysical models, it is necessary to use a cheap and accurate method to predict Young's modulus. For this purpose, deep learning and LSTM+MLP and CNN+LSTM algorithms have been used in this study to estimate Young's modulus. In order to apply the algorithm on the data, it is necessary to first determine the effective and influential characteristics on Young's modulus. In this article, the effective characteristics were determined using the Pearson correlation coefficient, and the logs of Vp, RHOB, and NEUT were identified as the input of the algorithms. In the following, the introduced models were applied, and RMSE, MSE and R2 were calculated to evaluate the results of the models. The comparison of the results shows that both algorithms have obtained good results for training and test data, and for blind data, the CNN+LSTM algorithm performs better than the LSTM+MLP algorithm for It has Young's modulus prediction because it has a lower error and a higher coefficient of determination compared to the LSTM+MLP algorithm. So, it can be said that deep learning algorithms can be used as an effective, simple and low-cost method to estimate elastic modulus and especially Young's modulus using logs.

REFERENCES

- [1] Yale, D. P., and Jamieson, W. H. (1994). "Static and Dynamic Rock Mechanical Properties in the Hugoton and Panoma Fields, Kansas". SPE Mid-Continent Gas Symposium, Texas, USA.
- [2] Tutuncu, A. N., Podio, A. L., Gregory, A. R., and Sharma, M. M. (1998). "Nonlinear Viscoelastic Behavior of Sedimentary Rocks. Part I: Effect of Frequency on Strain Amplitude". Geophysics, 63(1): 184-194.
- [3] Hongkui, G., Yingsong, L., Shanzhou, M., and Song, L. (2001). "Difference of Rock Elastic Parameters under Static and Dynamic Loading". In: the ISRM International Symposium, 2nd Asian Rock Mechanics Symposium, Beijing, China, September.

- [4] Jaeger, J. C., and Cook, N. G. W. (1976). *"Fundamentals of Rock Mechanics"*. First Edition, Chapman and Hall, London, pp. 585. DOI: <https://doi.org/10.1017/S0016756800044897>.
- [5] Valim, S. M., and 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*, 14(19): 6022. DOI: <https://doi.org/10.3390/en14196022>.



تخمین مدول یانگ با نگارهای پتروفیزیکی و الگوریتم‌های یادگیری عمیق در یکی از میادین هیدروکربنی ایران

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

۱- دانشجوی دکترا، دانشکده مهندسی معدن، دانشکده فنی، دانشگاه تهران، تهران

۲- استاد، دانشکده مهندسی معدن، دانشکده فنی، دانشگاه تهران، تهران

۳- استادیار، دانشکده مهندسی معدن، دانشکده فنی، دانشگاه تهران، تهران

پذیرش: ۱۴۰۳/۱۱/۲۳

دریافت: ۱۴۰۳/۰۲/۳۱

چکیده

مدول یانگ یکی از پارامترهای مهم در مدل‌سازی ژئومکانیکی و یکی از پیش‌نیازهای اساسی برای تحلیل پایداری دیواره چاه در طول مسیر حفاری چاه‌های نفت و گازی است. برای تعیین مدول یانگ مدل‌های تجربی زیادی معرفی شده‌اند که هر کدام از آنها مختص منطقه‌ای خاص هستند. یکی از روش‌هایی که اخیراً زیاد مورد استفاده قرار می‌گیرد روش‌های هوشمند است. در این مطالعه سعی شده است تا مدول یانگ دینامیک با استفاده از الگوریتم‌های یادگیری عمیق در یکی از چاه‌های مخازن هیدروکربنی جنوب غرب ایران پیش‌بینی شود. برای استفاده از الگوریتم‌های یادگیری عمیق ویژگی‌های موثر برای تخمین مدول یانگ برای ورودی الگوریتم‌ها با تعیین ضریب همبستگی پیرسون مشخص شدند. در ادامه با استفاده از شبکه‌های ترکیبی $CNN+LSTM$ ، $LSTM+MLP$ مدول یانگ تخمین زده شد و مقدار ضریب تعیین برای این الگوریتم‌ها برای داده‌های آموزش و تست نزدیک به ۱ و خطای پیش‌بینی هر دو الگوریتم بسیار کم به دست آمده است. همچنین برای اطمینان از نتایج الگوریتم‌ها بخشی از داده به عنوان داده شاهد کنار گذاشته شد و خطا و ضریب تعیین برای آن محاسبه گردید که مقادیر خطا (MSE) برای شبکه‌های ترکیبی $CNN+LSTM$ و $LSTM+MLP$ به ترتیب برابر ۲۵/۹۹ و ۳۰/۵۱ و مقادیر ضریب تعیین (R^2) آنها به ترتیب برابر ۰/۸۱ و ۰/۷۷ به دست آمده است. نتایج حاصل بیان‌کننده کارایی الگوریتم‌های یادگیری عمیق معرفی شده در پیش‌بینی مدول یانگ است ولی در مقایسه دو الگوریتم ارایه شده، الگوریتم $CNN+LSTM$ دقت بالاتر و خطای کمتری دارد.

کلمات کلیدی

مدول یانگ، داده‌های پتروفیزیکی، الگوریتم $CNN+LSTM$ ، الگوریتم $LSTM+MLP$ ، ارزیابی مدل.

استناد به این مقاله

ملائی، ف.، مرادزاده، ع.، محبیان، ر.؛ ۱۴۰۴؛ "تخمین مدول یانگ با نگارهای پتروفیزیکی و الگوریتم‌های یادگیری عمیق در یکی از میادین هیدروکربنی ایران". نشریه مهندسی منابع معدنی، دوره دهم، شماره ۲، ص ۷۰-۵۳.

DOI: 10.30479/jmre.2025.20402.1693



توضیحات	علائم اختصاری	توضیحات	علائم اختصاری
Artificial intelligence	AI	Latero Log 7	LL7
Artificial neural network	ANN	Machine learning technique	ML
Brittleness index	BI	Micro Latero Log	MLL
Backpropagation artificial neural network	BPANN	Multi extreme learning machine	MLEM
Caliper log	CHAL	Multi-layer perceptron	MLP
Compensate neutron log	CNL	Mean square error	MSE
Convolutional neural network	CNN	Neutron porosity	NEUT
Deep learning	DL	Coefficient of determination	R ²
Deep neural network	DNN	Density log	RHOB
Acoustic (sonic) log	DT	Root mean square error	RMSE
Extreme learning machine	ELM	Recurrent neutral network	RNN
Elman neural network	ENN	Formation true resistivity	RT
Feedforward artificial neural network	FFANN	Support vector machine	SVM
Fuzzy logic	FL	Support vector regression	SVR
Genetic algorithm	GA	Shear wave velocity	Vs
Gamma ray log	GR	Compressional wave velocity	Vp
Long short-term memory networks	LSTM		

۱- مقدمه

اطلاعات خواص مکانیک سنگی مخازن هیدروکربنی بر روی تصمیم‌گیری در عملیات حفاری، تکمیل چاه، تحریک چاه و نظایر آن تاثیرگذار است. یکی از پارامترهای مهم در مکانیک سنگ مدول یانگ است که در واقع شاخصی از میزان مقاومت نمونه سنگ در برابر کرنش یا به عبارت دیگر شاخصی از میزان سختی سنگ است [۱]. مدول یانگ یکی از پارامترهای الاستیک سنگ است که بسته به روش تعیین آن به دو نوع الاستیک و دینامیک تقسیم‌بندی می‌شود. آزمایش‌های الاستیکی که بر روی نمونه‌های گرفته شده از سازندها انجام می‌شود مقادیر مدول یانگ الاستیک را با اندازه‌گیری تغییر شکل سنگ تحت فشار به دست می‌دهد. آزمایش‌های الاستیک به نمونه‌گیری مستقیم از ناحیه مورد نظر نیاز دارد و تجهیزات آزمایشگاهی خاصی برای دستیابی به نتایج خوب مورد نیاز است، بنابراین به علت هزینه و زمان زیاد مورد نیاز در این روش، نمی‌توان مقادیر مدول یانگ الاستیک را برای تمام اعماق سازندهای زیرزمینی به طور مستقیم با استفاده از روش‌های آزمایشگاهی به دست آورد. در مقابل روش دینامیک ساده‌تر، کم هزینه‌تر و نیازمند وقت کمتری است. در این روش با توجه به لرزه‌نگاری یا چاه‌پیمایی نمودار پیوسته‌ای از پارامترهای الاستیک تحت

شرایط درجا به دست می‌آید. علاوه بر مدول یانگ، برخی پارامترهای مکانیک سنگی دیگری مانند مدول برشی، مدول بالک و ضریب لامه را با استفاده از سرعت امواج طولی و برشی به دست آورد [۲]. رابطه ۱، مدول یانگ دینامیک (E_{dyn}) را نشان می‌دهد [۵].

