

Research Article

Prediction of shear wave velocity using petrophysical logs and deep learning algorithms in a hydrocarbon field in Iran

Farhad Mollaei¹, Ali Moradzadeh¹, Reza Mohebian^{1*}

1- School of Mining Engineering, College of Engineering, University of Tehran, after jalal Al Ahmad St., North Kargar St., Tehran, Iran

Keywords: Shear wave velocity, Petrophysical data, MLP algorithm, CNN+MLP algorithm, LSTM+MLP algorithm

1-Introduction

Understanding and assessing the petrophysical and lithological parameters of oil and gas reservoirs through various well logs is a crucial component of the oil industry, particularly during the exploration and production stages. Compressional waves velocity alone does not adequately characterize formation properties, especially lithology, due to significant overlap in compressional wave velocities across different rocks types. However, the additional insights provided by shear wave velocity can help reduce these associated uncertainties (Mohammadnia et al., 1382). Well-log data is one of the most important sources of information for identifying rock properties in subsurface formations. Seismic wave velocity and other petrophysical data are effective in assessing the properties of rocks and underground fluids. Shear wave velocity is a crucial parameter in geophysical and geomechanical studies and provides valuable information for determining pore pressure, pores fluid types, and the mechanical properties of reservoir rocks. Shear wave velocity is typically measured with DSI tools or trough laboratory testing. However, DSI tools are not recorded in many wells, especially old wells, due to their high cost.

On the other hand, laboratory core measurements are time-consuming and costly, and since the number of cores in wells is limited and discontinuous, they cannot express the properties of subsurface rocks. Therefore, it would be highly beneficial to employ a method capable of rapidly and cost-effectively predicting shear wave velocity along a well's depth. Several methods have been proposed to predict shear wave velocity using log data, among the most notable of which are those developed by Castagna et al. (1985), Eskandari et al. (2004), Pickett (1963) and Coello (2007).

2-Material and methods

In this study, the logs SGR, CGR, DT, RHOB, RT, NPHI, CALIPER, V_p, and PEF were available for estimating shear wave velocity using deep learning algorithms.

To identify the most influential features and appropriate inputs for these algorithms, the correlation coefficient of each feature with the shear wave velocity were evaluated. One method for feature selection is calculating the Pearson correlation coefficient. Based on Pearson's correlation, the V_p, RHOB, NPHI, and CALIPER logs were selected as algorithms inputs, as adding other logs increased error and reduced accuracy. Figure 1 shows feature selection using the Pearson correlation matrix.

In research work, a total of 1633 data points were available, with 204 data points set aside as blind data to validate the algorithm's results. The remaining data were divided into two parts for training and testing purposes. Specially, 80% of the data (1143 data points) were allocated for training, while 20% of the data

* Corresponding author: mohebian@ut.ac.ir

DOI: 10.22055/aag.2024.45698.2426

Received: 2024-01-02

Accepted: 2024-04-29

(286 data points) were designated for testing. To enhance accuracy, data normalization was performed using the Min-Max normalization function, which scales the data zero and one.

The Adam optimizer was used for optimization. Model evaluation and comparison among deep learning algorithms were carried out using RMSE, MSE, MAE error, and the R2 coefficient, with the formulas presented in Equations 1, 2, 3, and 4.

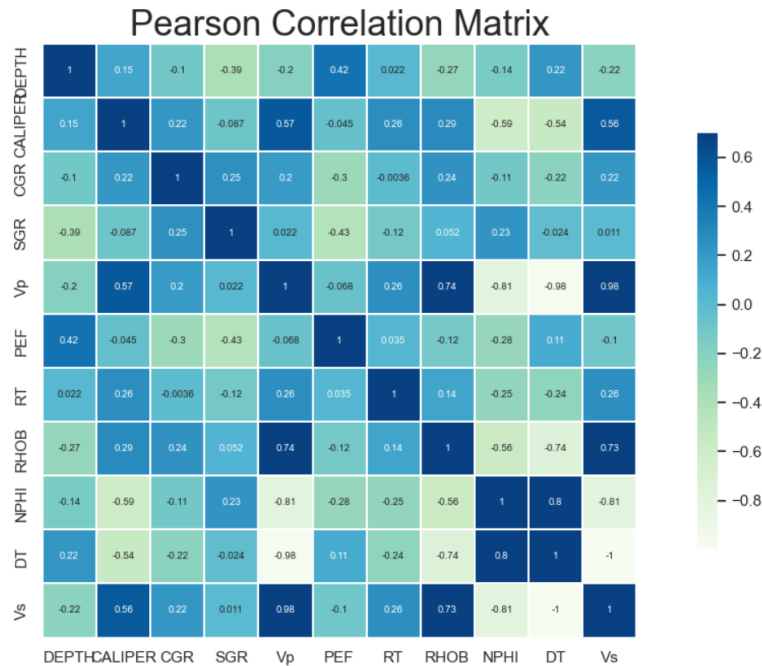


Fig. 1. Selection features using Pearson correlation matrix.

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

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

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

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

3-Results and discussions

This study examined the results of three deep learning algorithms-MLP, LSTM+MLP, and CNN +MLP- by calculating RMSE, MSE, MAE error, and R2 for training, testing, and blind datasets. Table 1 displays the prediction errors and accuracy of shear wave velocity based on the test (20%) subset. Figure 2 compares the predicted and measured shear wave velocity values for both training and test data while Table 2 provides the Vs prediction errors and accuracy results for the blind subsets. Fig. 3, shows the comparison between predicted and measured Vs for blind dataset.

Table 1. Shear wave velocity Prediction errors and accuracy for test data records using a deep learning algorithm.

Deep Learning models	MAE	MSE	RMSE	R ²
MLP	0.0084	0.0001	0.0119	0.9645
LSTM+MLP	0.0067	7.1806e-5	0.0084	0.9821

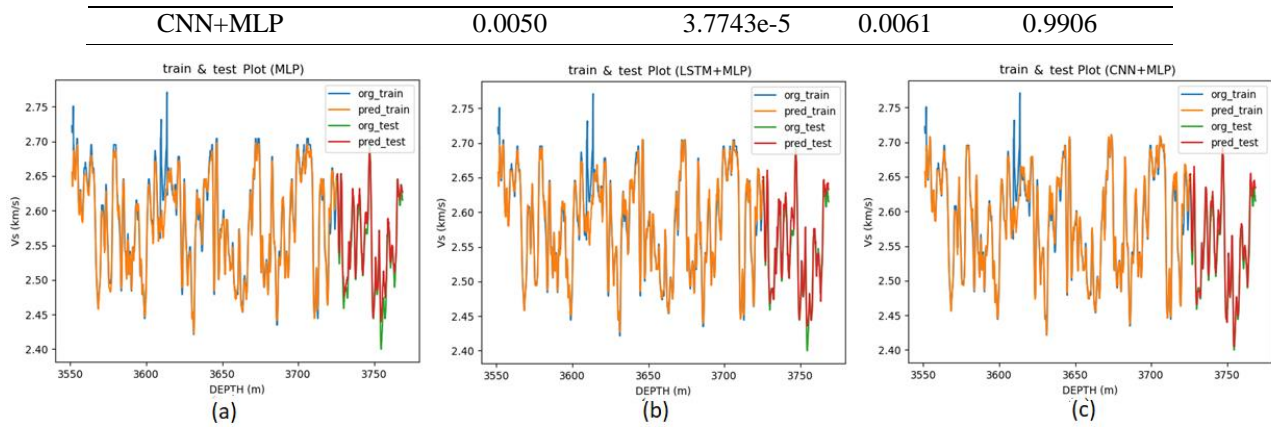


Fig. 2. Display of Vs., predict using deep learning algorithms for train and test data. (a), Vs. Prediction for train and test data using MLP algorithm. (b), Vs prediction using LSTM+MLP. (c), Vs. Prediction using CNN+MLP. Blue log (Vs. measured for training (original data)), orange log (Vs. predicted for training data), green log (Vs. measured for test data (original data)), and red log (Vs. predicted for test data).

Table 2. Vs prediction errors and accuracy for blind data records using deep learning algorithms.

Deep Learning models	MAE	MSE	RMSE	R ²
MLP	0.0185	0.0005	0.0235	0.7989
LSTM+MLP	0.0082	8.8125e-5	0.0093	0.8984
CNN+MLP	0.0052	6.8915e-5	0.0083	0.9032




Fig. 3. Display of Vs. Predicts using deep learning algorithms for blind data. (a), Vs prediction for blind data using MLP algorithm. (b), Vs prediction using LSTM+MLP. (c), Vs. Prediction using CNN+MLP. Blue log (Vs. predicted), orange log (Vs. measured).

4-Conclusion

Considering the importance of shear wave velocity in determining reservoir parameters, rock physics, and geomechanical models and the unavailability of DSI logs in most wells, it is necessary to use a cheap and accurate method to predict shear wave velocity. This study employed deep learning approaches, specially the MLP, LSTM+MLP, and CNN+MLP algorithms - to estimate shear wave velocity, selecting appropriate input features base on Pearson's correlation coefficient. Comparison of results from these three algorithms indicates that LSTM+MLP and CNN+MLP algorithms perform well in predicting shear wave velocity, as they achieve low error rates and acceptable coefficient of determination for both test and blind datasets.

