



Petroleum Research

Petroleum Research, 2023(August-September), Vol. 33, No. 130, 20-23

DOI:10.22078/PR.2023.4890.3185

Determining the Characteristics of the Porous Media for a Carbonate Rock using Micro CT Scan Images Assisted by Convolutional Neural Network

Sara Shirafkan, Mohammad Ahmadi* and Mehdi Shabani

Petroleum Engineering Department, Amirkabir University of Technology, Tehran, Iran

m.ahmady@aut.ac.ir

DOI:10.22078/PR.2023.4919.3198

Received: July/17/2022

Accepted: March/28/2023

Introduction

Correctly determining petrophysical parameters and flow characteristics in porous media is crucial to hydrology, environmental engineering, and petroleum engineering. For the last two decades, it has been suggested to extract the network structure (topology) and model the fluid flow from the rock pores. Numerous studies have been conducted along this path, and based on recent advancements, it has been discovered that it is possible to prepare three-dimensional images of the rocks in such a way that the porous space can be extracted and accurately modeled the rock's real porous space [1]. With a precision of under ten or one hundred nanometers (the size of each voxel), non-destructive X-ray micro-computed tomography is regarded as one of the top technologies in the field of imaging and creating a correct perspective of the physical processes and fluid flow in the porous space of the rock, taking the rock samples photographs [2]. Image segmentation is regarded as a crucial stage that can have a significant impact on the findings of the digital rocks study. This stage assigns the number one to points that are part of the grain and zero to points deemed pore. Specific computational algorithms, including direct simulation (finite element method, finite volume, and

lattice Boltzmann method [3]), are recommended for calculating the properties of the rock's porous space. In this technique, the algorithms mentioned above, which discretize the rock's pores, are directly applied to images, frequently demanding a high computational volume. There is an alternative method, called algorithms for extracting the rock network model, in which a network of the internal structure of the rock is initially extracted, along with associated parameters like the pores and throats radius, followed by the relevant equations are applied to the obtained network to determine the current characteristics. The pore space of rocks must be transformed into a network of wide pores joined by narrower void spaces known as throats to extract the pores network [1]. Numerous attempts have been made in recent decades to extract the pores network from 3D images. The multi-orientation scanning method, medial axis-based method, Voronoi diagram-based method, and maximal ball method are the major algorithms.

One of the drawbacks of the digital rock analysis method is the extensive computational workload it entails. Hence, to mitigate both the computational load and processing time, artificial intelligence and machine learning techniques, particularly deep learning

methods, have been employed to attain accurate results more efficiently [4]. Machine learning stands as one of the prevailing techniques within the realm of artificial intelligence [5]. In recent years, it has made substantial strides in the realm of tackling and resolving intricate problems. Despite their notable predictive accuracy, machine learning methods necessitate the extraction of features from images and cannot be directly applied to digital images. Consequently, this requirement leads to substantial time and computational resource demands. The Convolutional Neural Network (CNN) represents a prominent subset of deep learning, serving as a specialized form of artificial neural network. Notably, it has garnered significant interest in recent years, particularly within the domain of visual recognition, owing to its ability to be directly applied to images. In the past, research efforts have been dedicated to the domain of computing and ascertaining petrophysical properties and parameters from digital images through the utilization of Convolutional Neural Networks (CNNs). In their study, Sudakov et al. [6] investigated the efficiency of several deep and machine learning methods, including convolutional neural network, in the direction of permeability estimation using 3D sandstone samples. The permeability of the samples was calculated using the network modeling method. The results of the study have shown that the convolutional neural network method is the best and most efficient method among the used algorithms. A limitation of this approach is that the study exclusively employed a single homogeneous sandstone sample. In homogeneous rock formations, there exists a slight dispersion in permeability among various samples under investigation. Moussa Tembely et al. [4] conducted an assessment of the efficacy of various deep and machine learning techniques for permeability estimation, employing 3D samples of carbonate rock. Due to the limited number of samples used for training, the Convolutional Neural Network (CNN) method was found to be less acceptable when compared to alternative methods. In the study conducted by Naïf AL Qahtani et al. [7], three distinct types of sandstone, namely Brea, Bentheimer, and Gosford, were utilized. They generated 2D images with dimensions of 1282 (128 x 128) and computed various structural parameters of the network, including porosity, specific surface area, and average pore size distribution. The efficiency of the 2D neural network was assessed, and the error in the calculated values was found to be less than 6%.

Consequently, this study utilized a heterogeneous carbonate rock, extending upon previous experiments. In this investigation, three-dimensional convolutional neural networks were leveraged as predictive tools to estimate essential parameters, including porosity, average pore size, average throat size, average connection number, and average pore shape factor.

These parameters hold significant importance in the determination and computation of flow-related properties such as permeability, capillary pressure, and more. In summary, this study employed both the convolutional neural network and the maximal ball algorithm to compare their computational efficiency in calculating certain values. Broadly, the study is divided into two main sections:

1. Image Preparation and Network Extraction: The first section involves preparing images for model computation and training. Subsequently, techniques were applied to extract the porous space network from each image, each with dimensions of 100x100x100. This step aims to determine the essential parameters that serve as outputs for the model.

2. Convolutional Neural Network Model: The second section focuses on the design and construction of a convolutional neural network model. This model is employed to train and test the data prepared in the previous step.

Materials and Methods

Data set

The model employed in this study was evaluated using a sample of carbonate rock cores referred to as C1 [1] (Figure 1). C1 is composed of fossiliferous wackestone or packstone. The prototype, with a precision level and voxel size of 2.85 micrometers, is available in dimensions of 400x400x400 voxels, which are the three-dimensional counterparts of pixels. This particular rock sample exhibits a porosity of 23% and an average connection number of 3. In this pre-segmented rock sample, each individual rock voxel has been assigned zero (representing pore space) or one (representing solid grain material).




Fig. 1 C1 carbonate rock with dimensions 400×750×750 and accuracy 2.875 μm [1]; b) 3D image of C1 carbonate rock segmented with dimensions 400×400×400 voxels, where black color denotes granular component and white color denotes pores.

Methods

In this section, explanations are given in relation to how to prepare images for investigating and training the network, as well as how to extract data and characteristics from images. Additionally, it delves into aspects related to the performance of the convolutional neural network (CNN) and the procedure for its implementation.

Images Preparation

Using MATLAB software and employing a step size of 15 voxels, the aforementioned rock sample was transformed into a set of images and cubes, each with dimensions of 100x100x100. This process was carried out to create a diverse dataset for training the deep learning algorithm, resulting in a total of 9,261 samples. To ensure diversity within this dataset, it was essential for these images to exhibit variations, and the characteristics extracted from them should not be identical. This diversity is crucial for effectively training the network to handle a wide range of data.

Additionally, it was important for the size and dimensions of the obtained images to be smaller than the Representative Volume Element (RVE) of the rock C1. The RVE represents the minimum volume and dimensions required for the rock properties to be representative of the entire rock. This decision was made to create a dataset with diverse pore space characteristics.

According to Peyman Mostaghimi et al. [8], the resulting volume from the 100x100x100 voxel dimensions is indeed smaller than the RVE for this type of rock. Consequently, the characteristics inferred from these images differ, allowing each of these smaller samples to be assessed and examined as if it were a distinct rock sample.

Rock's Structural Network Extraction

In this study, a pore network extraction code [9] based on the maximal ball method was utilized to extract the structural properties of the rock for each individual sample. The algorithm's foundation is rooted in the work of Dong and Blunt [1]. Specifically, the proposed algorithm incorporates Stages 1 and 2 from Raini's study to calculate porosity and other pertinent parameters.

After sampling and converting the original image into 9,261 samples, the maximal ball method was applied to each of the transformed images, each with dimensions of 100x100x100, using MATLAB software. This process yielded a range of parameters, including porosity, pore size, throat size, connection number, and pore shape factor, all of which were obtained from the algorithm.