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

که در آن:

ρ : نگارهای چگالی

V_s : سرعت موج برشی

V_p : سرعت موج فشاری است.

مطالعات زیادی با استفاده از روش‌های مختلف برای تخمین مدول الاستیک انجام شده است. یکی از روش‌هایی که در سال‌های اخیر برای تخمین مدول الاستیک استفاده شده است، روش‌های هوشمند است. روی و همکاران [۳]، از الگوریتم‌های ANN، ANFIS و رگرسیون چندگانه (MR) برای پیش‌بینی مدول یانگ زغال‌سنگ اشباع شده از CO₂ استفاده کرد. متین و همکاران [۴]، مدول یانگ را با استفاده از رگرسیون چند متغیره (MVR) و شبکه عصبی رگرسیون تعمیم یافته (GRNN) پیش‌بینی کرد. طارق و همکاران


(ANFIS, ANN) پیش‌بینی کرد. احمد و همکاران [۲۱]، نسبت پواسون استاتیک را با استفاده از هوش مصنوعی (FN, RF) پیش‌بینی کردند. سیدینگ و الکاتانتی [۲۲]، مشخصات مدول الاستیک استاتیک را از داده‌های حفاری با استفاده از تکنیک‌های هوش مصنوعی (SVM, ANN) پیش‌بینی کردند. سینگ و همکاران [۲۳]، استفاده از الگوریتم ANFIS برای پیش‌بینی مدول یانگ پیشنهاد کرد. گولتکین و همکاران [۲۴]، از مدل‌های مختلف رگرسیون مبتنی بر ML مانند ANN, NLMR و ANFIS با استفاده از وزن واحد، تداخل و سرعت صوتی برای تعیین غیرمستقیم مدول یانگ بازالت استفاده کردند. شاهانی و همکاران [۲۵]، مدول الاستیک سنگ‌ها را با استفاده از یادگیری ماشین (مدل‌های رگرسیون هوشمند، (LightGBM)، ماشین بردار پشتیبان (SVM)، Catboost، رگرسیون درختی تقویت شده گرادیان (GBRT)، جنگل تصادفی (RF)، و (XGBoost)) پیش‌بینی کردند. جین و همکاران [۲۶]، مقاومت فشاری و مدول الاستیک سنگ‌ها را با استفاده از یادگیری ماشین پیش‌بینی کردند که در این مدل، یک مدل ترکیبی GWO-ELM، بر اساس یک شبکه ماشین یادگیری که به وسیله الگوریتم گرگ خاکستری (grey wolf) بهینه شده است، ساخته شده است.

با توجه به این که مدول یانگ یکی از پارامتری مهم مکانیک سنگی است که کاربردهای مهمی در مدل‌سازی‌های ژئومکانیکی دارد، بنابراین تعیین دقیق آن اهمیت بسزایی پیدا می‌کند. در این مقاله و برای اولین بار دو الگوریتم یادگیری عمیق ترکیبی شامل LSTM+MLP, CNN+MLP برای پیش‌بینی مدول یانگ دینامیک استفاده شده است. هدف از این مطالعه ارایه الگوریتمی برای پیش‌بینی مدول یانگ دینامیک و مقایسه این نتایج با یکدیگر است.


۲- معرفی داده‌ها و زمین‌شناسی منطقه

داده‌های مورد استفاده در این تحقیق از یکی از چاه‌های مربوط به میدان هیدروکربنی در جنوب غربی ایران است. این میدان در فروافتادگی دزفول قرار دارد و سنگ مخزن آن سازند آسماری و گروه بنگستان است [۲۷]. کل داده‌های موجود ۸۵۹۱ داده است که در محدوده عمق ۳۰۵٫۲۶ تا ۲۹۷۷٫۲۹ متر قرار دارند و نگارهای RHOB, CHAL, NEUT, LL7, PEF, Vp, MLL, GR را شامل می‌شوند.

[۵]، نسبت پواسون از سنگ‌های کربناته را با استفاده از یک شبکه عملکردی (FN) پیش‌بینی کرد. عبدی و همکاران [۶]، مدل‌های ANN و MRA (خطی) را برای پیش‌بینی مدول یانگ توسعه داد. قاسمی و همکاران [۷]، مقاومت فشاری و مدول یانگ سنگ‌های کربناته را با توسعه یک رویکرد مبتنی بر مدل درختی (model tree-based) ارزیابی کرد. امراثو و همکاران [۸]، مقاومت و مدول یانگ سنگ‌های رسوبی ناهمگن را با استفاده از ANFIS بر اساس تداخل، Vp و چگالی تعیین کردند. محمود و همکاران [۹]، مدول یانگ استاتیک برای سازند ماسه سنگی با استفاده از شبکه‌های عصبی مصنوعی را تخمین زدند. محمود و همکاران [۱۰]، از یک مدل ANN برای پیش‌بینی مدول یانگ ماسه‌سنگ استفاده کردند. یانگ و همکاران [۱۱]، مدل بیزی را برای پیش‌بینی مدول یانگ سنگ‌های گرانیتی دست نخورده توسعه دادند. داورپناه و همکاران [۱۲]، با پیشنهاد روابط خطی و غیرخطی، همبستگی‌های قوی بین خواص تغییر شکل استاتیکی و دینامیکی انواع سنگ‌های مختلف ایجاد کردند. وقاص و همکاران [۱۳]، از رگرسیون خطی و غیرخطی، منظم‌سازی و ANFIS (با استفاده از یک سیستم استنتاج عصبی فازی) برای پیش‌بینی مدول یانگ دینامیک سنگ‌های رسوبی استفاده کردند. محمود و همکاران [۱۴]، مدول یانگ دینامیک را با استفاده از شبکه عصبی تخمین زدند. شاهانی و همکاران [۱۵]، یک مدل رگرسیون XGBoost را برای اولین بار در ترکیب با MLR و ANN برای پیش‌بینی مدول یانگ سنگ رسوبی دست نخورده ایجاد کردند. سریان [۱۶]، مدل‌های رگرسیون ماشین احتمال کمینه (MPMR)، ماشین بردار ارتباط (RVM) و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) را برای پیش‌بینی مدول یانگ سنگ‌های آذرین هوازده استفاده کرد. کوکن [۱۷]، خواص تغییر شکل سنگ‌ها، یعنی مدول یانگ مماسی (Eti) و نسبت پواسون مماسی (vti) را با استفاده از روش‌های مختلف آماری و محاسباتی نرم مانند رگرسیون و ارزیابی‌های ANN پیش‌بینی کرد. آویس رشید و همکاران [۱۸]، از آزمون‌های غیرمخرب، یعنی MLR و ANN برای تخمین فاکتور Q و مدول یانگ استفاده کرد. کائو و همکاران [۱۹]، از یک مدل رگرسیون (XGBoost) ادغام شده با مدل الگوریتم (FA) برای پیش‌بینی مدول یانگ استفاده کردند. سایدینگ [۲۰]، نسبت پواسون را از پارامترهای حفاری با استفاده از ابزارهای یادگیری ماشین