This suggests that they can be effectively used with standard well log data. So, in general, these findings demonstrate that deep learning algorithms provide a reliable method for predicting shear wave velocity

5- References

- Castagna, J.P., Batzle, M.L., Eastwood, R.L., 1985. Relationships between compressional wave and shear-wave velocities in clastic silicate rocks. *Geophysics* 50(4), 571–581. <http://dx.doi.org/10.1190/1.1441933>.
- Coello, C.C., Van Veldhuizen, D.A., Lamont, G.B., 2007. Evolutionary algorithms for solving multiobjective problems. In: Goldberg, E et al. (Eds.), Springer Science & Business Media, Springer New York, pp. 130-441.
- Eskandari, H., Rezaee, M.R., Mohammadnia, M., 2004. Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir, South Iran. *Open Journal of Geology* 4, 42-48.
- Moatazadian, I., Rahimpour-Bonab, H., Kadkhodaie-Ilkhchi, A., & Rajoli, M., 2011. Prediction of shear and Compressional Wave Velocities from petrophysical data utilizing genetic algorithms technique: A case study in Hendijan and Abuzar fields located in Persian Gulf. *Geopersia* 1(1), 1-17. <https://doi.org/10.22059/jgeope.2011.22161>.
- Pickett, GR., 1963. Acoustic character logs and their applications in formation evaluation. *Journal of Petroleum Technology* 15, 659–667. <https://doi.org/10.2118/452-PA>.

HOW TO CITE THIS ARTICLE:

Mollaie, F., Moradzadeh, A, Mohebian, R. 2024. Prediction of Shear Wave Velocity Using Petrophysical Logs and Deep Learning Algorithms in a Hydrocarbon Field in Iran. *Adv. App. Geol.* 14(3), 652-670.

DOI: 10.22055/aag.2024.45698.2426

URL: https://aag.scu.ac.ir/article_19165.html

©2024 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers

پیش‌بینی سرعت موج برشی با استفاده از لاگ‌های پتروفیزیکی و الگوریتم‌های یادگیری عمیق در یکی از میادین هیدروکربنی ایران

فرهاد ملائی

گروه اکتشاف نفت، دانشکده مهندسی معدن، دانشکدگان فنی دانشگاه تهران، دانشگاه تهران، تهران، ایران

علی مرادزاده

گروه اکتشاف نفت، دانشکده مهندسی معدن، دانشکدگان فنی دانشگاه تهران، دانشگاه تهران، تهران، ایران

رضا محبیبان*

گروه اکتشاف نفت، دانشکده مهندسی معدن، دانشکدگان فنی دانشگاه تهران، دانشگاه تهران، تهران، ایران

*mohebian@ut.ac.ir

تاریخ دریافت: ۱۴۰۲/۰۹/۱۴ تاریخ پذیرش: ۱۴۰۲/۱۲/۲۶

چکیده

سرعت موج برشی یکی از مهم‌ترین پارامترهای اثرگذار در مدل‌سازی‌های پتروفیزیکی و ژئومکانیکی است. برای تعیین سرعت موج برشی 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 سرعت موج برشی با استفاده از روش یادگیری عمیق در یکی از چاه‌های مخازن هیدروکربنی جنوب غرب ایران پیش‌بینی شده است. جهت استفاده از روش یادگیری عمیق ابتدا نیاز هست که ویژگی‌های موثر الگوریتم‌ها مشخص شود. در این مقاله از ضریب همبستگی پیرسون برای انتخاب ویژگی‌ها استفاده شد و در ادامه با استفاده از شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی بازگشتی + شبکه عصبی پرسپترون چندلایه (LSTM+MLP)، شبکه عصبی تبدیلی + شبکه عصبی پرسپترون چندلایه (CNN+MLP) سرعت موج برشی تخمین زده شد و مقدار خطا و ضریب تعیین (R^2) برای داده‌های آموزش و تست محاسبه گردید. همچنین جهت اطمینان از نتایج الگوریتم‌ها بخشی از داده به عنوان داده شاهد کنار گذاشته شد و خطا و ضریب تعیین برای این داده‌ها نیز محاسبه گردید که ضریب تعیین $R^2_{MLP} = 0.9032$ ، $R^2_{LSTM+MLP} = 0.8984$ ، $R^2_{CNN+MLP} = 0.7989$ به دست آمده است. نتایج بیانگر بالاتر بودن خطا و کمتر بودن ضریب تعیین مربوط به شبکه MLP نسبت به شبکه‌های LSTM+MLP و CNN+MLP است. با توجه به نتایج حاصل شده می‌توان از روش‌های یادگیری عمیق جهت پیش‌بینی سرعت موج برشی به عنوان روشی مناسب و کم‌هزینه استفاده کرد.

واژه‌های کلیدی: سرعت موج برشی، داده‌های پتروفیزیکی، لاگ DSI ، مخزن آسماری، یادگیری عمیق

۱- مقدمه

داده‌های چاه‌نگاری هستند. سرعت امواج لرزه‌ای در کنار سایر اطلاعات پتروفیزیکی ابزار مناسبی جهت تعیین خواص سنگ‌ها و سیالات زیر زمین هستند. سرعت موج برشی پارامتری کلیدی در مطالعات ژئوفیزیکی و ژئومکانیکی بوده و اطلاعات ارزشمندی برای تعیین فشار منفذی، نوع سیالات موجود در منافذ و تعیین خواص مکانیکی سنگ‌های مخزن فراهم می‌کند. اندازه‌گیری سرعت موج برشی با ابزار DSI یا اندازه‌گیری‌های آزمایشگاهی صورت می‌گیرد که در بسیاری از چاه‌ها، به خصوص چاه‌های قدیمی از ابزار DSI به دلیل هزینه بالا ثبت نمی‌شود. از طرف دیگر مغزه‌ها در اندازه‌گیری آزمایشگاهی زمان‌بر و هزینه‌بر بوده و

شناخت و ارزیابی پارامترهای پتروفیزیکی و سنگ‌شناسی مخازن نفت و گاز با استفاده از نمودارهای مختلف چاه‌پیمایی، امروزه به عنوان یکی از اصلی‌ترین بخش‌های صنعت نفت در مراحل اکتشاف و تولید مخزن محسوب می‌شود. سرعت امواج تراکمی به تنهایی تشخیص دهنده خوبی برای خصوصیات سازندها به ویژه لیتولوژی نیست، زیرا سرعت امواج تراکمی در سنگ‌های مختلف دارای هم‌پوشانی زیادی می‌باشد و اطلاعات اضافی فراهم شده به‌وسیله سرعت امواج برشی می‌تواند ابهامات مربوطه را کاهش دهد (Wong and Nikravesh, 2001). یکی از مهم‌ترین منابع اطلاعاتی جهت تعیین خواص سنگ‌های سازندهای زیرزمین،

موج برشی مطرح شده است که از داده‌های لاگ استفاده می‌کنند که از مهم‌ترین روابط می‌توان به رابطه Castagna و همکاران (۱۹۸۵)، Eskandari و همکاران (۲۰۰۴)، Pickett (۱۹۶۳)، Coello و همکاران (۲۰۰۷) و Brocher (۲۰۰۵) اشاره کرد.

چون تعداد مغزه‌ها در چاه‌ها محدود و به صورت ناپیوسته می‌باشند نمی‌تواند خواص سنگ‌های زیر زمین را به خوبی بیان کند. پس استفاده از روشی که در مدت زمان کم و با هزینه کمتری بتواند سرعت موج برشی را در یک چاه به صورت پیوسته پیش‌بینی کند، ایده‌آل خواهد بود. روش‌هایی برای پیش‌بینی سرعت

جدول ۱- روابط تجربی متداول جهت پیش‌بینی سرعت موج برشی.

Table 1. Common empirical formulas used to predict shear wave velocity.

Model's name	Empirical equation
Pickett, 1963	$V_s = V_p / 1.9$
Castagna et al, 1985	$V_s = 1.0168V_p - 0.05509V_p^2 - 1.0305$
Eskandari et al, 2004	$V_s = 1.612V_p - 0.1236V_p^2 - 2.0357$
Brocher, 2005	$V_s = 0.0064V_p^4 - 0.1238V_p^3 + 0.7949V_p^2 - 1.2344V_p + 0.7758$
Coello et al, 2007	$V_s = 1.09913326V_p^{0.9238115636}$

در جدول ۲ علائم اختصاری به کار رفته در مقاله بیان شده است.