Convolutional Neural Network

The convolutional layer, pooling layer, and fully connected layer are the three main layers that make up a convolutional neural network. Different layers execute different duties [10]. The convolutional layer is accountable for feature extraction from the images, the pooling layer is employed to decrease dimensions and features, and the fullyconnected layer is utilized as a classification layer at the end. Random elimination layers have been utilized to avoid network overfitting. During training, the neural network layer's neurons or,

more precisely, its outputs are randomly ignored by the random elimination regularization method. The error function is a measurement that assesses how suitable the model is in terms of its capacity and competence to forecast new values. Mean squared error (MSE), one of the most well-known and popular error functions in regression analysis, is the error function used in this model. The optimizer function chosen in this model, Adam (adaptive moment estimation), modifies the network parameters (weights and biases) by applying the pertinent relations while considering the error function's derivative. Furthermore, Distribution of the average probability density function of five characteristics generated from the maximal ball method for the training, validation, and testing sets is shown in Figure 2.




Fig. 2 Distribution of the average probability density function of five characteristics generated from the maximal ball method for the training, validation, and testing sets.

Conclusions

In this research, the rock's physical parameters have been estimated using a three-dimensional convolutional neural network. A set of micro CT scan images of a carbonate rock sample were utilized to train and test the model. Five physical properties of the rock, such as porosity, average throat size, average pore size, average connection number, and average pore shape factor, have first been calculated for each image using network extraction algorithms. To test and evaluate the network, the number of layers and the proper value of the learning rate were determined based on the trend and the value of the error function after the convolutional neural network had been trained using the input images and their relevant features. The coefficient of determination and the relative error rate for porosity are calculated to be 99% and 4.2%, respectively, for the average throat size are 90.2% and 3.8%, for the average pore size are 94.5% and 2.6%, for the average connection number are 93.6%

and 3.9%, and for the average pore shape coefficient are 75.3% and 3.4% after evaluating and calculating the characteristics of the set of test data images. When calculating the average connection number, average pore size, and average porosity, which are 20%, 7%, and 5%, respectively, the results from this study are significantly superior to those from Al-Qahtani's manuscript. The results suggest that the convolutional neural network has great potential for assessing the physical characteristics of digital rocks and that this potential can be increased in order to decrease the physical parameters of the rocks. Since this network is believed to be modeled solely on one type of rock, it will naturally produce accurate and logical results in the shortest amount of time when calculating the physical parameters of further samples of the same type of rock. To provide a thorough evaluation of the properties of all types of rocks, future research can use multiple different rock samples, including carbonate and sandstone, at the same time as input to the network. Additionally, the convolutional neural network's potential and efficiency can be assessed in image segmentation as well as in the estimation of more complex petrophysical parameters, such as the permeability and formation factor. Therefore, more complex convolutional neural network models can be used to enhance the network's efficiency.

References

1. Dong, H., & Blunt, M. J. (2009). Pore-network extraction from micro-computerized-tomography images. *Physical review E*, 80(3), 036307, doi.org/10.1103/PhysRevE.80.036307.
2. Niu, Y., Mostaghimi, P., Shabaninejad, M., Swietojanski, P., & Armstrong, R. T. (2020). Digital rock segmentation for petrophysical analysis with reduced user bias using convolutional neural networks. *Water Resources Research*, 56(2), e2019WR026597, doi.org/10.1029/2019WR026597.
3. Raeini, A. Q., Bijeljic, B., & Blunt, M. J. (2017). Generalized network modeling: Network extraction as a coarse-scale discretization of the void space of porous media, *Physical Review E*, 96(1), 013312, doi.org/10.1103/PhysRevE.96.013312.
4. Tembely, M., & AlSumaiti, A. (2019, November). Deep learning for a fast and accurate prediction of complex carbonate rock permeability from 3D micro-CT images, In Abu Dhabi International Petroleum Exhibition & Conference. OnePetro, doi.org/10.2118/197457-MS.
5. Shokri S., Sadeghi M. T. & Ahmadi Marudost M. (2012). Presenting the combined method of data pre-processing in the regression vector machine to predict the quality of refined diesel, *Naft Research*, 75,; 23 pages 116-102.
6. Sudakov, O., Burnaev, E., & Koroteev, D. (2019). Driving digital rock towards machine learning: Predicting permeability with gradient boosting and deep neural networks. *Computers & geosciences*, 127, 91-98, doi.org/10.1016/j.cageo.2019.02.002.
7. Alqahtani, N., Alzubaidi, F., Armstrong, R. T., Swietojanski, P., & Mostaghimi, P. (2020). Machine learning for predicting properties of porous media from 2d X-ray images. *Journal of Petroleum Science and Engineering*, 184, 106514, doi.org/10.1016/j.petrol.2019.106514.
8. Mostaghimi, P., Blunt, M. J., & Bijeljic, B. (2013). Computations of absolute permeability on micro-CT images. *Mathematical Geosciences*, 45, 103-125.
9. Jackson, S. J., Niu, Y., Manoorkar, S., Mostaghimi, P., & Armstrong, R. T. (2022). Deep learning of multiresolution x-ray micro-computed-tomography images for multiscale modeling. *Physical Review Applied*, 17(5), 054046, doi.org/10.1103/PhysRevApplied.17.054046.
10. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.

تعیین خصوصیات فضای متخلخل یک سنگ کربناته با استفاده از تصاویر میکرو سی تی اسکن توسط الگوریتم شبکه عصبی پیچشی

سارا شیرافکن، محمد احمدی* و مهدی شعبانی
دانشکده مهندسی نفت، دانشگاه صنعتی امیرکبیر، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۰۶/۲۴ تاریخ پذیرش: ۱۴۰۲/۰۱/۰۸

چکیده

در این مطالعه، عملکرد شبکه عصبی پیچشی در مشخصه سازی فضای متخلخل سنگ مورد ارزیابی قرار گرفته است. جهت آموزش شبکه، مجموعه ای از تصاویر میکرو سی تی اسکن سه بعدی از زیر نمونه های یک سنگ کربناته C1 با خصوصیات فیزیکی مربوطه اعم از تخلخل، متوسط اندازه گلوگاه، متوسط اندازه منافذ، متوسط عدد پیوستگی و متوسط ضریب شکل منافذ فراهم گردیده است. تصویر به کار برده شده از نمونه سنگ کربناته جهت آماده سازی مجموعه تصاویر ورودی، به ۹۲۶۱ تصویر به ابعاد $100 \times 100 \times 100$ واکسل تقسیم شده است و سپس با بهره گیری از الگوریتم کره بیشینه محاطی برای هر نمونه، خصوصیات نام برده به دست آمده است. در ادامه با تقسیم بندی مجموعه داده به دست آمده به سه بخش آموزش، ارزیابی و آزمایش (۷۵:۱۵:۱۰)، شبکه طراحی شده از جهت تعداد لایه و نرخ یادگیری مورد مقایسه و ارزیابی قرار گرفته است. سپس بعد از آزمایش شبکه بر روی مجموعه داده های آزمایش، ضریب تعیین پارامترها به ترتیب ذکر شده، ۹۹٪، ۹۰٪، ۹۴٪، ۹۳٪ و ۷۵٪ و میانگین درصد خطای نسبی برای هر یک از خصوصیات کمتر از ۴٪ محاسبه شده است. از این رو باتوجه به نتایج حاصل شده می توان نتیجه گرفت که تطابق خوبی میان مقادیر پیش بینی شده و مقادیر واقعی خصوصیات موجود است.

کلمات کلیدی: شبکه عصبی پیچشی، تصاویر میکرو سی تی اسکن، سنگ کربناته، نرخ یادگیری، ضریب تعیین.