شکل ۱: شماتیک شبکه MLP



شکل ۲: ساختار یک بلاک LSTM [۲۹]

که همراه با $X(1)$ ، ورودی مرحله بعدی محسوب می‌شود. بنابراین، $h(0)$ و $X(1)$ ورودی‌های مرحله بعدی هستند. به طور مشابه، $h(1)$ از مرحله بعدی به همراه $X(2)$ ورودی مرحله بعدتر به حساب می‌آیند و این روند همین‌طور ادامه دارد. به این ترتیب، محتوا را حین آموزش به طور مداوم به یاد می‌آورد. شبکه‌های حافظه طولانی کوتاه‌مدت (Long Short-Term Memory) یک نسخه بهبود یافته از شبکه‌های عصبی بازگشتی هستند که باعث می‌شوند به خاطر سپردن داده‌های گذشته در حافظه، آسان‌تر شود. مشکل محوشوندگی تدریجی شبکه‌های عصبی بازگشتی در اینجا برطرف شده است. LSTM برای طبقه‌بندی، پردازش و پیش‌بینی سری‌های زمانی در حضور تاخیرهای زمانی با مدت نامشخص مناسب است. این شبکه، مدل را با استفاده از پس انتشار (back-propagation) آموزش می‌دهد [۲۹]. در یک شبکه LSTM، سه دروازه وجود دارد:

دروازه ورودی: تشخیص می‌دهد که از کدام مقدار ورودی باید برای بهبود حافظه استفاده شود. تابع سیگموئید (Sigmoid) تصمیم می‌گیرد که کدام مقادیر را از صفر و ۱

۳- روش تحقیق

۳-۱- شبکه عصبی پرسپترون چندلایه

شبکه عصبی پرسپترون چند لایه، دسته‌ای از شبکه‌های عصبی مصنوعی پیشخور محسوب می‌شوند که حداقل سه لایه خواهند داشت: یک لایه ورودی (Input Layer)، یک لایه پنهان (Hidden Layer)، یک لایه خروجی (Output layer). نودهای شبکه عصبی که به آن‌ها Neuron گفته می‌شود، واحدهای محاسباتی در یک شبکه عصبی محسوب می‌شوند. در این شبکه عصبی، از خروجی‌های لایه اول (ورودی)، به عنوان ورودی‌های لایه بعدی (پنهان) استفاده می‌شود. این کار به همین شکل ادامه پیدا می‌کند تا زمانی که پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه پنهان به عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. به لایه‌هایی که بین لایه ورودی و لایه خروجی قرار می‌گیرند، لایه‌های پنهان (Hidden Layers) گفته می‌شود. شبکه‌های پرسپترون چند لایه، مانند شبکه‌های عصبی پرسپترون تک لایه، حاوی مجموعه‌ای از وزن‌ها نیز هستند که باید برای آموزش و یادگیری شبکه عصبی تنظیم شوند [۲۸]. شکل ۱، شماتیک شبکه MLP را نشان می‌دهد.


۳-۲- شبکه عصبی بازگشتی

شبکه عصبی بازگشتی (Recurrent Neural Network)، تعمیمی از شبکه عصبی پیشخور (feedforward) است که یک حافظه داخلی دارد. این شبکه، ماهیتی بازگشتی دارد، زیرا برای هر داده ورودی، تابع یکسانی را اجرا می‌کند در حالی که خروجی ورودی فعلی به محاسبه قبلی بستگی دارد. پس از تولید خروجی، این خروجی کپی شده و مجدداً به شبکه بازگشتی ارسال می‌شود. برای تصمیم‌گیری، ورودی فعلی و خروجی که از ورودی قبلی آموزش دیده است، در نظر گرفته می‌شود. برخلاف شبکه‌های عصبی پیشخور، شبکه‌های عصبی بازگشتی می‌توانند از حالت (حافظه) داخلی خود برای پردازش دنباله‌ای از ورودی‌ها استفاده کنند. این موضوع باعث می‌شود که این شبکه‌ها در کارهایی مانند تشخیص دستخط به هم متصل و تکه تکه نشده یا تشخیص گفتار قابل استفاده باشند. در سایر شبکه‌های عصبی، تمام ورودی‌ها از یکدیگر مستقل هستند، اما در شبکه عصبی بازگشتی، همه ورودی‌ها با یکدیگر مرتبط هستند. مطابق شکل ۲، ابتدا $X(0)$ را از دنباله ورودی گرفته و سپس $h(0)$ را به عنوان خروجی تحویل می‌دهد

کانولوشن، ماتریسی است که همه جا صفر است مگر جاهایی که تمپلیت خاصی که در فیلتر وجود داشته، در تصویر نیز وجود داشته است. برای مثال اگر فیلتری برای تشخیص نقاط طراحی کرده‌ایم و آن را با تصویر اصلی کانوالو کنیم، هر قسمتی از تصویر که ویژگی نقطه دارد در ماتریس خروجی مقداری غیرصفر خواهد داشت.

لایه‌ی Pooling: این لایه اطلاعات مربوط به ویژگی‌های استخراج شده را تجمیع می‌کند. نوعی فشرده‌سازی در ویژگی‌های شناسایی شده ایجاد می‌کند و باعث می‌شود که اگر موقعیت یا جهت یا مقیاس تصاویر عوض شد، همچنان شبکه بتواند ویژگی‌های مورد نظر را استخراج کند (Shift Invariancy).

لایه Fully Connected: ماتریس‌های ویژگی استخراج شده در انتهای شبکه یا به اصطلاح Feature map ها به صورت ستونی پشت سر هم چیده می‌شوند و به عنوان ورودی برداری به لایه Fully Connected داده می‌شوند و خروجی نهایی اجرا می‌شود [۳۰].



شکل ۳: پردازش تصویر به وسیله روش CNN

۴- پیش‌بینی مدول یانگ با استفاده از الگوریتم یادگیری عمیق

در این مقاله داده‌های نگارهای RHOB, CHAL, NEUT, LL7, PEF, Vp, MLL, GR برای تعیین مدول یانگ با استفاده از الگوریتم‌های یادگیری عمیق در دسترس بودند. فلوجارت پیش‌بینی مدول یانگ این مطالعه با استفاده از روش یادگیری عمیق در شکل ۴ نشان داده شده است.

برای انتخاب ویژگی‌های موثر و ورودی‌های مناسب به الگوریتم‌ها باید ضریب همبستگی ویژگی‌ها را با مدول یانگ بررسی کرد. یکی از روش‌های انتخاب ویژگی محاسبه ضریب همبستگی پیرسون است. این ضریب میزان همبستگی خطی

عبور دهد. تابع $\tanh$ به مقادیر عبور کرده، بر اساس اهمیت آنها، وزنی در بازه -1 تا 1 می‌دهد.


دروازه فراموشی: تشخیص می‌دهد چه جزئیاتی را باید از بلوک دور انداخت. این موضوع به وسیله تابع سیگموئید تصمیم‌گیری می‌شود. تابع سیگموئید، به حالت قبلی $(1 - \tanh)$ و ورودی محتوا (X_t) نگاه می‌کند و برای هر عدد در وضعیت سلول $C_t - 1$ ، عددی بین صفر و 1 به عنوان خروجی برمی‌گرداند. دروازه خروجی: از ورودی و حافظه بلوک برای تصمیم‌گیری در مورد خروجی استفاده می‌شود. تابع سیگموئید تصمیم می‌گیرد که کدام مقادیر را از صفر و 1 عبور دهد. تابع $\tanh$ به مقادیر عبور کرده، بر اساس اهمیت آنها، وزنی در بازه -1 تا 1 می‌دهد و با خروجی تابع سیگموئید ضرب می‌شود.