مورچگان برای تخمین سرعت موج برشی استفاده کرد. Bagheripour و همکاران (۲۰۱۵) از رگرسیون بردار پشتیبان جهت پیش‌بینی سرعت موج برشی استفاده کردند. Al-Dousari و همکاران (۲۰۱۶) با استفاده از یادگیری ماشین (GRNN) سرعت موج برشی تخمین زدند. Behnia و همکاران (۲۰۱۷) با یادگیری ماشین (GEP & ANFIS) سرعت موج برشی را تخمین زدند. Mehrgini و همکاران (۲۰۱۹) با یادگیری ماشین (MLP & ENN) سرعت موج برشی را تخمین زدند. Zhang و همکاران (۲۰۲۰) با یادگیری عمیق (LSTM) سرعت موج برشی را تخمین زدند. Gholami و همکاران (۲۰۲۰) با یادگیری ماشین (ONN, OFIS, OSVR & CM LSSVM) سرعت موج برشی را پیش‌بینی کردند. Ghorbani و همکاران (۲۰۲۱) با یادگیری ماشین (GA) سرعت موج برشی را پیش‌بینی کردند. Ebrahimi و همکاران (۲۰۲۲) با استفاده از یادگیری ماشین (الگوریتم‌های MGGP, ANFIS, MLP-ANN) و داده‌های چاه سرعت موج برشی را تخمین زدند. Rajabi و همکاران (۲۰۲۲) با استفاده از یادگیری ماشین (الگوریتم‌های MLP و ELM) و داده نمودارهای پتروفیزیکی سرعت موج برشی را تخمین زدند. Gholami و همکاران (۲۰۲۲) با استفاده از یادگیری ماشین (الگوریتم شبکه عصبی مصنوعی، منطق فازی و نروفازی) و لاگ‌های پتروفیزیکی سرعت موج برشی کند و تند را پیش‌بینی کردند. Nasrnia و همکاران (۲۰۲۳) با ترکیب روش‌های هوشمند و مدل‌های فیزیکی سنگی سرعت موج برشی را پیش‌بینی کردند. روش‌های هوشمند شامل شبکه عصبی (NN)، منطق فازی (FL)، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) می‌باشد. در این مطالعه سه

در سال‌های اخیر استفاده از روش‌های هوشمند در پیش‌بینی مسائل مهندسی نفت به صورت چشمگیری افزایش یافته است. Huang و همکاران (۲۰۰۱) از منطق فازی و الگوریتم‌های ژنتیک و شبکه‌های عصبی برای پیش‌بینی تراوایی در مخازن نفتی استفاده کردند. Bhatt و Helle (۲۰۰۲) با استفاده از نمودارهای چاه-پیمایی و به کمک شبکه‌های عصبی تداخل و تراوایی را پیش‌بینی کردند. Eskandari و همکاران (۲۰۰۴) جهت تخمین سرعت موج برشی از رگرسیون چندگانه و شبکه عصبی مصنوعی استفاده کردند. Rezaee و همکاران (۲۰۰۷) با استفاده از یادگیری ماشین (FL, ANN, ANFIS) سرعت موج برشی را پیش‌بینی کردند. Rajabi و همکاران (۲۰۱۰) از روش‌های هوشمند برای پیش‌بینی سرعت موج برشی و استونلی براساس داده‌های چاه‌نگاری استفاده کردند. Abdulraheem و Anifowose (۲۰۱۱) با استفاده از روش‌های هوشمند منطق فازی و رگرسیون بردار پشتیبان تداخل و تراوایی را پیش‌بینی کردند. Moatazedian و همکاران (۲۰۰۱) سرعت موج برشی و تراکمی را با استفاده از الگوریتم ژنتیک پیش‌بینی کردند. Asoodeh و Bagheripour (۲۰۱۲) از شبکه‌های عصبی مصنوعی، منطق فازی و نروفازی برای پیش‌بینی سرعت موج برشی استفاده کردند. Maleki و همکاران (۲۰۱۴) از ترکیب رگرسیون بردار پشتیبان و شبکه‌های عصبی برای پیش‌بینی سرعت موج برشی استفاده کردند. Gholami و همکاران (۲۰۱۴) با استفاده از روش‌های یادگیری ماشین (MLP) سرعت موج برشی را پیش‌بینی کردند. Akhundi و همکاران (۲۰۱۴) به کمک یادگیری ماشین (ANN) سرعت موج برشی را پیش‌بینی کردند. KadkhodaeiIlkhachi (۲۰۱۵) از الگوریتم بهینه‌ساز کلونی

الگوریتم یادگیری عمیق شامل MLP, LSTM+MLP, CNN+MLP جهت پیش‌بینی سرعت موج برشی استفاده شده است. هدف از این مطالعه ارائه الگوریتمی برای پیش‌بینی سرعت موج برشی و مقایسه این نتایج با یکدیگر است، که نتایج بیان‌کننده کاربرد الگوریتم‌های یادگیری عمیق برای تخمین سرعت موج برشی می‌باشد.

جدول ۲- علائم اختصاری.

Table 2. Abbreviation signs.

AI: Artificial intelligence
ANFIS: Adaptive neuro-fuzzy inference system
ANN: Artificial neural network
ASR: Automatic speech recognition
BPANN: Backpropagation artificial neural network
CHAL: Caliper log
CNL: Compensate neutron log
CNN: Convolutional neural network
DL: Deep learning
DNN: Deep neural network
DT: Acoustic (sonic) log
ELM: Extreme learning machine
ENN: Elman neural network
FFANN: Feedforward artificial neural network
FL: Fuzzy logic
GA: Genetic algorithm
GEP: Gene expression programming
GR: Gamma ray log
GRA: Grey relational analysis LSTM Long short-term memory networks
GRG: Generalized reduced gradient
GRNN: General regression neural network
LSSVM: Least-squares support-vector machines
LSTM: Long short-term memory networks
MAE: Mean absolute error
MAPE: Mean absolute percentage error
MF: Memetic firefly
ML: Machine learning technique
MLEM: Multi extreme learning machine
MLP: Multi-layer perceptron
MLP-ANN: Multi-layer perceptron artificial neural network
MSE: Mean square error
MGGP: Multi-gene genetic programming
NARX: Nonlinear autoregressive network with exogenous inputs
NRMSE: Normalized Root Mean Squared Error
OFIS: Optimized fuzzy inference
ONN: Optimized neural network
OSVR: Optimized support vector regression
PSO: Particle swarm optimization
R ² : Coefficient of determination
RHOB: Density log
RMSE: Root mean square error
RNN: Recurrent neural network
RS: Shallow lateral resistivity log
RT: Formation true resistivity
SFIS: Surgeon's fuzzy inference
SML: Single machine learning
SVM: Support vector machine
SVR: Support vector regression
Vs: Shear wave velocity
Vp: Compressional wave velocity

۲- زمین شناسی

۱-۲- زمین شناسی منطقه مورد مطالعه

داده‌های مورد استفاده مربوط به یکی چاه‌های یکی از میادین هیدروکربنی در جنوب غرب ایران می‌باشد. این میدان توسط شرکت اکتشاف و تولید نفت ایران کشف شد و یکی از بزرگ‌ترین میدان‌های نفتی حوضه زاگرس است، که در بخش خاوری منطقه ساختاری فروافتادگی دزفول قرار دارد. این میدان با روند شمال غربی-جنوب شرقی در قسمت غربی تا مرکزی و روند شمال شرقی جنوب غربی، در قسمت انتهایی شرقی، امتداد یافته است. تاقدیس این میدان دارای بیشینه شیب ۴۵-۶۵ درجه در یال جنوب باختری و ۲۰-۴۵ درجه در یال شمال خاوری است. فاصله میان ستیغ مخزن و ژرف‌ترین سطح تماس آب و نفت در سازند آسماری حدود ۲۰۰۰ متر است. ساختار این میدان در نیمرخ‌های عرضی متنوع است، به طوری که در دماغه شمال-باختری متقارن و در کوهانه باختری به سوی مرکز نامتقارن با بیشینه شیب حدود ۷۰ درجه و به سوی شمال خاور تا دماغه خاوری حالت نیمه متقارن به خود گرفته است. این تغییر شکل ساختار، نشان‌دهنده تنوع سازوکار چین‌خوردگی در این تاقدیس است. همچنین نیمرخ‌های لرزه‌ای سازوکار چین-خوردگی این تاقدیس را از نوع هم‌مرکز نشان می‌دهند که از سطح به ژرفا با کاهش فضای موجود در اثر چین‌خوردگی همراه بوده است. این کاهش فضا با گسلش در یال جنوبی همراه بوده که شیب گسل به تدریج کم شده تا این که به سطح جدایشی تاقدیس منتهی می‌شود. رخنمون سطحی این میدان، سازند آغاچاری بوده و سازندهای آسماری و گروه‌های بنگستان و خامی، مخازن هیدروکربوری موجود در این میدان می‌باشند. سازند آسماری مهم‌ترین سنگ مخزن این میدان است، که خود به ۶ لایه مخزنی تقسیم شده‌است. لایه‌های مخزنی یک، دو، سه به‌طور عمده از کربنات‌های دولومیتی تشکیل شده‌اند، بنابراین تراکم شکستگی‌ها به ویژه در لایه یک (۹۰ درصد دولومیت) بیشتر است. در لایه‌های مخزنی چهار، پنج و شش این میدان، به دلیل افزایش لایه‌های شیلی و مارنی، همچنین کاهش شکنندگی، تراکم شکستگی‌ها کمتر می‌شود (Motiei, 2009; Serkati and Letouzey, 2004). به منظور افزایش ظرفیت برداشت نفت خام از این میدان، به‌طور متوسط روزانه ۲۵ میلیون متر مکعب گاز، از طریق ایستگاه تزریق گاز به مخزن آسماری این میدان تزریق می‌شود. داده‌های موجود در یکی از

چاه‌های این میدان جهت تخمین سرعت موج برشی شامل لاگ-های گامای طبیعی (SGR)، گامای تصحیح شده (CGR)، زمان موج صوتی تراکمی (DT)، لاگ چگالی (RHOB)، لاگ مقاومت ویژه (RT)، لاگ نوترون (NPHI)، لاگ قطرسنجی (CALIPER)، لاگ سرعت موج فشاری (Vp)، لاگ سرعت موج برشی (VS) و لاگ فوتوالکتریک (PEF) می‌باشد که در محدوده عمقی ۳۵۴۸/۲۶ تا ۳۷۹۹/۷۸ متری قرار دارند. در شکل ۱، لاگ‌های موجود در چاه موردنظر ترسیم شده‌اند.