مقدمه
بلکه در هیدرولوژی و مهندسی محیط زیست، امری بسیار مهم و حیاتی است. در دو دهه اخیر با توجه به زمان بر بودن روش های آزمایشگاهی، استخراج ساختار شبکه و مدل سازی جریان سیال از منافذ سنگ مطرح می شود، در طی این مسیر تحقیقات فراوانی انجام شده است و بر اساس پیشرفت های

تعیین درست پارامترهای پتروفیزیکی و خصوصیات جریان در محیط متخلخل نه تنها در مهندسی نفت

آخر، تهیه تصاویر سه بعدی از سنگ‌ها به صورتی که بتوان فضای متخلخل واقعی سنگ را به درستی استخراج و مدل سازی کرد، مورد توجه قرار گرفت [۱]. پرتونگاری میکرو محاسباتی^۱ غیرمخرب اشعه ایکس، به عنوان یکی از فناوری‌های پیشرو در زمینه تصویربرداری و ایجاد یک دید درست از فرآیندهای فیزیکی و جریان سیالات در فضای متخلخل سنگ، شناخته شده است و با دقتی در حدود کمتر از ۱۰ nm یا ۱۰۰ nm (اندازه هر واکسل^۲)، از نمونه‌های سنگی، عکس برداری می‌کند [۲]. در مطالعه سنگ‌های دیجیتالی، بخش بندی^۳ تصویر گامی مهم محسوب می‌شود که می‌تواند تأثیر عمیقی بر نتایج داشته باشد. در این مرحله به نقاطی که جزء دانه محسوب می‌شوند عدد یک و نقاطی که فضای خالی محسوب می‌شوند عدد صفر نسبت داده می‌شود. در جهت محاسبه خصوصیات فضای متخلخل سنگ، الگوریتم‌های محاسباتی مشخصی پیشنهاد می‌شوند: شبیه سازی مستقیم (روش المان محدود، حجم محدود و روش شبکه بولتزمن^۴) [۳]، در این روش، الگوریتم‌های مذکور با گسسته سازی فضای خالی سنگ، مستقیماً بر تصاویر اعمال می‌شوند که اغلب به حجم محاسباتی بالایی نیازمند هستند. از این رو یک روش جایگزین، الگوریتم‌های استخراج مدل شبکه سنگ، هستند که ابتدا، یک شبکه‌ای از ساختار داخلی سنگ همراه با پارامترهای وابسته از جمله اندازه منافذ و گلوگاه‌ها استخراج می‌شود و سپس جهت محاسبه خصوصیات جریانی، معادلات مربوطه بر شبکه به دست آمده، اعمال می‌شود. برای استخراج شبکه فضای خالی باید فضای خالی سنگ را به صورت شبکه‌ای از منافذ بزرگ که با فضاهای باریک تری به نام گلوگاه به یکدیگر متصل هستند، تبدیل کرد [۱]. در چند دهه اخیر، تلاش‌های بسیاری در راستای استخراج شبکه‌ی فضای خالی از تصاویر سه بعدی، انجام شده است. اصلی ترین الگوریتم‌ها شامل روش پیمایش چندجهته^۵، روش بر پایه‌ی محور میانی^۶، روش مبتنی

بر نمودار ورونی^۷ و روش کره بیشینه محاطی^۸ هستند. روش کره بیشینه محاطی به عنوان مرسوم ترین روش جهت استخراج شبکه فضای متخلخل، ابتدا توسط سلین و همکاران [۴] ارائه شد. اساس این روش به این صورت است که به مرکز نقطه میانی هر واکسل مربوط به فضای خالی، بزرگ ترین کره‌ای که سطح واکسل دانه‌ای را لمس کند، رسم و سپس کره‌هایی که به طور کامل با دیگر کره‌ها همپوشانی دارند حذف می‌شوند و در این میان، بزرگ ترین کره‌ها نشانگر منافذ خالی^۹ و کوچک ترین کره‌های میان منافذ، بیانگر گلوگاه‌ها هستند و سپس الخروسی و بلانت [۵] در کنار مفاهیم پیشین جهت تعیین سلسله مراتب بزرگترین کره محاطی علاوه بر مفاهیم ارشد (کره بزرگ) و برده (کره کوچک) از واژه جدیدی به نام خوشه استفاده نمودند تا کره‌های محاطی مجاور هم اندازه را در یک دسته جا دهند. این رویکرد، موجب شده است تا ابهامات ناشی از کره‌های یکسان که بی اهمیت نیستند بعد از تبدیل فضای متخلخل به بزرگترین کره‌های محاطی، برطرف شود. هودانگ و بلانت [۱] در پی توسعه روش پیشین جهت تشخیص درست گلوگاه‌ها، با نسبت دادن کره‌ها به درخت‌های خانواده بر اساس رتبه و اندازه شان، روشی جدید جهت تشخیص منافذ و گلوگاه‌ها ارائه داد. نتایج حاصل از این روش با نتایج آزمایشگاهی تطابق خوبی نشان داد. اما این روش مقدار ضریب سازند^{۱۰} را کمتر از مقدار واقعی تخمین می‌زند. همچنین در این روش طول گلوگاه کمتر از مقدار واقعی و به طبع طول منافذ بیشتر از مقدار واقعی به دست می‌آید که این امر موجب ایجاد خطا در تعیین هدایت کلی جریان می‌شود.

1. Micro-Computed Tomography (micro-CT)

2. Voxel

3. Lattice Boltzmann Method

4. Multi-orientation Scanning Method

5. Medial axis Based Method

6. Voronoi Diagram Based Method

7. Maximal Ball Method

9. Pore

10. Formation Factor

و در سال‌های اخیر به‌صورت چشمگیری در راستای تحلیل و حل مسائل پیچیده، پیشرفت کرده است. علی‌رغم دقت پیش‌بینی زیاد، روش‌های یادگیری ماشین، نیازمند به استخراج ویژگی از تصاویر هستند و قابلیت اعمال مستقیم بر تصاویر دیجیتالی را ندارند، از این‌رو زمان و حجم محاسباتی زیادی را در پی دارند. شبکه عصبی پیچشی^۴، از زیر بخش‌های یادگیری عمیق محسوب می‌شود و یک نوعی از شبکه عصبی مصنوعی است که در سال‌های اخیر توجه بسیاری را در زمینه مسائل تشخیص دیداری^۵ به خود جلب کرده است و قابلیت اعمال مستقیم بر تصاویر را دارد. در گذشته در زمینه محاسبه و تعیین خصوصیات و پارامترهای پتروفیزیکی از تصاویر دیجیتالی با بهره‌گیری از شبکه عصبی پیچشی، تحقیقاتی صورت گرفته است. سوداگو و همکاران [۱۰] در مطالعه خود با بهره‌گیری از نمونه‌های سه‌بعدی ماسه‌سنگ به رأ^۶ کارایی چندین روش یادگیری ماشین و عمیق از جمله شبکه عصبی پیچشی را در جهت تخمین تراوایی موردبررسی قرار دادند. تراوایی نمونه‌ها از روش مدل‌سازی شبکه محاسبه شده است. نتایج مطالعه نشان داده است که روش شبکه عصبی پیچشی از میان الگوریتم‌های به‌کاربرده شده، بهترین و پربازده‌ترین روش است. از محدودیت‌های این روش این است که در این مطالعه تنها از یک نمونه ماسه‌سنگ همگون استفاده شده است. در سنگ‌های همگون، میان تراوایی نمونه‌های مختلف مورد مطالعه، پراکندگی اندکی موجود است. موسی تمبلیو همکاران [۸] با استفاده از نمونه‌های سه‌بعدی سنگ کربناته، کارایی روش‌های مختلف یادگیری ماشین و عمیق را در تخمین تراوایی مورد ارزیابی قرار داده و با توجه به تعداد پایین نمونه‌های به‌کاربرده شده در