۳-۳- شبکه عصبی تبدیلی

شبکه عصبی کانولوشنی (Convolutional Neural Network) کلاس خاصی از شبکه‌های عصبی مصنوعی (Artificial Neural Network) در هوش مصنوعی است. این شبکه‌ها مشابه شبکه‌های عصبی سنتی دارای لایه‌ی ورودی، لایه‌ی پنهان و لایه‌ی خروجی هستند. تعداد لایه‌های این شبکه را می‌توان افزایش داد و بر چالش‌های ناشی از افزایش لایه‌ها غلبه کرد، از این رو در رده شبکه‌های عصبی عمیق (Deep Neural Network) قرار می‌گیرند.

CNN اولین بار در سال ۱۹۸۰ توسط Yann Lecun معرفی شد. ساختار شبکه از کورتکس بینایی مغز الهام گرفته شده است. طبق آزمایش‌های انجام شده، در مسیر کورتکس بینایی در مغز، با دیدن یک جسم ابتدا ویژگی‌های ساده و اولیه آن شناسایی می‌شوند و در طی این مسیر، ویژگی‌های شناسایی شده، پیشرفته‌تر می‌شوند، به طوری که نوره‌های انتهای مسیر بینایی با دیدن یک شی یا یک چهره‌ی خاص، فعال می‌شوند. فرض اولیه در این شبکه آن است که ورودی، تصویر یا چیزی شبیه به تصویر است و کاربرد اصلی این شبکه‌ها در حوزه بینایی ماشین (Computer vision) است. لایه‌های اصلی تشکیل‌دهنده شبکه CNN شامل Convolutional layer, Pooling Layer, Fully Connected Layer است (شکل ۳). شبکه‌های CNN می‌توانند لایه‌های دیگری نیز مانند Batch Normalization و نظایر آن داشته باشند.

لایه کانولوشنی: در لایه کانولوشن یک فیلتر با تصویر کانوالو (نوعی عملیات ریاضی) می‌شود. نتیجه این عملیات



شکل ۵: انتخاب ویژگی‌ها از طریق ماتریس همبستگی پیرسون

تنظیم می‌گردند. در ادامه برای بهینه‌سازی از تابع بهینه‌ساز Adam استفاده شده است. برای ارزیابی مدل و مقایسه نتایج الگوریتم‌های یادگیری عمیق از معیارهای RMSE، MSE و R^2 استفاده شده است که روابط آنها مطابق معادلات ۲، ۳ و ۴ است.


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

$$RMSE = \sqrt{MSE} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Z_{measured} - Z_{predict})^2}{\sum_{i=1}^n (Z_{measured} - Z_{average})^2} = 1 - \frac{MSE}{\sigma^2} \quad (4)$$


۵- نتایج

در این بخش نتایج دو الگوریتم یادگیری عمیق شامل LSTM+MLP و CNN+LSTM مورد بررسی قرار می‌گیرند و برای ارزیابی آنها معیارهای RMSE، MSE و R^2 برای داده‌های تست و شاهد محاسبه شده است. در این تحقیق برای تخمین مدول یانگ دینامیک از داده واقعی سرعت موج برشی حاصل از نگار DSI استفاده شده است. با توجه به اینکه در اکثر چاه‌ها سرعت موج برشی در دسترس نیست، سعی شده است بدون استفاده از نگار DSI و با استفاده از نگارهای معمولی این پارامتر تخمین زده شده است. برای اعتبارسنجی نتایج خروجی الگوریتم‌ها، مدول یانگ واقعی با مدول یانگی که از نگارهای معمولی تخمین زده شده، مقایسه و مورد اعتبارسنجی قرار



شکل ۴: فلوچارت پیش‌بینی مدول یانگ با استفاده از یادگیری عمیق

بین دو متغیر تصادفی را می‌سنجد. مقدار این ضریب بین ۱- تا ۱ تغییر می‌کند که «۱» به معنای همبستگی مثبت کامل، «۰» به معنی نبود همبستگی و «-۱» به معنی 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 نگاره‌های RHOB, CHAL, NEUT, LL7, PEF, Vp, MLL, GR دسترس بودند. شکل ۵، انتخاب ویژگی‌های موثر از طریق ماتریس همبستگی پیرسون را نشان می‌دهد. با توجه به شکل ۵ و با توجه به همبستگی پیرسون نگارهای Vp, RHOB, NEUT به عنوان ورودی الگوریتم‌ها انتخاب شدند و اضافه کردن نگارهای دیگر باعث افزایش خطا و کاهش دقت می‌شود. در ادامه از کل ۸۵۹۱ داده ابتدا ۱۶۳۴ داده به صورت تصادفی انتخاب و به عنوان داده شاهد جهت اطمینان از نتایج الگوریتم کنار گذاشته شد. از باقی داده‌ها ۸۰٪ برای آموزش (۵۵۶۵ داده) و ۲۰٪ داده‌ها (۱۳۹۲ داده) برای تست به صورت تصادفی تقسیم و استفاده شدند. در مرحله بعد نرمال‌سازی داده‌ها برای دستیابی به دقت بالاتر انجام شده است. برای نرمال‌سازی از تابع Min-Max Normalization استفاده شده که به کمک آن داده‌های موجود بین صفر و یک




شکل ۶: نمایش خطای MSE (نمودار مشکی رنگ) و خطای اعتبارسنجی (نمودار قرمز رنگ) برای دو الگوریتم ارایه شده: (الف) الگوریتم LSTM+MLP، (ب) الگوریتم CNN+LSTM

گرفت. پارامترهایی که برای سه الگوریتم یادگیری عمیق استفاده شده است مطابق جدول ۱ است. شکل ۶، خطای MSE و اعتبارسنجی (validation) را برای هرکدام از الگوریتم‌ها نشان داده است. جدول ۲، بخشی از داده‌های مدول یانگ واقعی و تخمین زده شده بر حسب عمق و اختلاف آنها در مرحله آموزش نشان داده شده است. همچنین جدول ۳، پارامترهای آماری، MSE، RMSE و R^2 را برای داده‌های آموزش برای پیش‌بینی مدول یانگ با استفاده از الگوریتم‌های یادگیری عمیق نشان داده است. شکل ۷، مدول یانگ دینامیکی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM برای داده‌های آموزش را نشان داده است. با توجه به شکل‌های ۶ و ۷ و جدول‌های ۲ و ۳، $MSE_{LSTM+MLP} = 0.2808$ ، $MSE_{CNN+LSTM} = 0.0426$ ، $RMSE_{LSTM+MLP} = 0.5299$ ، $RMSE_{CNN+LSTM} = 0.2064$ و $R^2_{LSTM+MLP} = 0.9973$ و $R^2_{CNN+LSTM} = 0.9996$ به دست آمده است. نتایج حاصل از داده‌های آموزش بیانگر خطای پایین و ضریب تعیین بالا برای هر دو الگوریتم ارایه شده است. در این شکل‌ها نمودار مشکی رنگ (مدول یانگ اندازه‌گیری شده) و نمودار قرمز رنگ (مدول یانگ پیش‌بینی شده) برای داده آموزش است.