۳- روش تحقیق

۱-۳- شبکه عصبی پرسپترون چندلایه

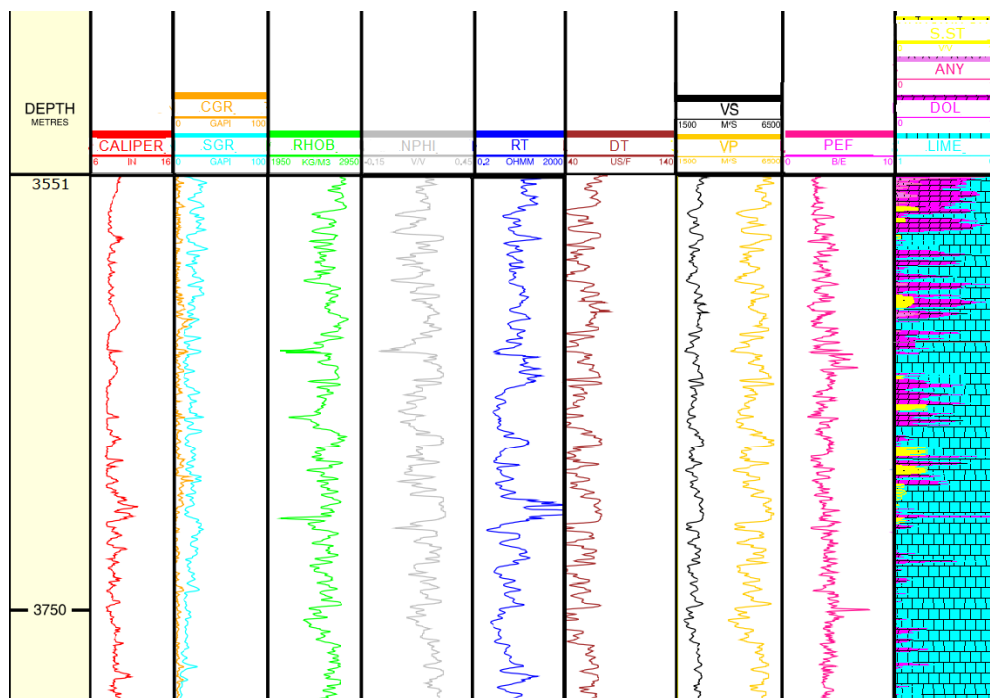
شبکه عصبی پرسپترون چند لایه، دسته‌ای از شبکه‌های عصبی مصنوعی پیشخور محسوب می‌شوند. در یک شبکه عصبی پرسپترون چندلایه، حداقل سه لایه گره‌ها وجود خواهند داشت: لایه ورودی، لایه پنهان، لایه خروجی. گره‌های شبکه عصبی که به آنها نرون گفته می‌شود، واحدهای محاسباتی در یک شبکه عصبی محسوب می‌شوند. در این شبکه عصبی، از خروجی‌های لایه اول (ورودی)، به عنوان ورودی‌های لایه بعدی (پنهان) استفاده می‌شوند؛ 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 خروجی قرار می‌گیرد لایه پنهان گفته می‌شود (Alavi et al, 2010). شبکه‌های پرسپترون چند لایه حاوی مجموعه‌ای از وزن‌ها نیز هستند که باید برای آموزش و یادگیری شبکه عصبی تنظیم شوند. شکل ۲، شماتیکی از شبکه عصبی پرسپترون چندلایه را نشان می‌دهد.

۲-۳- شبکه عصبی بازگشتی

شبکه عصبی بازگشتی یک شبکه عصبی است که خروجی هر سلول نه تنها به لایه‌های پیشین مربوط می‌شود، بلکه خروجی هر سلول ورودی خودش را نیز تغذیه می‌کند؛ به عبارت دیگر، شبکه بازگشتی با استفاده از یک حلقه بازگشتی این امکان را به وجود می‌آورد تا اطلاعات به دست آمده (آخرین وضعیت) توسط شبکه در پایان هر محاسبه برای محاسبات آتی مورد استفاده قرار گیرد. شکل ۳، معماری یک نرون در شبکه عصبی بازگشتی را نشان می‌دهد که دارای یک ورودی در لحظه t و x_t و یک ورودی دیگر $ht-1$ است. $ht-1$ در حقیقت خروجی این سلول شبکه عصبی در لحظه $t-1$ (آخرین خروجی نرون) بوده است.


بر روی آن انجام شده است. شکل ۴، ساختار یک بلاک LSTM که شامل سه دروازه ورودی، خروجی و فراموشی می شود را نشان می دهد. خروجی بلاک LSTM به صورت بازگشتی به ورودی بلاک و ورودی سه گیت نامبرده شده متصل می شود. توابع فعال سازی در گیت های ورودی و خروجی معمولاً تابع تانژانت هذلولی است و تابع فعال سازی در گیت فراموشی تابع سیگموئید است. اتصالات غیرنقطه چین شامل اتصالات غیروزن دار هستند و اتصالات نقطه چین دار همگی وزن دار هستند.

یکی از مشکلات شبکه های عصبی بازگشتی، ناتوانی آنها در یادگیری وابستگی بلندمدت است. برای رفع این مشکل هوچریتز و اشمیت هوبر (Hochreiter & Schmidhuber, 1997)، یک معماری برای شبکه های عصبی بازگشتی پیشنهاد کردند که به معماری حافظه طولانی کوتاه مدت (LSTM) معروف شد و قادر بود تا نقصان فراموشی ذکر شده را جبران کند (Hochreiter & Schmidhuber, 1997). از زمان معرفی معماری LSTM تاکنون بهبودهایی در راستای افزایش کارایی




شکل ۱- لاگ های موجود در چاه. از چپ به راست: ستون ۱: Depth، ستون ۲: SGR و CGR، ستون ۳: RHOB، ستون ۴: NPHI، ستون ۵: RT، ستون ۶: DT، ستون ۷: Vp و Vs، ستون ۸: PEF و ستون ۹: Lithology.

Fig 1. The logs in the well. From left to right: column 1: Depth, column 2: CGR and SGR, column 3: RHOB, column 4: NPHI, column 5: RT, column 6: DT, column 7: Vp and Vs, column 8: PEF, column 9: Lithology.




شکل ۲- شماتیک شبکه MLP (Alavi et al, 2010).

Fig. 2. Schematic diagram of MLP (Alavi et al, 2010).



شکل ۳- ساختار یک نرون در شبکه عصبی بازگشتی (Greff et.al, 2017).

Fig 3. The structure of a neuron in a recurrent neural network (Greff et.al, 2017).



شکل ۴- ساختار یک بلاک LSTM (Greff et.al, 2017).

Fig 4. The structure of an LSTM block (Greff et.al, 2017).


۳-۳- شبکه عصبی تبدیلی

این روش در دهه‌های ۱۹۸۰ و ۱۹۹۰ معرفی شد. اگرچه، شبکه عصبی تبدیلی برای مدتی به دست فراموشی سپرده شد، با این حال از سال ۲۰۱۲ و با اصلاح شبکه عصبی تبدیلی (CNN or ConvNet)، پیشرفت زیادی در اکثر حوزه ماشین داشته و با سرعت زیادی در حال گسترش است (Geo & Liu, 2015). از مزایای روش CNN می‌توان به کاهش تعداد پارامترهای وزن به کمک مفهوم اشتراک گذاری وزن‌ها اشاره کرد. همچنین در تولید ویژگی‌ها در این روش، همسایگی‌های یک پیکسل در نظر گرفته می‌شود که با فرض یکسان بودن خواص آماری پیکسل‌های یک بخش در تصاویر سازگار است (Guo et al, 2015). در شبکه‌های عصبی چندلایه پرسپترون نورون‌ها به صورت کامل با یکدیگر متصل هستند و با افزایش بعد تصاویر،

تعداد اتصالات و پارامترهای آزاد بسیار زیاد شده و در نتیجه داده‌های آموزشی بسیار حجیمی لازم خواهد بود. بنابراین ممکن است در طول آموزش به دلیل متناسب نبودن تعداد نمونه‌های آموزشی، مشکل بیش‌برازش رخ دهد (Lecun et al, 1998). همچنین شبکه‌های عصبی چندلایه پرسپترون در برابر نویز مقاومتی از خود نشان نمی‌دهند. یکی از مهم‌ترین نقاط ضعف شبکه‌های عصبی MLP عدم ارائه مکانیزمی برای تولید خودکار ویژگی است. با توجه به مشکلات MLP روش‌هایی در قالب CNN ارائه شده است (Zeiler and Fergus, 2014). CNN از سه لایه کانولوشن، پولینگ و اتصال کامل تشکیل شده است. لایه کانولوشن از کانولوشن تصویر ورودی به کمک ناحیه‌های دریافت محلی به وجود می‌آید و در این لایه مفهوم سلسله مراتبی بودن و به شی نزدیک شدن تحقق پیدا می‌کند. حرکت

عمق خروجی همان عمق ورودی به لایه پولینگ می‌باشد و تغییری نمی‌کند. روش‌های مختلفی برای اعمال پولینگ وجود دارد، اما روش‌های میانگین‌گیری و انتخاب ماکزیمم با کاهش نسبت دو و تابع فعال‌سازی Relu از رایج‌ترین روش‌ها هستند. 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 CNN فراهم می‌کند (Benigo et al, 1994). توابع فعال-سازی انواع متفاوتی دارند. چند نمونه از معروف‌ترین توابع فعال-سازی، تابع سیگموئید، تابع تانژانت هایپربولیک، تابع یکسوساز خطی رلو، تابع خطی نمایی و سافت‌مکس است. شکل ۵، نمونه-ای از پردازش تصویر توسط شبکه عصبی کانولوشن را نشان می‌دهد.