ربانی و همکارانش [۶] روش جدیدی جهت استخراج شبکه فضای متخلخل توسعه دادند. آن‌ها از دو ابزار رایج پردازش تصویر، تابع فاصله^۱ و تقسیم‌بندی حوزه آبریز^۲ استفاده نموده و مقادیری چون توزیع اندازه گلوگاه و منافذ خالی و عدد پیوستگی را محاسبه و با مقادیر به‌دست‌آمده از روش کره بیشینه محاطی دانگ و بلانت مقایسه کردند. نتایج این دو روش توافق و هماهنگی خوبی داشتند. رائینی و همکارانش [۳] در جهت کاهش عدم قطعیت پارامترهای اندازه‌گیری شده در استخراج شبکه از روش کره بیشینه محاطی، روشی با عنوان استخراج شبکه تعمیم‌یافته ابداع نمود. این روش بر مبنای تبدیل محور میانی در قالب حداکثر کره بر سطح میانی، ارائه شده است. این روش فضای خالی را به منافذ خالی جدا و هر منفذ خالی را به چندین زیر بخش تحت عنوان اتصالات نیمه گلوگاه^۳ تقسیم می‌کند. هر اتصال نیمه گلوگاه با تحلیل نمودارهای محور میانی در صفحه محوری خود به گوشه‌ها تقسیم‌بندی می‌شوند. پارامترهای تخمین زننده هر گوشه شامل زاویه گوشه، حجم و رسانایی است؛ که در نهایت با اعتبارسنجی این الگوریتم در نمونه‌های مختلف و با روش‌های شبیه‌سازی مستقیم، نشان دادند که این مدل خصوصیات ماکروسکوپیک سنگ را به‌خوبی حفظ می‌کند. فرزاد برزگر و همکاران [۷] نیز، در مطالعه خود با تعریف آستانه احاطه گلوگاه از ایجاد گلوگاه‌های غیر واقعی جلوگیری کردند. که در مقیاس کوچک از اهمیت به‌سزایی برخوردار است و با مقایسه با نتایج روش کره بیشینه محاطی اصلاح شده به نتایج خوبی دست یافتند. یکی از محدودیت‌های روش آنالیز دیجیتالی سنگ، حجم محاسباتی بالا در طی فرآیند است. از این‌رو در جهت کاهش حجم و زمان محاسباتی، روش‌های هوش مصنوعی و یادگیری ماشین، (عمیق) برای دستیابی به نتایجی درست در مدت‌زمان کمتر به کار گرفته شده است [۸]. یادگیری ماشین یکی از رایج‌ترین روش‌ها در علم هوش مصنوعی است [۹]

1. Distance Function

2. Watershed Segmentation

3. half-throat Connections

4. Convolutional Neural Network


5. Visual Recognition

6.

متخلخل بر هر تصویر ($100 \times 100 \times 100$) و محاسبه پارامترهای موردنیاز به عنوان خروجی مدل ۲- طراحی و ساخت مدل شبکه عصبی پیچیده جهت آموزش و آزمودن داده‌های تهیه شده.

مجموعه داده

در این مطالعه از یک نمونه از مغزه‌های سنگ کربناته C1 [۱] در جهت ارزیابی مدل استفاده شده است (شکل ۱). سنگ کربناته C1 یک سنگ وکستون/پکستون فسیل دار است. نمونه اولیه به ابعاد $400 \times 400 \times 400$ واکسل (معادل سه بعدی پیکسل)، با دقت و اندازه واکسل $2/85 \mu m$ موجود است. تخلخل و متوسط عدد پیوستگی این نمونه سنگ ۲۳٪ و ۳ است. این نمونه سنگ از پیش بخش‌بندی شده و به هر واکسل سنگ عدد صفر (فضای خالی) یا یک (دانه) اختصاص داده شده است.



شکل ۱ الف) سنگ کربناته C1، با ابعاد $400 \times 400 \times 750$ و دقت $2/85 \mu m$ [۱] و (ب) تصویر سه بعدی سنگ کربناته C1 بخش‌بندی شده با ابعاد $400 \times 400 \times 400$ واکسل.


روش کار

در این بخش در ارتباط با نحوه آماده‌سازی تصاویر، جهت مطالعه و آموزش شبکه و نحوه محاسبه داده و خصوصیات از تصاویر توضیحاتی ارائه شده است. همچنین در رابطه با عملکرد و فرآیند اجرای شبکه عصبی پیچشی در ادامه صحبت شده است. یک گردش کار کلی از روند انجام کار در این مطالعه در شکل ۲ آورده شده است. منظور از عدد کوئوردیناسون، عدد پیوستگی است.

آموزش نمونه‌ها، در روش شبکه عصبی پیچشی به دقت قابل قبولی نسبت به دیگر روش‌ها نرسید. نیف القحطانی [۱۱] و همکاران با بهره‌گیری از سه نوع ماسه‌سنگ به رأ^۱، بنتهایمر^۲ و گسفورد^۳ و تولید تصاویر دوبعدی به ابعاد 128×128 (۱۲۸×۱۲۸) و محاسبه پارامترهای ساختاری شبکه چون تخلخل، سطح خاص^۴ و میانگین اندازه تخلخل، کارایی شبکه عصبی دوبعدی را مورد ارزیابی قرار دادند و خطای مقادیر محاسبه شده را کمتر از ۶٪ ارزیابی کرده‌اند. اگرچه این مطالعه بر اساس فضای متخلخل دوبعدی است که این امری ناکارآمد است زیرا فضای متخلخل به صورت طبیعی سه بعدی است و بسیار پیچیده‌تر از فضای دوبعدی است و همچنین پیوستگی و قرارگیری منافذ نسبت به هم در فضای دوبعدی و سه بعدی با تخلخل یکسان ممکن است با یکدیگر متفاوت باشند. همان‌طور که عنوان شده است در اکثر مقالات پیشین، بر روی ماسه‌سنگ‌های همگون، مطالعه انجام شده است. در صورتی که تعیین خصوصیات سنگ‌های پیچیده همانند سنگ‌های کربناته به دلیل ناهمگنی‌های موجود، بسیار چالش‌برانگیز و مهم است. از این رو در این مطالعه، از یک سنگ کربناته ناهمگن استفاده و مطالعات پیشین گسترش داده شده است. در این مطالعه از شبکه عصبی پیچشی سه بعدی به عنوان یک ابزار پیش‌بینی کننده جهت تخمین و پیش‌بینی پارامترهای مهمی چون: تخلخل، میانگین اندازه منافذ، میانگین اندازه گلوگاه، میانگین عدد پیوستگی و میانگین ضریب شکل منافذ که مقادیری مهم و اساسی در تعیین و محاسبه پارامترهای مربوط به جریان چون تراوایی، فشار موینگی و غیره هستند، استفاده شده است. در نهایت زمان محاسباتی این مقادیر با استفاده از شبکه عصبی پیچشی با الگوریتم کره بیشینه محاطی^۵ که در این مطالعه از آن بهره گرفته شده است مقایسه می‌شود. به طور کلی، این مطالعه از دو بخش تشکیل شده است:

۱- آماده‌سازی تصاویر جهت محاسبه و آموزش مدل و سپس پیاده‌سازی روش‌های استخراج شبکه فضای

1. Berea
2. Bentheimer
3. Gosford
4. Specific Surface area
5. Maximall Ball




شکل ۲ گردش کار ارائه شده جهت تخمین خصوصیات فضای متخلخل از طریق شبکه عصبی پیچشی.

مورد نیاز برای سنگ تا خصوصیات به دست آمده نماینده ای از خصوصیات کل سنگ باشد- اندازه و ابعاد تصاویر به دست آمده، باید از مقدار نماینده حجم ابتدایی سنگ C1 کمتر باشد. با توجه به مطالعه پیمان مستقیمی و همکاران [۱۲] بر روی حجم اولیه نماینده سنگ C1، با احتساب ابعاد $100 \times 100 \times 100$ واکسل برای این نوع سنگ، حجم به دست آمده از حجم اولیه نماینده کوچک تر است. از این رو میان خصوصیات به دست آمده از تصاویر، اختلاف وجود دارد. بنابراین هر یک از این نمونه های کوچک به عنوان یک نمونه سنگ مستقل، می توانند مورد ارزیابی و آزمایش قرار گیرند.

آماده سازی تصاویر


نمونه مذکور، جهت ساخت مجموعه ای از داده ها برای الگوریتم یادگیری عمیق، با بهره گیری از نرم افزار متلب و با گام ۱۵ واکسل به تصاویر و مکعب هایی با ابعاد $100 \times 100 \times 100$ تبدیل شده و در نهایت به ۹۲۶۱ نمونه دست یافتیم (شکل ۳). برای تولید مجموعه داده مورد نیاز برای آموزش شبکه، نیاز است که این تصاویر با هم متفاوت باشند و خصوصیات به دست آمده از تصاویر با یک دیگر یکسان نباشند تا بتوان شبکه را با مجموعه ای از داده های مختلف آموزش داد. از این رو با توجه به مفهوم حجم اولیه نماینده - حداقل حجم و ابعاد



شکل ۳ شماتیکی از نمونه برداری با گام ۱۵ واکسل.