جدول ۱: پارامترهای مشترک مربوط به الگوریتم‌های یادگیری عمیق

مدل یادگیری عمیق پارامتر		
LSTM+MLP	CNN+LSTM	اندازه دسته
۱۰۲۴	۱۰۲۴	نرخ یادگیری
۰/۰۱	۰/۰۰۰۱	تکرار
۱۰۰	۱۰۰	تابع بهینه ساز
Adam	Adam	تعداد لایه‌ها
۴	۴	سایر توضیحات
دولایه اول مربوط به LSTM و دو لایه دوم مربوط به MLP لایه‌های LSTM: لایه پنهان اول: ۱۰۰ گره و Dropout=0.1 لایه پنهان دوم: ۲۰۰ گره و Dropout=0.1 لایه‌های MLP: لایه پنهان اول: ۱۰۰ گره لایه پنهان دوم: ۲۰۰ گره Activation function=Relu	دولایه اول مربوط به CNN و دو لایه دوم مربوط به LSTM لایه‌های CNN: تعداد فیلترهای لایه اول: ۱۲۸ و تعداد فیلترهای لایه دوم: ۲۵۶ Kernel size=3, Padding= same Activation function=Relu, Strides=2 لایه‌های LSTM: لایه پنهان اول: ۱۰۰ گره و Dropout=0.2 لایه پنهان دوم: ۲۰۰ گره و Dropout=0.3	



شکل ۷: تخمین مدول یانگ 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 (مدول یانگ اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (مدول یانگ پیش‌بینی شده داده آموزش))

در ادامه عملکرد الگوریتم‌های ارایه شده بر روی داده‌های تست بررسی شده است. جدول ۴، بخشی از داده‌های مدول یانگ واقعی و تخمین زده شده بر حسب عمق و اختلاف آنها را برای این دسته از داده‌ها نشان داده است. همچنین در جدول ۵ مقادیر، MSE، RMSE و R^2 برای داده‌های تست برای پیش‌بینی مدول یانگ نشان داده شده است. افزون بر این، شکل ۸ مدول یانگ دینامیکی اندازه‌گیری و تخمین زده شده با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM را برای داده‌های تست نشان داده است. با توجه به جداول ۴ و ۵ و شکل ۸، مقادیر آماری؛

جدول ۲: نمایش بخشی از داده‌های مدول یانگ تخمین زده شده و واقعی مربوط به داده‌های آموزش

خطا	داده آموزش (مدول یانگ دینامیک پیش‌بینی شده) (مگا پاسگال)	داده آموزش (مدول یانگ دینامیک واقعی) (مگا پاسگال)	عمق (متر)
۰٫۲۶۶۷	۴۸٫۹۶۴۶	۴۹٫۲۳۱۳	۱۲۱۰٫۲۱
۰٫۲۹۸۱	۴۸٫۸۰۲۱	۴۹٫۱۰۰۲	۱۲۱۰٫۵۱
۰٫۳۱۳۷	۵۰٫۲۵۷۳	۵۰٫۵۷۱	۱۲۱۰٫۸۲
۰٫۳۴۵۳	۵۰٫۱۸۷۳	۵۰٫۵۳۲۶	۱۲۱۱٫۱۲
۰٫۳۹۴	۵۰٫۲۴۵۷	۵۰٫۶۳۹۷	۱۲۱۱٫۴۳
۰٫۴۴۳۸	۵۱٫۶۴۷	۵۲٫۰۹۰۸	۱۲۱۱٫۷۳
۰٫۴۲۳۳	۵۲٫۶۱۰۸	۵۳٫۰۳۴۱	۱۲۱۲٫۰۴
۰٫۱۷۳۱	۵۲٫۶۲۳۹	۵۳٫۷۹۷	۱۲۱۲٫۳۴
۰٫۱۳۲	۵۰٫۶۳۹۹	۵۰٫۶۵۳۱	۱۲۱۲٫۶۵
۰٫۳۵۸	۴۴٫۹۹۲۳	۴۴٫۹۶۸۱	۱۲۱۲٫۹۵
۰٫۱۱۳۵	۴۳٫۴۸۰۱	۴۳٫۵۹۳۶	۱۲۱۳٫۲۶
۰٫۲۶۶۳	۴۷٫۰۴۵۹	۴۷٫۳۱۲۲	۱۲۱۳٫۵۶
۰٫۳۱۴۳	۴۹٫۳۳۱۲	۴۹٫۶۴۵۵	۱۲۱۳٫۸۷
۰٫۲۸۷۳	۵۰٫۷۳۰۸	۵۱٫۰۱۸۱	۱۲۱۴٫۱۷
۰٫۳۴۵۷	۴۷٫۱۲۹۹	۴۷٫۴۷۵۶	۱۲۱۴٫۴۸
۰٫۲۹۳۵	۴۸٫۱۹۹۸	۴۸٫۴۹۳۳	۱۲۱۴٫۷۸
۰٫۲۵۶۹	۴۹٫۴۵۱۵	۴۹٫۷۰۸۴	۱۲۱۵٫۰۹
۰٫۳۴۹۹	۵۱٫۷۲۶۷	۵۲٫۰۷۶۶	۱۲۱۵٫۳۹
۰٫۴۴۲۱	۵۳٫۸۳۶۳	۵۴٫۲۷۸۴	۱۲۱۵٫۶۹
۰٫۴۹۸۲	۵۵٫۵۸۹۷	۵۶٫۰۸۷۹	۱۲۱۶
۰٫۳۶۵۵	۵۵٫۳۸۳۲	۵۵٫۷۴۸۷	۱۲۱۶٫۳
۰٫۲۸۴۳	۵۱٫۶۸۸۶	۵۱٫۹۷۲۹	۱۲۱۶٫۶۱
۰٫۱۲۶۷	۵۱٫۶۰۹	۵۱٫۷۳۵۷	۱۲۱۶٫۹۱
۰٫۱۱۲۱	۴۷٫۷۶۷	۴۷٫۸۷۹۱	۱۲۱۷٫۲۲
۰٫۰۷۷۸	۴۶٫۳۶۶۲	۴۶٫۴۴۴	۱۲۱۷٫۵۲
۰٫۰۸۸۷	۴۴٫۸۱۹۵	۴۴٫۹۰۸۲	۱۲۱۷٫۸۳
۰٫۰۱۵۹	۴۶٫۱۸۹۱	۴۶٫۲۰۵	۱۲۱۸٫۱۳
۰٫۰۶	۴۵٫۶۷۵۸	۴۵٫۶۱۵۸	۱۲۱۸٫۴۴
۰٫۰۵۲۱	۴۳٫۱۱۰۹	۴۳٫۰۵۸۸	۱۲۱۸٫۷۴
۰٫۰۱۴۴	۴۲٫۲۷۱۴	۴۲٫۲۵۷	۱۲۱۹٫۰۵

جدول ۳: محاسبه خطاها و ضریب تعیین داده‌های آموزش برای تخمین مدول یانگ

مدل‌های یادگیری عمیق	MSE	RMSE	R^2
LSTM+MLP	۰٫۲۸۰۸	۰٫۵۲۹۹	۰٫۹۹۷۳
CNN+LSTM	۰٫۰۴۲۶	۰٫۲۰۶۴	۰٫۹۹۹۶



جدول ۴: نمایش بخشی از داده‌های مدول یانگ تخمین زده شده و واقعی مربوط به داده‌های تست