فیلتر یا فیلترها بر روی باندهای ورودی به شکل تاگل مومنت است (Gu et al, 2018). تعیین تعداد فیلتر بانک‌ها و لایه‌های کانولوشن و تنظیم پارامترهای آن از چالش‌های موجود است. در لایه پولینگ، کاهش سایز تصویر انجام می‌شود. علت اصلی اعمال این اپراتور، کاهش حجم محاسبات و تضمین ناورد (invariant) بودن ویژگی‌ها نسبت به سایز تصویر است (Yoo, 2015). علاوه بر مزیت فوق، غیرخطی بودن ویژگی‌های تولید شده در مرحله کانولوشن به کمک تابع فعال‌سازی در لایه پولینگ صورت می‌گیرد. عملیات پولینگ، کاهش سایز را در امتداد ابعاد مکانی انجام می‌دهد که نتیجه این کار، یک توده با اندازه کوچکتر خواهد بود. در اصل از طریق این عملیات است که در انتهای شبکه کانولوشن یک بردار امتیاز ایجاد می‌شود. به دلیل اینکه این عملیات بر روی تمامی برش‌ها اعمال می‌گردد،



شکل ۵- پردازش تصویر توسط روش CNN (Kuo and Huang, 2018).


Fig 5. Image processing by CNN method (Kuo and Huang, 2018).

توجهی رسید. ضریب همبستگی پیرسون 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 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 لاگ‌های V_p , CALIPER, NPHI, RT, RHOB, DT, CGR, SGR, PE و V_s در دسترس بودند. شکل ۷، انتخاب ویژگی‌های موثر از طریق ماتریس همبستگی پیرسون را نشان می‌دهد. با توجه به شکل ۷، و با توجه به همبستگی پیرسون لاگ‌های V_p , CALIPER, NPHI, RHOB, به عنوان ورودی الگوریتم‌ها انتخاب شدند و اضافه کردن لاگ‌های دیگر باعث افزایش خطا و کاهش دقت می‌شود.

۴-۲- پیش‌بینی سرعت موج برشی با استفاده از روش یادگیری عمیق

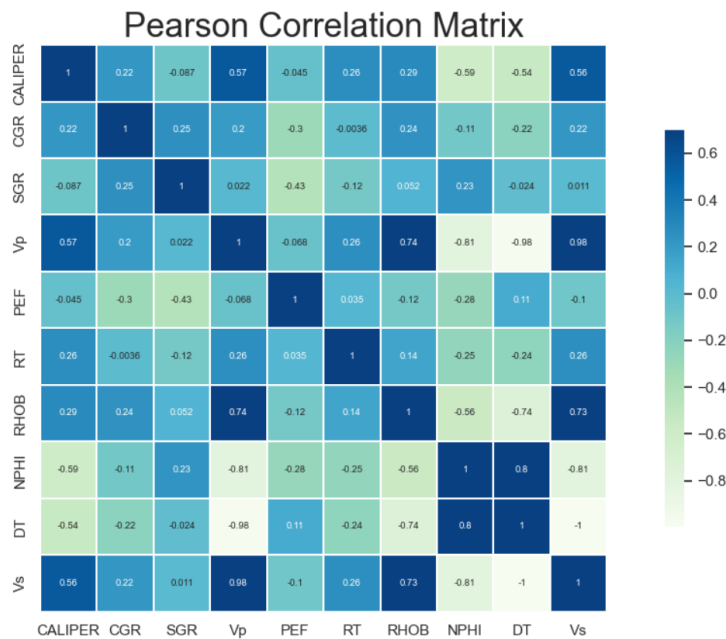
در این مقاله داده‌های RT, RHOB, DT, CGR, SGR, CALIPER, NPHI, V_p , PE و V_s برای تعیین سرعت موج برشی با استفاده از الگوریتم‌های یادگیری عمیق در دسترس بودند. فلوجارت پیش‌بینی سرعت موج برشی با استفاده از روش یادگیری عمیق در شکل ۶، نمایش داده شده است.

برای انتخاب ویژگی‌های موثر و ورودی‌های مناسب به الگوریتم‌ها باید ضریب همبستگی ویژگی‌ها را با سرعت موج برشی 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



شکل ۶- فلوجارت پیش‌بینی سرعت موج برشی با استفاده از روش یادگیری عمیق.

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



شکل ۷- انتخاب ویژگی‌ها از طریق ماتریس همبستگی پیرسون.

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

(R^2) استفاده شده است که روابط آنها مطابق معادلات ۱، ۲، ۳ و ۴ می‌باشد.

(رابطه ۱)

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z_{measured} - Z_{predict}|$$

(رابطه ۲)

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

(رابطه ۳)

$$RMSE = \sqrt{MSE}$$

(رابطه ۴)

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

در ادامه کل داده‌ها ۱۶۳۳ داده بودند و از ابتدا ۲۰۴ داده به عنوان داده شاهد جهت اطمینان از نتایج الگوریتم کنار گذاشته شد و بقیه داده که به دو قسمت آموزش و تست تقسیم شدند که ۸۰٪ داده‌ها (۱۱۴۳ داده) به آموزش و ۲۰٪ داده‌ها (۲۸۶ داده) به تست تقسیم شدند. در مرحله بعد 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 الگوریتم‌های یادگیری عمیق از میانگین قدرمطلق خطا (MAE)، میانگین مربعات خطا (MSE)، جذر میانگین مربعات خطا (RMSE) و ضریب تعیین

۴- نتایج

برای داده‌های تست و شاهد RMSE, MSE, MAE و R2 محاسبه گردیده است. پارامترهایی که برای سه الگوریتم یادگیری عمیق استفاده شده است مطابق جدول ۳، به شرح زیر می‌باشد:

در این مقاله نتایج سه الگوریتم یادگیری عمیق شامل MLP, LSTM+MLP و CNN+MLP مورد بررسی قرار گرفتند و

جدول ۳- پارامترهای مشترک مربوط به الگوریتم‌های یادگیری عمیق.

Table 3. Common parameters related to deep learning algorithms.

Algorithm	MLP	LSTM+MLP	CNN+MLP
Parameter			
Bath_size	50	50	50
learning rate	0.0001	0.001	0.0001
Iteration	400	200	200
Validation_split	0.1	0.1	0.1
Optimization function	Adam	Adam	Adam

شکل (۸-۱)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم CNN+MLP می‌باشد. نمودار آبی رنگ (سرعت موج برشی اندازه‌گیری شده داده آموزش)، نمودار نارنجی رنگ (سرعت موج برشی پیش‌بینی شده داده آموزش)، نمودار سبز رنگ (سرعت موج برشی اندازه‌گیری شده داده تست) و نمودار قرمز رنگ (سرعت موج برشی پیش‌بینی شده داده تست) است.

شکل ۹، مقایسه سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده داده‌های تست با استفاده از الگوریتم‌های MLP، LSTM+MLP و CNN+MLP نشان داده است. شکل (۹-۱)، سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم MLP برای داده‌های تست، شکل (۹-۲)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم LSTM+MLP و شکل (۹-۳)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم CNN+MLP می‌باشد. نمودار آبی رنگ مربوط به داده‌های تست سرعت موج برشی اندازه‌گیری شده و نمودار نارنجی رنگ مربوط به داده‌های تست سرعت موج برشی پیش‌بینی شده می‌باشد. با توجه به شکل ۹ و جدول ۴، بالاترین خطا و کمترین دقت مربوط به الگوریتم MLP و کمترین خطا و بالاترین دقت مربوط به CNN+MLP می‌باشد. پارامترهای محاسبه شده برای الگوریتم MLP برابر است با: $MAE=0.0084$ ، $MSE=0.0001$ ، $RMSE=0.0119$ ، $R2=0.9645$ و پارامترهای محاسبه شده برای الگوریتم CNN+MLP برابر است با: $MAE=0.0050$ ، $MSE=3.7743e-5$ ، $RMSE=0.0061$ ، $R2=0.9906$

سایر پارامترهای مربوط به الگوریتم MLP: تعداد لایه‌های پنهان دو لایه که در لایه اول تعداد گره‌ها ۱۰۰ و در لایه دوم تعداد گره‌ها ۲۰۰ در نظر گرفته شده است و از تابع فعال‌ساز Relu استفاده شده است.