استخراج شبکه ساختاری سنگ

جهت دستیابی به پارامترهای ساختاری سنگ برای هر یک از نمونه‌ها از یک کد استخراج شبکه منافذ [۱۳] از الگوریتم کره بیشینه محاطی استفاده شده است. اساس الگوریتم استفاده‌شده بر اساس مقاله‌ی دانگ و بلانت [۱] است. در الگوریتم مورد بحث در نحوه تعیین تخلخل و پارامترهای وابسته از مفاهیم به‌کاربرده شده در مقاله رائینی (مراحل ۱ و ۲)، بهره گرفته‌شده است. توابع ضریب شکل منافذ در این کد از مقاله [۱۴] گرفته‌شده است. شکل ۴، شبکه استخراج‌شده از تصویر اولیه نمونه سنگ کربناته با استفاده از الگوریتم مذکور را نشان می‌دهد.



شکل ۴ شبکه استخراج‌شده از تصویر اولیه سنگ کربناته C1 با ابعاد ۴۰۰×۴۰۰×۴۰۰ واکسل با استفاده از الگوریتم بیشینه محاطی.

در نرم‌افزار متلب بعد از نمونه‌برداری و تبدیل تصویر اولیه به ۹۲۶۱ نمونه، بر هریک از تصاویر تبدیل شده (۱۰۰×۱۰۰×۱۰۰)، الگوریتم کره بیشینه محاطی اعمال شده است. پارامترهای به‌دست‌آمده از الگوریتم شامل تخلخل، اندازه منافذ، اندازه گلوگاه، عدد پیوستگی و ضریب شکل منافذ است. الگوریتم اعمال شده بر هر تصویر، ضمن استخراج شبکه منافذ و گلوگاه‌ها، پارامترهایی از قبیل تخلخل، تعداد و اندازه منافذ و گلوگاه‌ها، تعداد گلوگاه‌های متصل به هر منفذ و ضریب شکل هر منفذ را به دست آورده. با توجه به این امر که هر تصویر از تعدادی منفذ و گلوگاه تشکیل شده است، متوسط اندازه منافذ و گلوگاه،

متوسط ضریب شکل منافذ و متوسط عدد پیوستگی به عنوان خصوصیات و برچسب‌های متناسب برای هر تصویر در الگوریتم یادگیری بانظارت استفاده شده است.

هر یک از موارد به شرح زیر است:

۱- اندازه: شعاع بزرگ‌ترین کره محاطی تعریف‌شده به‌عنوان اندازه منفذ خالی و شعاع بزرگ‌ترین بیشینه کره محاطی گلوگاه در خط و زنجیره منفذ خالی-گلوگاه، به‌عنوان اندازه گلوگاه تعریف می‌شود [۱].

۲- ضریب شکل: منافذ و گلوگاه‌های واقعی ساختارهایی بی‌قاعده و پیچیده دارند. در این کد برای گلوگاه‌ها، ضریب شکل به‌صورت زیر تعریف می‌شود:

$$G = \frac{R^2}{4A} \quad (1)$$

R شعاع تعیین‌شده و A سطح مقطع گلوگاه است.

ضریب شکل منافذ از طریق میانگین وزنی ضریب شکل گلوگاه‌های همسایه براساس سطح مشترک با منافذ خالی محاسبه می‌شود [۱۴].

۳- عدد پیوستگی: عدد پیوستگی Z بیانگر تعداد گلوگاه‌های مستقل مرتبط به یک منفذ خالی است. توزیع عدد پیوستگی یک نوع ارزیابی و اندازه‌گیری از ارتباط و پیوستگی شبکه است [۱].

شبکه عصبی پیچشی

شبکه عصبی پیچشی از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: لایه پیچشی^۱، لایه ادغام^۲ و لایه تماماً متصل^۳. لایه‌های مختلف وظایف مختلفی را انجام می‌دهند [۱۵]. لایه پیچشی وظیفه استخراج ویژگی از تصاویر را بر عهده دارد، لایه ادغام در جهت کاهش ابعاد و ویژگی‌ها و لایه تمام متصل در انتها به‌عنوان لایه طبقه‌بندی اعمال می‌شود. در لایه پیچشی، یک سری هسته‌های تصادفی^۴، مجموعه‌ای از ویژگی‌هایی که در تصویر پنهان است را استخراج می‌کنند.

1. Convolutional Layer
2. Pooling Layer
3. Fully Connected Layer
4. Kernel

ادغام بیشینه^۴ که یک نوع نمونه‌گیری پایین^۵ نیز محسوب می‌شود، بزرگترین مقدار موجود در پنجره ادغام را انتخاب می‌کند. بعد از عبور تصاویر ورودی از چندین لایه پیچشی و لایه ادغام، مجموعه‌ای از نقشه‌های ویژگی سه‌بعدی ساخته می‌شود. لایه تمام متصل که مشابه با شبکه عصبی مصنوعی ساده است، بر این مجموعه از نقشه‌های ویژگی اعمال می‌شوند تا به خروجی مشخصی منجر شوند [۱۷]. در راستای جلوگیری از بیش‌ازحد مناسب بودن^۶ شبکه، از لایه‌های حذف تصادفی^۷ استفاده شده است. حذف تصادفی یک روش منظم‌سازی است که در حین آموزش، به‌صورت تصادفی، تعدادی از نورون‌های لایه شبکه عصبی (به عبارتی خروجی‌های لایه) نادیده گرفته می‌شوند. تابع خطا، معیاری برای سنجش مناسب بودن مدل از نظر قابلیت و توانایی در پیشگویی مقدارهای جدید است. در آموزش شبکه عصبی، باید یک تابع خطا جهت اختلاف موجود میان مقادیر پیش‌بینی خصوصیات و مقادیر واقعی تعریف شود. درواقع مدل جهت دست‌یابی به یک پیش‌بینی درست، باید به وزن‌هایی دست پیدا کند که این اختلاف را حداقل کند. تابع خطای استفاده‌شده در این مدل یکی از معروف‌ترین و معمول‌ترین توابع خطا در تحلیل رگرسیونی، میانگین مربعات خطا است. این تابع، میانگین مربعات فاصله بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. با توجه به این امر که ۵ خصوصیت فیزیکی به‌عنوان خروجی شبکه در نظر گرفته شده است، تابع خطای نهایی یک میانگین وزنی از تابع خطای هر پارامتر، با وزن یکسان است، بنابراین تمام پارامترها به میزان یکسان در همگرایی شبکه اثرگذار هستند. با احتساب مشتق تابع خطا، تابع بهینه‌ساز که در این مدل، آدام

از این ویژگی‌ها به‌صورت مستقیم استفاده نمی‌شود و باید از توابع فعال‌سازی و لایه‌های ادغام استفاده کرد. بعد از استخراج ویژگی، خروجی‌های به‌دست‌آمده به‌صورت مسطح شده^۱ به شبکه تمام متصل، اتصال می‌یابند [۱۶]. به‌طور کلی لایه پیچشی به‌عنوان مهم‌ترین لایه، شامل مجموعه‌ای از پالایه^۲ های استخراج‌کننده ویژگی با اندازه یکسان اما با وزن‌های متفاوت هستند که در حین آموزش یاد گرفته و به‌روزرسانی می‌شوند. در مفاهیم آنالیز سنگ‌های دیجیتالی و محاسبه‌ی خصوصیات پتروفیزیکی به دلیل ماهیت سنگ مخزن (فضایی سه بعدی)، نیاز است که استخراج منافذ و گلوگاه‌ها و محاسبه پارامترهای وابسته به آن در یک فضای سه‌بعدی اندازه‌گیری شود. ازاین‌رو در این مطالعه، از شبکه عصبی پیچشی سه‌بعدی استفاده شده است. نقشه‌های ویژگی شبکه عصبی پیچشی سه‌بعدی با ضرب داخلی تصاویر ورودی یا آخرین نقشه‌های ویژگی با یک مجموعه‌ای از هسته‌های تصادفی با پهنا، ارتفاع و کانال مشخص (هسته‌های سه‌بعدی) به‌صورت ساعت‌گرد، تولید می‌گردند. نقشه‌ی ویژگی F_k ، به‌صورت رابطه‌ی زیر محاسبه می‌شود:


$$f_j^i(w, h, l) = a(b_j^i + (\sum_n \sum_{x,y,z} f_n^{i-1}(w-x, h-y, l-z) K^i(x,y,z))) \quad (2)$$