خطا	مدول یانگ دینامیک پیش‌بینی شده (داده تست) (مگا پاسگال)	مدول یانگ دینامیک واقعی (داده تست) (مگا پاسگال)	عمق (متر)
۰٫۶۲۱۲	۶۷٫۷۸۷۱	۶۸٫۴۰۸۳	۲۰۷۵٫۲۳
۰٫۵۸۷۶	۷۱٫۵۰۶۲	۷۲٫۰۹۳۸	۲۰۷۵٫۵۴
۰٫۸۷۳۵	۶۸٫۶۹۳۲	۶۹٫۵۶۶۷	۲۰۷۵٫۸۴
۱٫۰۵۸۲	۶۳٫۹۱۵۵	۶۴٫۹۷۳۷	۲۰۷۶٫۱۵
۱٫۰۰۳۴	۶۲٫۹۳۳۲	۶۳٫۹۳۶۶	۲۰۷۶٫۴۵
۰٫۸۹۶۳	۶۲٫۴۱۳۶	۶۳٫۳۰۹۹	۲۰۷۶٫۷۵
۰٫۶۹۰۶	۶۳٫۵۶۹۳	۶۴٫۲۵۹۹	۲۰۷۷٫۰۶
۰٫۳۲۳۶	۷۱٫۶۰۰۱	۷۱٫۹۲۳۷	۲۰۷۷٫۳۶
۰٫۷۰۱۶	۶۳٫۶۳۹۵	۶۴٫۳۴۱۱	۲۰۷۷٫۶۷
۰٫۷۱۳	۶۴٫۱۹۴۴	۶۴٫۹۰۷۴	۲۰۷۷٫۹۷
۰٫۵۰۶۹	۶۸٫۲۷۰۷	۶۸٫۷۷۷۶	۲۰۷۸٫۲۸
۰٫۳۹۲۸	۶۹٫۲۲۶۸	۶۹٫۶۱۹۶	۲۰۷۸٫۵۸
۰٫۴۴۷۸	۶۷٫۳۸۰۵	۶۷٫۸۲۸۳	۲۰۷۸٫۸۹
۰٫۵۲۴۴	۶۷٫۴۲۰۸	۶۷٫۹۴۵۲	۲۰۷۹٫۱۹
۰٫۶۶۲۸	۶۷٫۷۱۳۷	۶۸٫۳۷۶۵	۲۰۷۹٫۵
۰٫۷۸۰۷	۶۷٫۸۰۵۴	۶۸٫۵۸۶۱	۲۰۷۹٫۸
۰٫۶۷۸	۷۰٫۱۶۱۷	۷۰٫۸۳۹۷	۲۰۸۰٫۱۱
۰٫۳۷۷۳	۷۱٫۲۵۱۴	۷۱٫۶۲۸۷	۲۰۸۰٫۴۱
۰٫۱۹۷۷	۷۰٫۱۰۶۲	۷۰٫۳۰۳۹	۲۰۸۰٫۷۲
۰٫۱۳۴۶	۶۷٫۴۱۶۱	۶۷٫۵۵۰۷	۲۰۸۱٫۰۲
۰٫۱۹۵۷	۶۶٫۱۸۳۷	۶۶٫۳۷۹۴	۲۰۸۱٫۳۳
۰٫۱۳۹۱	۶۷٫۴۳۱	۶۷٫۵۷۰۱	۲۰۸۱٫۶۳
۰٫۱۳۰۸	۶۶٫۸۱۹۴	۶۶٫۹۵۰۲	۲۰۸۱٫۹۴
۰٫۳۳۸۷	۶۴٫۵۲۰۹	۶۴٫۸۵۹۶	۲۰۸۲٫۲۴
۰٫۲۷۳	۶۸٫۲۵۲۸	۶۸٫۵۲۵۸	۲۰۸۲٫۵۵
۰٫۱۸۸	۷۳٫۱۹۶۱	۷۳٫۳۸۴۱	۲۰۸۲٫۸۵
۰٫۱۳۷۲	۷۵٫۴۰۵۶	۷۵٫۵۴۲۸	۲۰۸۳٫۱۶
۰٫۲۱۰۱	۷۳٫۳۵۷۷	۷۳٫۵۶۷۸	۲۰۸۳٫۴۶
۰٫۳۵۷۶	۷۰٫۱۵۴۸	۷۰٫۵۱۲۴	۲۰۸۳٫۷۷
۰٫۴۷۳	۶۵٫۸۹۶۲	۶۶٫۳۶۹۲	۲۰۸۴٫۰۷

جدول ۵: محاسبه خطاها و ضریب تعیین داده‌های تست برای تخمین مدول یانگ

مدل‌های یادگیری عمیق	MSE	RMSE	R ²
LSTM+MLP	۱٫۰۶۵۰	۱٫۰۳۲۰	۰٫۹۸۵۷
CNN+LSTM	۰٫۵۷۶۰	۰٫۷۵۸۹	۰٫۹۹۲۳

$MSE_{LSTM+MLP} = 1.0650$ $MSE_{CNN+LSTM} = 0.5760$
 $RMSE_{LSTM+MLP} = 1.0320$ $RMSE_{CNN+LSTM} = 0.7589$
 $R^2_{LSTM+MLP} = 0.9857$ و $R^2_{CNN+LSTM} = 0.9923$ به دست آمد. نتایج حاصل از داده‌های تست بیانگر خطای پایین و ضریب تعیین بالا برای هر دو الگوریتم ارایه شده است، اما الگوریتم CNN+LSTM در مقایسه با الگوریتم LSTM+MLP خطای کمتر و دقت بالاتری را نشان می‌دهد. با توجه به شکل‌های ۶ تا ۸ و جداول ۲ تا ۵، می‌توان دریافت که عملکرد دو الگوریتم ترکیبی LSTM+MLP و CNN+LSTM برای داده‌های آموزش و داده‌های تست خطای بسیار کم و دقت بسیار بالایی دارند.



شکل ۸: تخمین مدول یانگ 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 (مدول یانگ اندازه‌گیری شده داده تست)، نمودار سبز رنگ (مدول یانگ پیش‌بینی شده داده تست))

جدول ۶: نمایش بخشی از داده‌های مدول یانگ تخمین زده شده و واقعی مربوط به داده‌های شاهد

خطا	مدول یانگ پیش‌بینی شده (داده شاهد) (مگاپاسگال)	مدول یانگ دینامیک واقعی (داده شاهد) (مگاپاسگال)	عمق (متر)
۵,۵۴۱۷	۴۲,۲۱۸۹	۴۷,۷۶۰۶	۲۴۷۵,۷۴
۵,۹۴۳	۳۸,۸۲۴۸	۴۴,۷۶۷۸	۲۴۷۶,۰۴
۶,۴۷۷۱	۳۴,۷۶۰۲	۴۱,۲۳۷۳	۲۴۷۶,۳۵
۶,۷۳۸۶	۳۳,۴۶۹۲	۴۰,۲۰۷۸	۲۴۷۶,۶۵
۶,۹۵۴۸	۳۲,۹۵۷۹	۳۹,۹۱۲۷	۲۴۷۶,۹۶
۷,۱۰۴۵	۳۳,۳۶۶۱	۴۰,۴۷۰۶	۲۴۷۷,۲۶
۷,۱۲۷۹	۳۳,۵۷۸۴	۴۰,۷۰۶۳	۲۴۷۷,۵۷
۶,۹۵۸	۳۲,۸۴۱۸	۳۹,۷۹۹۸	۲۴۷۷,۸۷
۶,۸۰۱۷	۳۳,۵۰۲۷	۴۰,۳۰۴۴	۲۴۷۸,۱۸
۶,۶۴۶۲	۳۱,۷۷۲۹	۳۸,۴۱۹۱	۲۴۷۸,۴۸
۶,۴۹۵۲	۳۰,۵۹۶	۳۷,۰۹۱۲	۲۴۷۸,۷۹
۶,۲۸۸۹	۲۸,۶۹۳۸	۳۴,۹۸۲۷	۲۴۷۹,۰۹
۶,۲۲۷۲	۲۹,۰۷۳۳	۳۵,۳۰۰۵	۲۴۷۹,۴
۶,۱۲۱۵	۲۹,۵۶۴۹	۳۵,۶۸۶۴	۲۴۷۹,۷
۶,۱۰۱۶	۳۰,۷۳۸۹	۳۶,۸۴۰۵	۲۴۸۰,۰۱
۶,۰۱۰۲	۳۱,۶۴۹۷	۳۷,۶۵۹۹	۲۴۸۰,۳۱
۵,۸۵۸۵	۳۰,۶۵۵۳	۳۶,۵۱۳۸	۲۴۸۰,۶۱
۵,۵۷۵۶	۲۸,۷۴۳۸	۳۴,۳۱۹۴	۲۴۸۰,۹۲
۵,۳۳۱۷	۲۶,۳۴۵۳	۳۱,۶۷۷	۲۴۸۱,۲۲
۵,۵۶۸۶	۲۶,۸۸۲۵	۳۲,۴۵۱۱	۲۴۸۱,۵۳
۵,۸۴۶۶	۲۸,۱۹۸۶	۳۴,۰۴۵۲	۲۴۸۱,۸۳
۵,۹۳۲۳	۲۹,۸۹۲۷	۳۵,۸۲۵	۲۴۸۲,۱۴
۵,۷۹۸۹	۳۰,۲۹۶۲	۳۶,۰۹۵۱	۲۴۸۲,۴۴
۵,۵۶۹۵	۲۸,۸۲۰۵	۳۴,۳۹	۲۴۸۲,۷۵
۵,۴۹۴۷	۲۹,۲۳۳۴	۳۴,۷۲۸۱	۲۴۸۳,۰۵
۵,۶۰۲۸	۲۸,۹۳۳۶	۳۴,۵۳۶۴	۲۴۸۳,۳۶
۵,۷۰۵۱	۲۹,۱۰۸۶	۳۴,۸۱۳۷	۲۴۸۳,۶۶
۵,۶۹۹۱	۲۷,۵۳۶۳	۳۳,۲۳۵۴	۲۴۸۳,۹۷
۵,۶۸۳۴	۲۶,۶۰۸۲	۳۲,۲۹۱۶	۲۴۸۴,۲۷
۵,۷۲۵۱	۲۶,۱۶۲۹	۳۱,۸۸۸	۲۴۸۴,۵۸