سایر پارامترهای مربوط به الگوریتم LSTM+MLP: در این الگوریتم از دو لایه پنهان مربوط به LSTM که در لایه اول ۱۰۰ گره و در لایه دوم ۲۰۰ گره قرار دارد و در ادامه بعد از این دو لایه، دو لایه مربوط به Dense که لایه اول دارای ۱۰۰ و لایه دوم دارای ۲۰۰ گره می‌باشد.


سایر پارامترهای مربوط به الگوریتم CNN+MLP: در این الگوریتم سه لایه CNN که لایه اول دارای ۶۴ فیلتر، لایه دوم ۱۲۸ فیلتر، لایه سوم ۲۵۶ فیلتر و اندازه کرنل برابر ۲، و تعداد گام برابر ۱ و padding=same انتخاب گردید. بعد از سه لایه CNN دو لایه Dense قرار دارد که لایه اول دارای ۱۰۰ گره و لایه دوم دارای ۲۰۰ گره می‌باشد.

جدول ۴، MAE، MSE، RMSE و R2 برای داده‌های تست جهت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم‌های روش یادگیری عمیق نمایش داده است. شکل ۸، سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های آموزش و تست با استفاده از الگوریتم‌های MLP، LSTM+MLP و CNN+MLP نشان داده است. شکل (۸-۱)، سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم MLP برای داده‌های آموزش و تست، شکل (۸-۲)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم LSTM+MLP و

جدول ۴- محاسبه خطاها و ضریب تعیین داده‌های تست جهت پیش‌بینی سرعت موج برشی.


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

Models	MAE	MSE	RMSE	R ²
MLP	0.0084	0.0001	0.0119	0.9645
LSTM+MLP	0.0067	7.1806e-5	0.0084	0.9821
CNN+MLP	0.0050	3.7743e-5	0.0061	0.9906



شکل ۸- پیش‌بینی سرعت موج برشی داده آموزش و تست با استفاده روش یادگیری عمیق. (a) با استفاده از الگوریتم MLP، (b) با استفاده از الگوریتم LSTM+MLP و (c) با استفاده از الگوریتم CNN+MLP. نمودار آبی رنگ (سرعت موج برشی اندازه‌گیری شده داده آموزش)، نمودار نارنجی رنگ (سرعت موج برشی پیش‌بینی شده داده آموزش)، نمودار سبز رنگ (سرعت موج برشی اندازه‌گیری شده داده تست) و نمودار قرمز رنگ (سرعت موج برشی پیش‌بینی شده داده تست).

Fig 8. Display of Vs predict using deep learning algorithms for train and test data. (a) Vs prediction for train and test data using MLP algorithm, (b) Vs prediction using LSTM+MLP and (c) Vs prediction using CNN+MLP. Blue log (Vs measured for training (original data)), orange log (Vs predicted for training data), green log (Vs measured for test data (original data)), red log (Vs predicted for test data).



شکل ۹- پیش‌بینی سرعت موج برشی داده تست با استفاده روش یادگیری عمیق. (a) با استفاده از الگوریتم MLP، (b) با استفاده از الگوریتم LSTM+MLP و (c) با استفاده از الگوریتم CNN+MLP. نمودار آبی رنگ مربوط به داده‌های تست سرعت موج برشی اندازه‌گیری شده و نمودار نارنجی رنگ مربوط به داده‌های تست سرعت موج برشی پیش‌بینی شده می‌باشد.

Fig 9. Display of Vs predict using deep learning algorithms for test data. (a), Vs prediction for train and test data using MLP algorithm. (b), Vs prediction using LSTM+MLP. (c), Vs prediction using CNN+MLP. Blue log (Vs measured), orange log (Vs predicted).

برداشت نشده است می‌باشد. به همین دلیل جهت اطمینان از نتایج الگوریتم‌ها بخشی از داده‌ها از ابتدا به عنوان داده شاهد

هدف از این مطالعه بررسی الگوریتم‌های یادگیری عمیق برای پیش‌بینی سرعت موج برشی در چاه‌هایی که لاگ DSI


مربوط به داده‌های شاهد سرعت موج برشی اندازه‌گیری شده می‌باشد. شکل ۱۱، ضریب تعیین سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده داده‌های شاهد با استفاده از الگوریتم‌های MLP، LSTM+MLP و CNN+MLP نشان داده است. شکل (۱۱-ا)، ضریب تعیین سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم MLP برای داده‌های شاهد، شکل (۱۱-ب)، ضریب تعیین سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم LSTM+MLP و شکل (۱۱-ج)، ضریب تعیین سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم CNN+MLP می‌باشد. با توجه به شکل ۱۰ و جدول ۵، بالاترین خطا و کمترین دقت مربوط به الگوریتم MLP و کمترین خطا و بالاترین دقت مربوط به CNN+MLP می‌باشد. پارامترهای محاسبه شده برای الگوریتم MLP برابر است با: $MAE=0.0185$, $MSE=0.0005$, $RMSE=0.0235$, $R^2=0.7989$ و پارامترهای محاسبه شده برای الگوریتم CNN+MLP برابر است با: $MAE=0.0052$, $MSE=6.8915e-5$, $RMSE=0.0083$, $R^2=0.9032$.

کنار گذاشته شد که در نهایت جهت پیش‌بینی سرعت موج برشی به الگوریتم داده شود و سرعت موج برشی پیش‌بینی شده با سرعت موج برشی اندازه‌گیری شده مقایسه شود. جهت انجام این مراحل از پارامترهای MAE , MSE , $RMSE$ و R^2 استفاده شده است. جدول ۵، MAE , MSE , $RMSE$ و R^2 برای داده‌های شاهد جهت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم‌های روش یادگیری عمیق (MLP)، LSTM+MLP و CNN+MLP نمایش داده است. شکل ۱۰، مقایسه سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده داده‌های شاهد با استفاده از الگوریتم‌های MLP، LSTM+MLP و CNN+MLP نشان داده است. شکل (۱۰-ا)، سرعت موج برشی پیش‌بینی شده با استفاده از الگوریتم MLP برای داده‌های شاهد، شکل (۱۰-ب)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم LSTM+MLP و شکل (۱۰-ج)، پیش‌بینی سرعت موج برشی با استفاده از الگوریتم CNN+MLP می‌باشد. نمودار آبی رنگ مربوط به داده‌های شاهد سرعت موج برشی پیش‌بینی شده و نمودار نارنجی رنگ

جدول ۵- محاسبه خطاها و ضریب تعیین داده‌های شاهد جهت پیش‌بینی سرعت موج برشی.

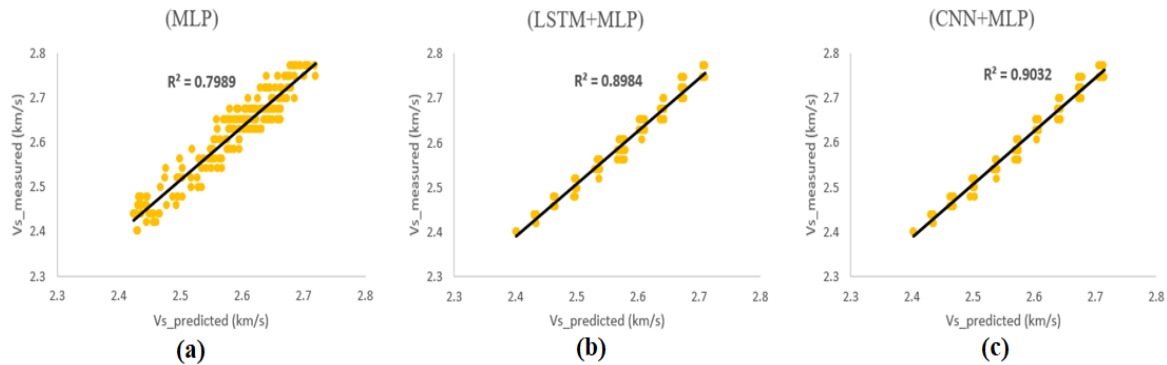
Table 5. Vs Prediction errors and accuracy for blind data records.