در این رابطه f_j^i و f_n^{i-1} به ترتیب مربوط به i امین نقشه ویژگی سه‌بعدی در i امین لایه و n امین نقشه ویژگی سه‌بعدی در $(i-1)$ امین لایه است. K^i و b_j^i نیز هر کدام به ترتیب مربوط به هسته سه‌بعدی و مقدار آستانه است. a بیانگر تابع فعال‌سازی غیرخطی به‌کاربرده شده در معادله است. در این شبکه از تابع فعال‌سازی واحد یکسو شده خطی^۳ (RELU) استفاده شده است که یک تابعی غیرخطی است که با ایجاد خاصیت غیرخطی، شبکه را در حل مسائل پیچیده، توانمند می‌سازد. پس‌از آن با عبور نقشه‌های ویژگی تولیدشده از لایه‌های ادغام، از ابعاد تصاویر کاسته، برای مثال لایه

1. Flattened
2. Filter
3. Rectified Linear Unit
4. Max Pooling
5. Down Sampling
6. Over Fitting
7. Dropout

است، متغیرهای خروجی بدون مقیاس در مسائل رگرسیونی می‌توانند موجب ایجاد خطای زیادی شوند که در نهایت منجر به شکست فرآیند آموزش می‌شود. این مدل دارای ۵ خروجی است که هر کدام در بازه‌های متفاوت، قرار دارند و آموزش مدل با این خصوصیات ممکن است منجر به واگرایی شبکه شود. از این رو خروجی‌های مذکور استانداردسازی (نرمال استاندارد) می‌شوند. درواقع میانگین آن‌ها روی عدد صفر و واریانس روی عدد یک تنظیم می‌شود.

(تخمین گشتاور تطبیقی^۱) انتخاب شده است، با اعمال روابط مربوطه، پارامترهای شبکه (وزن‌ها و سوگیری‌ها^۲) را به‌روزرسانی می‌کند. جزئیات ساختار و معماری شبکه عصبی پیچشی مورد استفاده در این مطالعه در **شکل ۵** و **جدول ۱** آورده شده است. از روش‌های مولد داده^۳ برای ورود تصاویر به شبکه، استفاده شده است؛ و تصاویر به‌صورت دسته‌ای با اندازه^۴ ۱۰۰ وارد حافظه کامپیوتر می‌شوند. لازم به ذکر است مقیاس ورودی و خروجی‌های مورد استفاده برای آموزش مدل عاملی بسیار مهم



شکل ۵ معماری شبکه عصبی ۳ بعدی مورد مطالعه.

جدول ۱ توضیحات مربوط به معماری شبکه عصبی پیچشی.

تعداد لایه	عملیات	توضیحات
۵ لایه	لایه پیچشی سه بعدی	اندازه هسته برای هر لایه (۷، ۷، ۷)، (۵، ۵، ۵)، (۳، ۳، ۳) و (۳، ۳، ۳)
		گام (۲، ۲، ۲)
		لایه گذاری ابعاد ماتریس ورودی و خروجی برابر است
		تعداد فیلترها در هر لایه [۱۶، ۳۲، ۶۴، ۱۲۸، ۲۵۶]
		تابع فعال سازی RELU
۲ لایه	نرمال سازی دسته‌ای	انتهای هر لایه پیچشی اعمال شده است.
	حداکثر پولینگ سه بعدی	اندازه هسته (۳، ۳، ۳)
	مسطح سازی	مسطح سازی ماتریس سه بعدی لایه آخر به ماتریس یک بعدی
۲ لایه	لایه تمام متصل	تعداد نورون [۵۱۲، ۱۰۲۴]
	تابع فعال سازی	RELU
	Dropout	در انتهای هر لایه تمام متصل، ۵۰ درصد از نورون‌ها به صورت تصادفی حذف می‌شوند.

1. Adaptive Moment Estimation (Adam)
 2. Bias
 3. Data Generator
 4. Batch

نتایج


توزیع آماری داده

($100 \times 100 \times 100$) و نوع تخلخل موجود در این نوع سنگ (با توجه به شکل ۱، در بخش‌هایی از سنگ، حفره‌های بزرگی موجود است)، تخلخل تعداد کمی از نمونه‌ها، عدد نسبتاً بالایی در حدود ۵۰٪، به دست آمده است که این امر تنها به دلیل کوچک بودن فضای نمونه سنگ در تصویر است.

معماری شبکه عصبی پیچشی

در این شبکه با توجه به ناهمگونی موجود میان یک نمونه تصویر، برخلاف مطالعات پیشین، جهت استخراج اطلاعات از واکنش‌های همسایه، از هسته‌هایی با اندازه بالا در لایه‌های اول و دوم استفاده شده است. سپس در جهت تعیین یک معماری بهینه برای شبکه عصبی پیچشی، تحلیل‌هایی در خصوص تعیین تعداد لایه و نرخ یادگیری در فرآیند بهینه‌سازی مدل، انجام شده است. جزئیات تحلیل‌های صورت گرفته در بخش‌های بعدی آورده شده است.


یادگیری عمیق یک الگوریتمی یادگیری ماشین مبتنی بر داده است. بنابراین کیفیت مدل به شدت به داده‌های ورودی وابسته است. داده‌های مورد بررسی به سه بخش آموزش، صحت سنجی و آزمایش، تقسیم (۷۵:۱۵:۱۰) شده‌اند. جهت مقایسه توزیع داده‌ها، توزیع تابع چگالی احتمال برای هریک از مجموعه داده‌های آموزش، صحت سنجی و آزمایش همراه با میانگین هر مجموعه در شکل ۶ آورده شده است. با توجه به یکسان بودن میانگین مجموعه‌ها برای هر خصوصیت و شباهت توزیع آماری، می‌توان نتیجه گرفت که توزیع هر خصوصیت در مجموعه‌های مختلف از هیچ‌گونه تعصب خاصی در انتخاب داده، پیروی نمی‌کند که این موضوع بر استحکام و کیفیت آموزش تأثیرگذار است. با تقسیم‌بندی نمونه سنگ اولیه به نمونه‌های کوچک‌تر، با توجه به کوچک بودن اندازه نمونه‌ها



شکل ۶ توزیع تابع چگالی احتمال متوسط پنج خصوصیت به دست آمده از روش کره بیشینه محاطی برای مجموعه‌های آموزش، صحت سنجی و آزمایش.

تعداد لایه

است. نتایج ارزیابی بعد از ۱۲۰ دور در **شکل ۸** و **جدول ۳** نشان داده شده است.



شکل ۸ نمودار تابع خطا بر حسب دور با نرخ‌های یادگیری مختلف
جدول ۳ تحلیل نرخ یادگیری‌های مختلف

نرخ یادگیری	۰/۰۰۵	۰/۰۰۱	۰/۰۰۳
تابع خطا	۰/۰۸۸۲	۰/۱۰۸	۰/۱۱۵۵


بحث

برای تعیین تعداد لایه‌های شبکه عصبی پیچشی، این دو شبکه از دوره ۸۰ به بعد تقریباً به مقدار ثابتی رسیده‌اند و همان‌طور که مشاهده می‌شود شبکه با ۵ لایه، تابع خطای (حداقل مربعات خطا) کمتری برای مجموعه داده‌های ارزیابی نسبت به ۴ لایه دارد و نوسانات رخ داده در شبکه با ۴ لایه بیشتر از ۵ لایه است.