جدول ۷: محاسبه خطاها و ضریب تعیین داده‌های شاهد برای پیش‌بینی مدول یانگ

مدل‌های یادگیری عمیق	MSE	RMSE	R^2
LSTM+MLP	۳۰,۵۱۰۱	۵,۵۲۳۵	۰,۷۷۳۳
CNN+LSTM	۲۵,۹۹۲۳	۵,۰۹۸۲	۰,۸۰۶۹

برای اطمینان از عملکرد هرچه بیشتر الگوریتم‌ها بخشی از داده‌های شاهد که از این فرآیند کنار گذاشته شده بودند در نهایت برای تخمین مدول یانگ به الگوریتم‌ها داده شدند و مدول یانگ پیش‌بینی شده با مدول یانگ اندازه‌گیری شده مقایسه گردیدند. برای ارزیابی نتایج از پارامترهای MSE، RMSE و R^2 استفاده شده است.


جدول ۶، بخشی از داده‌های مدول یانگ واقعی و تخمین زده شده بر حسب عمق و اختلاف آنها و جدول ۷ مقادیر پارامترهای خطا و برازش را برای داده‌های شاهد برای پیش‌بینی مدول یانگ با استفاده از الگوریتم‌های یادگیری عمیق (LSTM+MLP و CNN+LSTM) نشان می‌دهد. شکل ۱۰، مقایسه مدول یانگ اندازه‌گیری شده و پیش‌بینی شده داده‌های شاهد را با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM نشان می‌دهد. با توجه به جداول ۶ و ۷ و شکل ۹ مقادیر پارامترهای خطا و همبستگی، $MSE_{LSTM+MLP} = 30.5101$ ، $MSE_{CNN+LSTM} = 25.9923$ به $RMSE_{LSTM+MLP} = 5.5235$ و $RMSE_{CNN+LSTM} = 5.0982$ دست آمده است. نتایج حاصل از اعمال داده‌های شاهد روی الگوریتم‌های یاد شده بیانگر کمتر بودن خطای الگوریتم CNN+LSTM در مقایسه با الگوریتم LSTM+MLP است. ضریب تعیین مدول یانگ اندازه‌گیری و پیش‌بینی شده داده‌های شاهد با استفاده از الگوریتم‌های LSTM+MLP و CNN+LSTM و نمایش نمودار متقاطع آنها در شکل ۱۰، نشان می‌دهد که مقادیر $R^2_{LSTM+MLP} = 0.7733$ و $R^2_{CNN+LSTM} = 0.8069$ است. با توجه به شکل‌های ۹ و ۱۰ و جداول ۶ و ۷، می‌توان دریافت که الگوریتم LSTM+MLP نسبت به الگوریتم CNN+LSTM برای داده‌های شاهد خطای بیشتر و دقت کمتری دارد.

مقایسه نتایج حاصل از دو الگوریتم یادگیری عمیق برای پیش‌بینی مدول یانگ با استفاده از نگارهای چاه نشان می‌دهد که برای داده‌های تست مقادیر خطا تقریباً نزدیک به هم بوده و در داده‌های شاهد گرچه نتایج دو روش نسبتاً مناسب است، اما مقایسه نتایج حاصل از الگوریتم‌های روش یادگیری عمیق برای داده‌های شاهد حکایت از برتری الگوریتم CNN+LSTM نسبت به الگوریتم LSTM+MLP دارد، چرا که خطای بالاتر و دقت کمتری در الگوریتم LSTM+MLP نسبت به الگوریتم دیگر به دست آمده است.



شکل ۱۰: ضریب تعیین مدول یانگ اندازه‌گیری شده و مدول یانگ پیش‌بینی شده داده‌های شاهد با استفاده از الگوریتم‌های یادگیری عمیق؛ الف) با استفاده از الگوریتم LSTM+MLP، ب) با استفاده از الگوریتم CNN+LSTM

که ابتدا ویژگی‌های موثر و تاثیرگذار بر مدول یانگ تعیین شوند که در این مطالعه ویژگی‌های مناسب برای ورودی‌های این الگوریتم‌ها با استفاده از ضریب همبستگی پیرسون تعیین شد و نگاره‌های V_p , $RHOB$, $NEUT$ به عنوان ورودی الگوریتم‌ها مشخص گردید. در ادامه مدل‌های معرفی شده اعمال گردید و برای ارزیابی نتایج مدل‌ها پارامترهای $RMSE$, MSE و R^2 محاسبه گردید. مقایسه نتایج به دست آمده از این دو الگوریتم نشان‌دهنده آن است که هر دو الگوریتم نتایج خوبی برای داده‌های آموزش و تست به دست آورده‌اند، ولی برای داده‌های شاهد که در مراحل قبلی دیده نشده است الگوریتم CNN+LSTM نسبت به الگوریتم LSTM+MLP عملکرد بهتری برای پیش‌بینی مدول یانگ دارد، چرا که خطای کمتر و ضریب تعیین بیشتری نسبت به الگوریتم LSTM+MLP به دست آمده است. پس می‌توان گفت که از الگوریتم‌های یادگیری عمیق به عنوان روشی کارآمد، ساده و کم‌هزینه برای تخمین مدول‌های الاستیک و به ویژه مدول یانگ با استفاده از نگاره‌های متداول می‌توان استفاده کرد.



شکل ۹: تخمین مدول یانگ با استفاده از الگوریتم‌های یادگیری عمیق برای داده‌های شاهد با استفاده از؛ الف) الگوریتم LSTM+MLP و ب) الگوریتم CNN+LSTM (نمودار مشکی رنگ (مدول یانگ اندازه‌گیری شده داده شاهد)، نمودار قرمز رنگ (مدول یانگ پیش‌بینی شده داده شاهد))

۶- نتیجه‌گیری

باتوجه به اهمیت بسیار زیاد مدول یانگ در تعیین مدل‌های ژئومکانیکی و پتروفیزیکی، استفاده از روشی ارزان و در عین حال دقیق برای پیش‌بینی مدول یانگ لازم و ضروری است. به همین منظور در این مطالعه از یادگیری عمیق و الگوریتم‌های LSTM+MLP و CNN+LSTM برای تخمین مدول یانگ استفاده شده است. برای اعمال الگوریتم روی داده‌ها نیاز است