Models	MAE	MSE	RMSE	R ²
MLP	0.0185	0.0005	0.0235	0.7989
LSTM+MLP	0.0082	8.8125e-5	0.0093	0.8984
CNN+MLP	0.0052	6.8915e-5	0.0083	0.9032



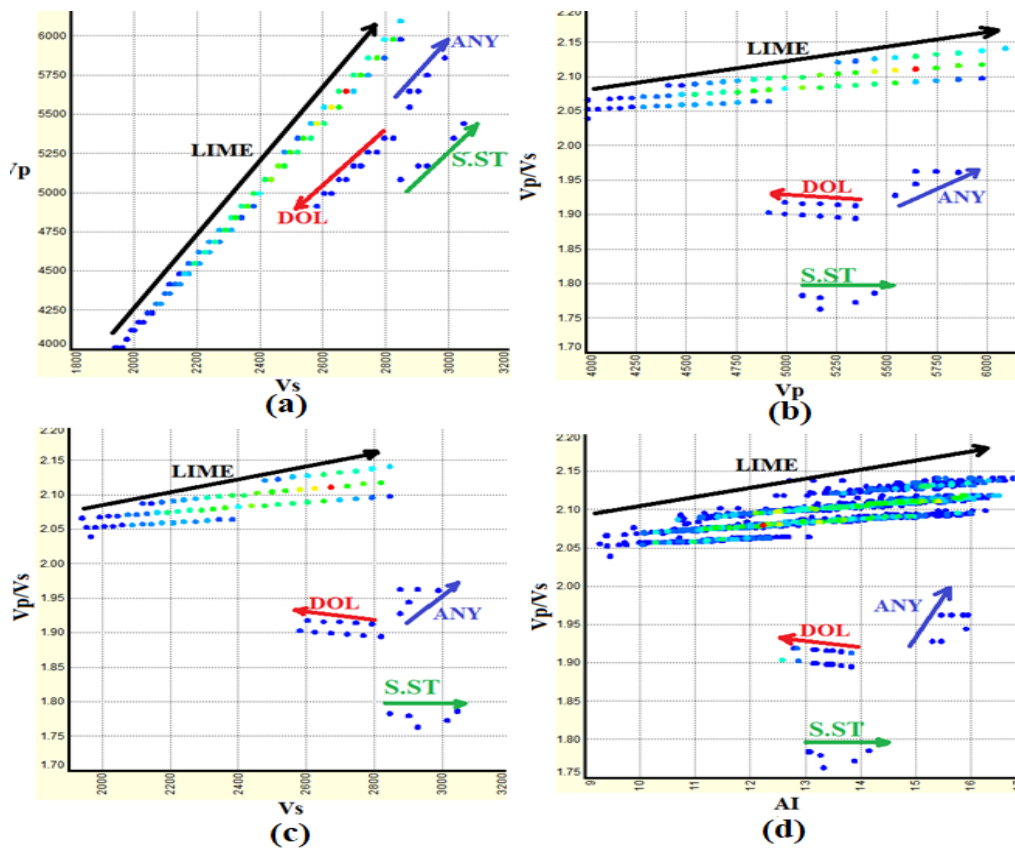
شکل ۱۰- پیش‌بینی سرعت موج برشی داده شاهد با استفاده روش یادگیری عمیق. (a) با استفاده از الگوریتم MLP، (b) با استفاده از الگوریتم LSTM+MLP و (c) با استفاده از الگوریتم CNN+MLP. نمودار آبی رنگ مربوط به داده‌های شاهد سرعت موج برشی پیش‌بینی شده و نمودار نارنجی رنگ مربوط به داده‌های شاهد سرعت موج برشی اندازه‌گیری شده می‌باشد.

Fig 10. Display of Vs predict using deep learning algorithms for test data. (a) Vs prediction for train and test data using MLP algorithm, (b) Vs prediction using LSTM+MLP and (c) Vs prediction using CNN+MLP. Blue log (Vs measured), orange log (Vs predicted).



شکل ۱۱- ضریب تعیین سرعت موج برشی اندازه‌گیری شده و سرعت موج برشی پیش‌بینی شده داده‌های شاهد با استفاده از روش یادگیری عمیق. (a) با استفاده از الگوریتم MLP، (b) با استفاده از الگوریتم LSTM+MLP و (c) با استفاده از الگوریتم CNN+MLP.

Fig 11. Display of coefficient of determination of blind data for Vs measured and Vs predicted using four deep learning algorithms. (a) R2 using MLP algorithm, (b) R2 using LSTM+MLP algorithm and (c) R2 using CNN+MLP algorithm.



شکل ۱۲- تفکیک لیتولوژی به کمک سرعت موج برشی. (a) تفکیک لیتولوژی به کمک پلات سرعت موج فشاری (Vp) در مقابل سرعت موج برشی (Vs)، (b) تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل Vp، (c) تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل Vs و (d) تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل امپدانس صوتی (AI).

Fig 12. Identification of lithology using shear wave velocity. (a) Vp – Vs plot, (b) Vp/Vs ratio – Vp plot, (c) Vp/Vs ratio – Vs plot and (d) Vp/Vs ratio – AI (Acoustic Impedance) plot.

لیتولوژی با استفاده از سرعت موج فشاری و برشی و نسبت سرعت‌های فشاری و برشی و مقاومت صوتی (AI) بررسی شده

یکی از کاربردهای مهم سرعت موج برشی کمک در شناسایی و تفکیک لیتولوژی می‌باشد. در شکل ۱۲ تفکیک

۵- نتیجه گیری

با توجه به اهمیت بسیار زیاد سرعت امواج برشی در تعیین پارامترهای مخزنی و مدل‌های فیزیک‌سنگی و ژئومکانیکی و در دسترس نبودن لاگ DSI در اکثر چاه‌ها، استفاده از روشی ارزان و در عین حال دقیق جهت پیش‌بینی سرعت امواج برشی لازم و ضروری است. به همین منظور در این مطالعه از روش یادگیری عمیق و الگوریتم‌های MLP، LSTM+MLP و CNN+MLP برای تخمین سرعت موج برشی با استفاده از داده‌های نمودارهای پتروفیزیکی در یکی از میادین هیدروکربنی ایران استفاده شده است. در این مطالعه ابتدا ویژگی‌های مناسب جهت ورودی‌های الگوریتم‌ها با استفاده از ضریب همبستگی پیرسون مشخص گردید که لاگ‌های Vp, RHOB, NPHI، CALIPER به عنوان ورودی انتخاب شدند. در ادامه تقسیم داده‌ها به بخش‌های آموزش و تست و شاهد و نرمال‌سازی داده‌ها انجام شد و در نهایت ارزیابی مدل‌ها (MSE, MAE, RMSE و R2) محاسبه گردید. مقایسه نتایج به دست آمده از این سه الگوریتم نشان‌دهنده آن است که الگوریتم‌های LSTM+MLP و CNN+MLP نسبت به الگوریتم MLP دارای عملکرد مناسب‌تری جهت پیش‌بینی سرعت امواج برشی می‌باشند، چراکه خطای به دست آمده و ضریب تعیین حاصل از آن‌ها مقادیر قابل قبولی برای داده‌های آموزش، تست و شاهد به دست آمده است و به سادگی با در اختیار داشتن لاگ‌های متداول قابل استفاده است. پس به‌طور کلی می‌توان گفت الگوریتم‌های روش یادگیری عمیق، روشی کارآمد برای پیش‌بینی سرعت موج برشی می‌باشد.

است. در شکل (۱۲-ا)، تفکیک لیتولوژی به کمک پلات سرعت موج فشاری (Vp) در مقابل سرعت موج برشی (Vs)، شکل (۱۲-ب)، تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل Vp، شکل (۱۲-ج)، تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل Vs، شکل (۱۲-د)، تفکیک لیتولوژی به کمک پلات نسبت سرعت موج فشاری به سرعت موج برشی (Vp/Vs) در مقابل امپدانس صوتی (AI) نمایش داده شده است. با توجه به شکل ۱۲، لیتولوژی‌های موجود شامل آهک (LIME)، انیدریت (ANY)، دولومیت (DOL) و ماسه‌سنگ (S.ST) می‌باشد که به کمک سرعت موج برشی به خوبی قابل تفکیک می‌باشند.

مقایسه نتایج حاصل از الگوریتم‌های روش یادگیری عمیق جهت پیش‌بینی سرعت موج برشی با استفاده از لاگ‌های متداول، نشان می‌دهد که برای داده‌های تست مقادیر خطا تقریباً نزدیک به هم بوده اما مقایسه نتایج حاصل از الگوریتم‌های روش یادگیری عمیق برای داده‌های شاهد حکایت از برتری الگوریتم‌های LSTM+MLP و CNN+MLP نسبت به الگوریتم MLP دارد و خطای بالاتر و دقت کمتری در الگوریتم MLP نسبت به دو الگوریتم دیگر به دست آمده است. پس با توجه به نتایج این مطالعه می‌توان روش یادگیری عمیق و الگوریتم‌های مطرح شده جهت پیش‌بینی سرعت موج برشی با استفاده از لاگ‌های متداول را به کار گرفت.

مراجع

- Akhundi, H., Ghafoori, M., Lashkaripour, G.R., 2014. Prediction of shear wave velocity using artificial neural network technique. multiple regression and petrophysical data: A case study in Asmari reservoir (SW Iran). *Open Journal of Geology* 4, 303-313. <https://doi.org/10.4236/ojg.2014.47023>.
- 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. *Journal of Plant Nutrition and Soil Science* 173, 368-379. <https://doi.org/10.1002/jpln.200800233>.
- Al-Dousari, M., Garrouch, A., Al-Omair, O., 2016. Investigating the dependence of shear wave velocity on petrophysical parameters. *Journal of Petroleum Science and Engineering* 146, 286-296. <https://doi.org/10.1016/j.petrol.2016.04.036>.
- Anifowose, F., Abdurraheem, A., 2011. Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization. *Journal of Natural Gas Science and Engineering* 3, 505-517. <https://doi.org/10.1016/j.jngse.2011.05.002>.
- Asoodeh, M., Bagheripour, P., 2012. Prediction of compressional, shear, and stonely wave velocities from conventional well log data using a committee machine with intelligent systems. *Rock Mechanics and Rock Engineering* 45, 45-63. <https://doi.org/10.1007/s00603-011-0181-2>.