با توجه به مقادیر نشان داده شده در **جدول ۳** و **شکل ۸**، شبکه به کار برده شده با نرخ یادگیری ۰/۰۰۵ عملکرد بهتری نسبت به دو نرخ یادگیری دیگر دارد. شبکه اجرا شده با نرخ ۰/۰۰۳ به دلیل اعوجاجات زیاد و تابع خطای بالا در نظر گرفته نمی‌شود. شبکه‌های اجرا شده با نرخ یادگیری ۰/۰۰۵ و ۰/۰۰۱ تقریباً عملکرد مشابهی نسبت به یکدیگر دارند و تنها در روند کاهشی و تابع خطای پایانی خود تفاوت اندکی نسبت به یکدیگر دارند و هر دو تقریباً از دور ۵۰ به بعد همگرا و ثابت شده‌اند؛ اما شبکه عصبی با نرخ ۰/۰۰۱ نوسانات بیشتری نسبت به شبکه با نرخ ۰/۰۰۵ دارد. از این‌رو شبکه

1. Random Seed

تعیین تعداد مناسب لایه‌های پیچشی امری بسیار مهم است. از این‌رو دو نوع شبکه با ۵ و ۴ لایه مورد بررسی قرار گرفته است. در این دو بررسی با توجه به انتخاب تصادفی داده‌های آموزش، صحت سنجی و آزمایش در مدل، با احتساب دانه تصادفی^۱ ثابت، مجموعه‌ای ثابت از مجموعه‌های مذکور در دو مدل انتخاب می‌گردد. همچنین با توجه به مقادیر تصادفی اولیه برای وزن‌ها با احتساب دانه‌ی تصادفی ثابت، شرایط اولیه برای دو مدل، ثابت در نظر گرفته شده است. نرخ یادگیری در این دو مدل ۰/۰۰۱ تنظیم شده است. نتایج آزمایش هر دو مدل بعد از ۱۲۰ دور در **شکل ۷** و **جدول ۲** قابل مشاهده است.



شکل ۷ نمودار تابع خطا بر حسب دور با تعداد لایه‌های مختلف.


جدول ۲ تحلیل تعداد لایه

تعداد لایه	۳-۳-۵-۷	۳-۳-۳-۵-۷
تابع خطا	۰/۲۶۴۶	۰/۱۰۸

نرخ یادگیری

نرخ یادگیری عاملی بسیار تأثیرگذار در نرخ همگرایی و دقت شبکه محسوب می‌شود زیرا نرخ یادگیری زیاد، می‌تواند موجب واگرایی شبکه و دور شدن تابع هدف از مقدار بهینه خود و کم بودن نرخ یادگیری می‌تواند موجب کند شدن آموزش و طولانی شدن فرآیند یادگیری شود. از این‌رو با توجه به تحلیل‌های قبلی، شبکه عصبی ۵ لایه با هسته‌های ۳-۳-۳-۵-۷ و نرخ‌های یادگیری ۰/۰۰۳، ۰/۰۰۱ و ۰/۰۰۵ مورد مقایسه و ارزیابی قرار گرفته

محاسبه شده میان مقادیر واقعی و پیش‌بینی شده کمتر از ۰.۴٪ است؛ که بیانگر انطباق خوبی میان مقادیر پیش‌بینی شده و واقعی است. همچنین ضریب تعیین محاسبه شده در تخمین متوسط اندازه گلوگاه، متوسط اندازه منافذ، متوسط عدد پیوستگی و متوسط ضریب شکل منافذ به ترتیب ۰.۹۴/۵، ۰.۹۳/۶ و ۰.۷۵/۳ است؛ و میانگین خطای نسبی مقادیر مذکور ۰.۳/۸، ۰.۲/۶، ۰.۳/۹ و ۰.۳/۴ پیش‌بینی شده است. مقادیر مذکور بیانگر انطباق نسبتاً خوبی میان مقادیر پیش‌بینی شده و واقعی است. در میان مقادیر نشان داده شده، ضریب شکل منافذ نسبت به مقادیر دیگر ضریب تعیین کمتری دارد که این امر با توجه به تصویر نشان داده شده از نمونه سنگ اولیه می‌تواند به دلیل ناهمگونی زیاد در شکل و هندسه منافذ وجود واگ^۴ در سنگ باشد و با افزایش تعداد تصاویر آموزش، می‌توان این مقدار را افزایش داد. در شکل ۱۰، توزیع خطای نسبی خصوصیات پیش‌بینی شده در شبکه عصبی پیچشی نمایش داده شده است.




شکل ۹ نمودار پراکندگی مقادیر پیش‌بینی شده (الف) تخلخل، (ب) متوسط شعاع گلوگاه، (پ) متوسط شعاع منافذ، (ت) متوسط عدد پیوستگی و (ث) متوسط ضریب شکل منافذ هر تصویر برحسب مقادیر به دست آمده از روش کره بیشینه محاطی

عصبی پیچشی با نرخ یادگیری ۰/۰۰۵ جهت آزمایش‌های بعدی انتخاب شده است و درنهایت در راستای جلوگیری از بیش‌ازحد مناسب بودن^۱ شبکه و کاهش وابستگی نتایج به داده‌های ورودی، شبکه نهایی با روش اعتبارسنجی متقابل^۲، ۷ بار اجرا و درنهایت از بهترین مدل جهت تخمین پارامترهای پتروفیزیکی مجموعه داده‌های آزمایش، استفاده شده است.

ارزایی داده‌های آزمایش

در شکل ۹ مقادیر پیش‌بینی شده پارامترهای پتروفیزیکی سنگ از شبکه عصبی پیچشی برحسب مقادیر واقعی (مقادیر به دست آمده از روش کره بیشینه محاطی) مجموعه داده‌های آزمایش ترسیم شده است. محاسبه تخلخل اولین گام در جهت اثبات توانایی و پتانسیل شبکه عصبی پیچشی در تخمین خصوصیات پیچیده‌تر و گران‌تر از جهت محاسباتی، محسوب می‌شود. با توجه به شکل ۹ ضریب تعیین^۳ محاسبه شده در تخمین تخلخل در شبکه موردبررسی ۰.۹۹٪ و میانگین خطای نسبی

1. Over Fitting
2. Cross Validation
3. Coefficient of Determination (R-squared)
4. Vuge



شکل ۱۰ نمودار فراوانی خطای نسبی الف) تخلخل، ب) متوسط شعاع گلوگاه، پ) متوسط شعاع منافذ، ت) متوسط عدد پیوستگی و ث) متوسط ضریب شکل منافذ هر تصویر.

دسته ورودی، تعداد گام‌های موردنیاز جهت ورود تصویر به شبکه ۷۰۹ عدد تعیین می‌شود و هر دور تقریباً ۹ min جهت آموزش مدل در ۱۲۰ دور حدوداً ۱۸ h خواهد بود؛ و در نهایت بعد از آموزش شبکه برای تخمین پارامترهای ذکر شده از مجموعه تصاویر آزمایش جهت محاسبه پارامترهای هر تصویر، تنها ۰/۰۱۸۹ s نیاز است در صورتی که در روش‌های استخراج شبکه، محاسبه خصوصیات فیزیکی مذکور ۱ min به طول می‌انجامد.

نتیجه‌گیری

در این مطالعه از یک شبکه عصبی پیچشی سه‌بعدی جهت تخمین پارامترهای فیزیکی سنگ بهره گرفته شده است. جهت آموزش و ارزیابی مدل از مجموعه‌ای از تصاویر میکرو سی‌تی‌اسکن یک نمونه سنگ کربنات استفاده شده است. در ابتدا با بهره‌گیری از الگوریتم‌های استخراج شبکه، برای

بر اساس مشاهدات صورت گرفته، تعداد زیادی از داده‌ها دارای خطای نسبی نزدیک به صفر بوده و به‌طور کلی بخش اعظمی از داده‌ها خطایی کمتر از ۱۰٪ دارند. بر اساس نتایج نشان داده‌شده، مشاهده می‌شود که بالاترین دقت ارزیابی در محاسبه تخلخل صورت گرفته است که می‌تواند به این دلیل باشد که تخلخل، پارامتری است که به‌صورت مستقیم از تصاویر قابل محاسبه است اما دیگر پارامترها رابطه‌ای غیرمستقیم با تصاویر دارند و از الگوریتم‌های استخراج شبکه به دست می‌آیند، از این رو شبکه خروجی ارزیابی بهتری نسبت به این پارامتر در مقابل دیگر پارامترها دارد.