۷- مراجع

- selection approach". *Bulletin of Engineering Geology and the Environment*, 78: 3413-3423.
- [12] Davarpanah, S. M., Ván, P., and Vásárhelyi, B. (2020). "Investigation of the relationship between dynamic and static deformation moduli of rocks". *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*, 6: 29.
- [13] Waqas, U., and Ahmed, M. F. (2020). "Prediction Modeling for the Estimation of Dynamic Elastic Young's Modulus of Thermally Treated Sedimentary Rocks Using Linear-Nonlinear Regression Analysis, Regularization, and ANFIS". *Rock Mechanics and Rock Engineering*, 53: 5411-5428.
- [14] Mahmoud, A. A., Elkatatny, S., Alsabaa, A., and Shehri, D. A. (2020). "Functional neural networks-based model for prediction of the static Young's modulus for sandstone formations". In *Conference: 54th US Rock Mechanics/Geomechanics Symposium, OnePetro*.
- [15] Shahani, N. M., Zheng, X., Liu, C., Hassan, F. U., and Li, P. (2021). "Developing an XGBoost Regression Model for Predicting Young's Modulus of Intact Sedimentary Rocks for the Stability of Surface and Subsurface Structures". *Frontiers in Earth Science*, 9: 761990.
- [16] Ceryan, N. (2021). "Prediction of Young's modulus of weathered igneous rocks using GRNN, RVM, and MPMR models with a new index". *Journal of Mountain Science*, 18: 233-251.
- [17] Köken, E. (2021). "Assessment of Deformation Properties of Coal Measure Sandstones through Regression Analyses and Artificial Neural Networks". *Archives of Mining Sciences (AMS)*, 66: 523-542.
- [18] Awais Rashid, H. M., Ghazzali, M., Waqas, U., Malik, A. A., and Abubakar, M. Z. (2021). "Artificial Intelligence-Based Modeling for the Estimation of Q-Factor and Elastic Young's Modulus of Sandstones Deteriorated by a Wetting-Drying Cyclic Process". *Archives of Mining Sciences (AMS)*, 66: 635-658.
- [19] Cao, J., Gao, J., Nikafshan Rad, H., Mohammed, A. S., Hasanipanah, M., and Zhou, J. (2022). "A novel systematic and evolved approach based on XGBoost-firefly algorithm to predict Young's modulus and unconfined compressive strength of rock". *Engineering with Computers*, 38(Suppl 5): 3829-3845. DOI: <https://doi.org/10.1007/s00366-020-01241-2>.
- [20] Siddig, O., Gamal, H., Elkatatny, S., and Abdurraheem, A. (2021). "Real-time prediction of Poisson's ratio from drilling parameters using machine learning tools". *Scientific Reports*, 11: 12611. DOI: <https://doi.org/10.1038/s41598-021-92082-6>.
- [21] Ahmed, A., Elkatatny, S., and Alsaihati, S. (2021). "Applications of Artificial Intelligence for Static
- [1] Tutuncu, A. N., Podio, A. L., Gregory, A. R., and Sharma, M. M. (1998). "Nonlinear Viscoelastic Behavior of Sedimentary Rocks, Part I: Effect of Frequency on Strain Amplitude". *Geophysics*, 63(1): 11-318.
- [2] Jaeger, J. C., and Cook, N. G. W. (1976). "Fundamentals of Rock Mechanics". Chapman and Hall, London, pp. 585.
- [3] Valim, S. M., and 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*, 14(19): 6022. DOI: <https://doi.org/10.3390/en14196022>.
- [4] Roy, D. G., and Singh, T. N. (2018). "Regression and soft computing models to estimate young's modulus of CO2 saturated coals". *Measurement*, 129: 91-101.
- [5] Matin, S. S., Farahzadi, L., Makaremi, S., Chelgani, S. C., and Sattari, G. (2018). "Variable selection and prediction of uniaxial compressive strength and modulus of elasticity by random forest". *Applied Soft Computing*, 70: 980-987.
- [6] Tariq, Z., Abdurraheem, A., Mah, M., and Ahmed, A. (2018). "A rigorous data-driven approach to predict Poisson's ratio of carbonate rocks using a functional network". *Petrophysics-The SPWLA Journal of Formation Evaluation and Reservoir Description*, 59(06): 761-777.
- [7] Abdi, Y., Garavand, A. T., and Sahamieh, R. Z. (2018). "Prediction of strength parameters of sedimentary rocks using artificial neural networks and regression analysis". *Arabian Journal of Geosciences*, 11: 587.
- [8] Ghasemi, E., Kalhori, H., Bagherpour, R., and Yagiz, S. (2018). "Model tree approach for predicting uniaxial compressive strength and Young's modulus of carbonate rocks". *Bulletin of Engineering Geology and the Environment*, 77: 331-343.
- [9] Umrao, R. K., Sharma, L. K., Singh, R., and Singh, T. N. (2018). "Determination of strength and modulus of elasticity of heterogenous sedimentary rocks: An ANFIS predictive technique". *Measurement*, 126: 194-201.
- [10] Mahmoud, A. A., Elkatatny, S., Ali, A., and Moussa, T. (2019). "Estimation of static young's modulus for sandstone formation using artificial neural networks". *Energies*, 12(11): 2125. DOI: <https://doi.org/10.3390/en12112125>.
- [11] Yang, L., Feng, X., and Sun, Y. (2019). "Predicting the Young's Modulus of granites using the Bayesian model

- [org/10.3390/su14063689](https://doi.org/10.3390/su14063689).
- [26] Jin, X., Zhao, R., and Ma, Y. (2022). "Application of a Hybrid Machine Learning Model for the Prediction of Compressive Strength and Elastic Modulus of Rocks". Minerals, 12(12): 1506. DOI: <https://doi.org/10.3390/min12121506>.
- [27] Motiei, H. (2009). "Petroleum geology of the Persian Gulf". Tehran University Press.
- [28] Mehrgini, B., Izadi, H., and Memarian, H. (2019). "Shear wave velocity prediction using Elman artificial neural network". Carbonates and Evaporites, 34: 1281-1291. DOI: <https://doi.org/10.1007/s13146-017-0406-x>.
- [29] Salehinejad, H., Sankar, S., Barfett, J., Colak, E., and Valaee, S. (2017). "Recent advances in recurrent neural networks". arXiv preprint arXiv:1801.01078. DOI: <https://doi.org/10.48550/arXiv.1801.01078>.
- [30] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, L., Wang, G., Cai, J., and Chen, T. (2017). "Recent advances in convolutional neural networks". Pattern Recognition, 77: 354-377. DOI: <https://doi.org/10.1016/j.patcog.10.013>.
- Poisson's Ratio Prediction While Drilling". Computational Intelligence and Neuroscience, 2021: 9956128. DOI: <https://doi.org/10.1155/2021/9956128>.
- [22] Siddig, O., and Elkatatny, S. (2021). "Workflow to build a continuous static elastic moduli profile from the drilling data using artificial intelligence techniques". Journal of Petroleum Exploration and Production Technology, 11: 3713-3722. DOI: <https://doi.org/10.1007/s13202-021-01274-3>.
- [23] Singh, R., Kainthola, A., and Singh, T. N. (2012). "Estimation of elastic constant of rocks using an ANFIS approach". Applied Soft Computing, 12(1): 40-45. DOI: <https://doi.org/10.1016/j.asoc.2011.09.010>.
- [24] Yesiloglu-Gultekin, N., and Gokceoglu, C. (2022). "A Comparison Among Some Non-linear Prediction Tools on Indirect Determination of Uniaxial Compressive Strength and Modulus of Elasticity of Basalt". Journal of Nondestructive Evaluation, 41: 10. DOI: <https://doi.org/10.1007/s10921-021-00841-2>.
- [25] Shahani, N. M., Xigui Zheng, X., Guo, X., and Wei, X. (2022). "Machine Learning-Based Intelligent Prediction of Elastic Modulus of Rocks at Thar Coalfield". Sustainability, 14(6): 3689. DOI: <https://doi.org/10.3390/su14063689>.