- Bagheripour., P., Gholami., A., Asoodeh., M., Vaezzadeh-Asadi., M., 2015. Support vector regression-based determination of shear wave velocity. *Journal of Petroleum Science and Engineering* 125, 95-99. <https://doi.org/10.1016/j.petrol.2014.11.025>.
- Behnia, D., Ahangari, K., Moeinossadat, S.R., 2017. Modeling of shear wave velocity in limestone by soft computing methods. *International Journal of Mining Science and Technology* 27, 423-430. <https://doi.org/10.1016/j.ijmst.2017.03.006>.
- Bengio, Y., Simard, P., Frasconi, P., 1994. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*. *Neural Network* 2, 157-166. <https://doi.org/10.1109/72.279181>.
- Bhatt, A., & Helle, H. B., 2002. Committee neural networks for porosity and permeability prediction from well logs. *Geophysical Prospecting* 50(6), 645-660. <https://doi.org/10.1046/j.1365-2478.2002.00346>.
- Brocher, T.M., 2005. Empirical relations between elastic wave speeds and density in the Earth's crust. *Bulletin of the Seismological Society of America* 95, 2081-2092. <https://doi.org/10.1785/0120050077>.
- Castagna, J.P., Batzle, M.L., Eastwood, R.L., 1985. Relationships between compressional wave and shear-wave velocities in clastic silicate rocks. *Geophysics* 50(4), 571-581. <http://dx.doi.org/10.1190/1.1441933>.
- Coello, C.C., Van Veldhuizen, D.A., Lamont, G.B., 2007. Evolutionary algorithms for solving multiobjective problems. In: Goldberg, E et al. (Eds.), Springer Science & Business Media, Springer New York, pp. 130-441.
- Ebrahimi, A., Izadpanahi, A., Ebrahimi, P., Ranjbar, A., 2022. Estimation of shear wave velocity in an Iranian oil reservoir using machine learning methods. *Journal of Petroleum Science and Engineering* 209, February 2022, 109841. <https://doi.org/10.1016/j.petrol.2021.109841>.
- Eskandari, H., Rezaee, M.R., Mohammadnia, M., 2004. Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir, South Iran. *Open Journal of Geology* 4, 42-48.
- Gholami Vijouyeh, A., Kadkhodaie, A., Hassanpour Sedghi, M., 2022. A committee machine with intelligent experts (CMIE) for estimation of fast and slow shear wave velocities utilizing petrophysical logs. *Computers & Geosciences* 165, 105-149. <https://doi.org/10.1016/j.cageo.2022.105149>.
- Gholami, A., Seyedali, S.M., Ansari, H.R., 2020. Estimation of shear wave velocity from post-stack seismic data through committee machine with cuckoo search optimized intelligence models. *Journal of Petroleum Science and Engineering* 189, <https://doi.org/10.1016/j.petrol.2020.106939>.
- Gholami, R., Moradzadeh, A., Rasouli, V., Hanachi, J., 2014. Shear wave velocity prediction using seismic attributes and well log data. *Acta Geophysica* 62, 818-848. <https://doi.org/10.2478/s11600-013-0200-7>.
- Ghorbani, H., Davoodi, S., Davarpanah, A., 2021. Accurate determination of shear wave velocity using LSSVM-GA algorithm based on petrophysical log. *European Association of Geoscientists & Engineers, Third EAGE Eastern Mediterranean Workshop 2021*, 1 - 3. <https://doi.org/10.3997/2214-4609.202137015>.
- 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. <https://doi.org/10.1109/TNNLS.2016.2582924>.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahrousy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., Chen, T., 2018. Recent advances in convolutional neural networks. *Pattern Recognition* 77, 354-377. <https://doi.org/10.1016/j.patcog.10.013>.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., and Lew, M. S., 2015. Deep learning for visual understanding: A review. *Neurocomputing* 187, 27-48, <https://doi.org/10.1016/j.neucom.2015.09.116>.
- Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural Comput* 9(8), 1735-1780.
- Huang, Y., Gedeon, T.D., & Wong, P.M., 2001. An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs. *Engineering Applications of Artificial Intelligence* 14(1), 15-21. [https://doi.org/10.1016/S0952-1976\(00\)00048-8](https://doi.org/10.1016/S0952-1976(00)00048-8).
- Kadkhodaie-Ilkhchi, A., 2015. A systematic approach for estimation of reservoir rock properties using Ant Colony Optimization. *Geopersia* 5, 7-17. <https://doi.org/10.7508/GEOP.2015.01.002>.
- Kuo, P., Huang, C., 2018. An electricity price forecasting model by hybrid structured deep neural networks. *Sustainability* 10, 1280. <https://doi.org/10.3390/su10041280>.

- Lecun, Y., Bottou, L., Bengio, L. and Haffner, P., 1998. Gradient -based learning applied to document recognition, *Proceedings of the IEEE* 86(11), 2278 –2324. <https://doi.org/10.1109/5.72679>.
- Maleki, Sh., Moradzadeh, A., Ghavami Riabi, R., Gholami, R., Sadeghzadeh, F., 2014. Prediction of shear wave velocity using empirical correlations and artificial intelligence methods. *NRIAG Journal Astron Geophysics* 3, 70–81. <https://doi.org/10.1016/j.nrjag.2014.05.001>.
- Mehrgini, B., Izadi, H., Memarian, H., 2019. Shear wave velocity prediction using Elman artificial neural network. *Carbonates Evaporites* 34(4), 1281–1291. <https://doi.org/10.1007/s13146-017-0406>.
- Moatazadian, I., Rahimpour-Bonab, H., Kadkhodaie-Ilkhchi, A., & Rajoli, M., 2011. Prediction of shear and Compressional Wave Velocities from petrophysical data utilizing genetic algorithms technique: A case study in Hendijan and Abuzar fields located in Persian Gulf. *Geopersia* 1(1), 1-17. <https://doi.org/10.22059/jgeope.2011.22161>.
- Motiei, H., 2009. *Petroleum geology of the Persian Gulf*. Tehran University Press. P. 707.
- Nasrnia, B., Falahat, R., Kadkhodaie, A., Gholami Vijouyeh, A., 2023. A committee machine-based estimation of shear velocity log by combining intelligent systems and rock-physics model using metaheuristic algorithms 126, Part A, November 2023, 106821. <https://doi.org/10.1016/j.engappai.2023.106821>.
- Pickett, GR., 1963. Acoustic character logs and their applications in formation evaluation. *Journal of Petroleum Technology* 15, 659–667. <https://doi.org/10.2118/452-PA>.
- Rajabi, M., Bohloli, B., Gholampour Ahangar, E., 2010. Intelligent approaches for prediction of compressional, shear and Stoneley wave velocities from conventional well log data: A case study from the Sarvak carbonate reservoir in the Abadan Plain (Southwestern Iran). *Computers & Geosciences* 36, 647–664. <https://doi.org/10.1016/j.cageo.2009.09.008>.
- Rajabi, M., 2022a. Prediction of Shear Wave Velocity by Extreme Learning Machine Technique from Well Log Data. *Journal of Petroleum Geomechanics* 4, 18–35. <https://doi.org/10.22107/JPG.2022.298520.1151>.
- Rezaee, MR., Kadkhodaie, A., Barabadi, A., 2007. Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia. *Journal of Petroleum Science and Engineering* 55, 201–212. <https://doi.org/10.1016/j.petrol.2006.08.008>.
- Sherkati, S., Letouzey, J., 2004. Variation of structural style and basin evolution in the central Zagros (Izeh zone and Dezful Embayment), Iran: *Marine and Petroleum Geology* 21, 535-554. <https://doi.org/10.1016/j.marpetgeo.2004.01.007>.
- Wong, P.M. and Nikravesh M., 2001. Field applications of intelligent computing techniques: *Journal of petroleum geology* 24(4), 381-387. <https://doi.org/10.1111/j.1747-5457.2001.tb00681.x>.
- Yoo, H.J., 2015. Deep Convolution Neural Networks in Computer Vision: A Review. *IEIE Transactions on Smart Processing and Computing* 4, 35 –43. <https://doi.org/10.5573/IEIESPC.2015.4.1.035>.
- Zeiler, M.D., Fergus, R., 2014. Visualizing and Understanding Convolutional Networks. In: Fleet, D et al. (Eds.), *Springer International Publishing Switzerland*, New York University, PP. 818-833.
- Zhang, Y., Zhong, H.R., Wu, Z., Zhou, H., Ma, Q., 2020. Improvement of petrophysical workflow for shear wave velocity prediction based on machine learning methods for complex carbonate reservoirs. *Journal of Petroleum Science and Engineering* 192, 107234. <https://doi.org/10.1016/j.petrol.2020.107234>.