تحلیل زمان محاسباتی

برای اجرای الگوریتم شبکه عصبی پیچشی در پایتون از کتابخانه‌ی کراس^۱ با پشتیبانی تنسورفلو و در جهت تسریع محاسبات در اجرای شبکه از سیستم پردازنده گرافیکی^۲ استفاده شده است. زمان محاسباتی موردنیاز در جهت آموزش مدل به‌صورت خطی با تعداد دوره‌های آموزش، افزایش می‌یابد. با در نظر گرفتن ۱۰ تصویر به‌عنوان

1. Keras

2. Tensor Flow

3. GPU

مقادیر ذکر شده بیانگر پتانسیل بالای شبکه عصبی پیچشی در تخمین پارامترهای فیزیکی سنگ‌های دیجیتالی است که می‌توان با بهره‌گیری بیشتر از پتانسیل شبکه عصبی پیچشی این مقادیر را کاهش داد. همان‌طور که مشخص است این شبکه تنها بر یک نوع سنگ، مدل شده است و طبیعتاً در تخمین پارامترهای فیزیکی نمونه‌های دیگر از همین نوع سنگ به نتایجی درست و منطقی در حداقل زمان، دست خواهد یافت. در مطالعات آتی می‌توان از چندین نمونه سنگ مختلف اعم از کربناته و ماسه‌سنگ به‌صورت یکجا به‌عنوان ورودی شبکه استفاده نمود تا بتوان ارزیابی جامعی از خصوصیات انواع سنگ‌ها ارائه داد و همچنین می‌توان، پتانسیل و کارایی شبکه‌ی عصبی پیچشی را در بخش‌بندی تصاویر و تخمین پارامترهای پتروفیزیکی پیچیده‌تر همچون تراوایی و ضریب سازند مورد ارزیابی قرارداد و جهت افزایش بازدهی شبکه از مدل‌های پیچیده‌تر شبکه عصبی پیچشی استفاده نمود.

هر تصویر، ۵ خصوصیت فیزیکی سنگ شامل تخلخل، متوسط اندازه گلوگاه، متوسط اندازه منافذ، متوسط عدد پیوستگی و متوسط ضریب شکل منافذ، محاسبه شده است. سپس شبکه عصبی پیچشی با تصاویر ورودی و خصوصیات متناظر با آن آموزش داده و با توجه به روند و مقدار تابع خطا تعداد لایه و مقدار مناسب نرخ یادگیری جهت آزمایش و ارزیابی شبکه، تعیین شد. بعد از ارزیابی و محاسبه خصوصیات مجموعه تصاویر داده‌های آزمایش، ضریب تعیین و میزان خطای نسبی برای تخلخل، به ترتیب ۰/۹۹ و ۰/۴۲، برای متوسط اندازه گلوگاه ۰/۹۰/۲ و ۰/۳/۸، برای متوسط اندازه‌ی منافذ ۰/۹۴/۵ و ۰/۲/۶، متوسط عدد پیوستگی ۰/۹۳/۶ و ۰/۳/۹ و برای متوسط ضریب شکل منافذ ۰/۷۵/۳ و ۰/۳/۴ محاسبه شده است. نتایج به‌دست‌آمده در این مطالعه نسبت به نتایج به‌دست‌آمده در مقاله القحطانی در محاسبه خطای نسبی متوسط عدد پیوستگی، متوسط اندازه منافذ و تخلخل که به ترتیب ۰/۲۰، ۰/۷ و ۰/۵ است، بسیار بهتر است. با توجه به نتیجه حاصل شده،

مراجع

- [1]. Dong, H. & Blunt M. J. (2009). Pore-network extraction from micro-computerized-tomography images, *Physical Review E*, 80(3), 036307, doi.org/10.1103/PhysRevE.80.036307.
- [2]. Niu, Y. (2020). Digital rock segmentation for petrophysical analysis with reduced user bias using convolutional neural networks, *Water Resources Research*, 56(2), e2019WR026597, doi.org/10.1029/2019WR026597.
- [3]. Raeini, A. Q. (2017). Generalized network modeling: Network extraction as a coarse-scale discretization of the void space of porous media, *Physical Review E*, 96(1): 013312, doi.org/10.1103/PhysRevE.96.013312.
- [4]. Silin, D., & Patzek, T. (2006). Pore space morphology analysis using maximal inscribed spheres, *Physica A: Statistical mechanics and its applications*, 371(2), 336-360, doi.org/10.1016/j.physa.2006.04.048.
- [5]. Al-Kharusi, A.S. & Blunt, M.J. (2007). Network extraction from sandstone and Carbonate pore space images, *Journal of Petroleum Science and Engineering*, 56: 219-231, doi.org/10.1016/j.petrol.2006.09.003.
- [6]. Rabbani, A., Jamshidi, S., & Salehi, S. (2014). An automated simple algorithm for realistic pore network extraction from micro-tomography images, *Journal of Petroleum Science and Engineering*, 123: 164-171, doi.org/10.1016/j.petrol.2014.08.020.
- [7]. Barzegar, F., Masihi, M., & Tabar, M. A. (2020). A rigorous algebraic-analytical method for pore network extraction from micro-tomography images, *Journal of Hydrology*, 590, 125561, doi.org/10.1016/j.jhydrol.2020.125561.
- [8]. Tembely, M. & A. AlSumaiti (2019). Deep learning for a fast and accurate prediction of complex carbonate rock permeability from 3D micro-CT images, *Abu Dhabi International Petroleum Exhibition & Conference*, Society of Petroleum Engineers, doi.org/10.2118/197457-MS.

[۹] شکر، س.، صادقی، م. ت. و احمدی مرودوست، م. (۱۳۹۲) ارائه روش ترکیبی پیش پردازش داده‌ها در ماشین

بردار رگرسیون جهت پیش‌بینی کیفیت گازوئیل پالایش‌شده، پژوهش نفت، ۷۵: (۲۳)، ۱۱۶ - ۱۰۲.
 [10]. Sudakov, O. (2019). Driving digital rock towards machine learning: Predicting permeability with gradient boosting and deep neural networks, *Computers & geosciences*, 127: 91-98, doi.org/10.1016/j.cageo.2019.02.002.

- [11]. Alqahtani, N. Alzubaidi, F., Armstrong, R. T., Swietojanski, P., & Moštaghimi, P. (2020). Machine learning for predicting properties of porous media from 2d X-ray images. *Journal of Petroleum Science and Engineering* 184: 106514, doi.org/10.1016/j.petrol.2019.106514.
- [12]. Moštaghimi, P., Blunt, M. J., & Bijeljic, B. (2013). Computations of absolute permeability on micro-CT images. *Mathematical Geosciences*, 45(1), 103-125.
- [13]. Raeini, A. (2020). <https://github.com/ImperialCollegeLondon/pnextract>.
- [14]. Bultreys, T., Lin, Q., Gao, Y., Raeini, A. Q., AlRatrout, A., Bijeljic, B., & Blunt, M. J. (2018). Validation of model predictions of pore-scale fluid distributions during two-phase flow. *Physical Review E*, 97(5), 053104, doi.org/10.1103/PhysRevE.97.053104.
- [15]. Krizhevsky A, Sutskever I, Hinton GE, editors (2012). Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*.
- [16]. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning, *Nature*, 521(7553), 436-444.
- [17]. Karimpouli, S., & Fattahi, H. (2018). Estimation of P-and S-wave impedances using Bayesian inversion and adaptive neuro-fuzzy inference system from a carbonate reservoir in Iran. *Neural Computing and Applications*, 29(11), 1059-1072.