



Application of Geomechanical Parameters in Identifying Hydrocarbon Zones and Determining the Lithology of the Nahr-umr Reservoir in One of the Southern Oilfields of Iran

Peyman Azizi Shoshbulag¹ and Ali kadhodaie^{2*}

1. Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran

2. Earth Science Department, Faculty of Natural Science, University of Tabriz, Iran

kadhodaie_ali@tabrizu.ac.ir

DOI: 10.22078/pr.2025.5699.3528

Received: May 30, 2025

Modify Date: September 28, 2025

Accepted: September 29, 2025

Introduction

Accurate identification of hydrocarbon-containing locations is considered one of the most important exploration steps to reduce the cost and increase the efficiency of the extraction and exploitation process of subsurface oil and gas. Traditional methods are usually very time-consuming and, despite the high cost, have the lowest coverage [1]. The progress of geophysical methods, especially the estimation of geomechanical parameters such as Young's modulus, bulk modulus, and Poisson's ratio using seismic data, has not only reduced these problems but also reduced drilling risks by predicting the type and quality of lithology [2]. This method helps to investigate the subsurface layer containing oil and gas with greater accuracy and on a larger scale [3].

Materials and Methods

The oil field under study is located in the northwest of the Persian Gulf, about 27 km from the city of Daylam. The field was first discovered in 1960 through Well A. Its main reservoir is the Nahr Omar Formation of the Early Cretaceous period and has three major layers: compact shale and marl at the top, limestone in the middle, and porous sandstone with shale layers at the bottom [4]. The Hendijan–Bahregansar strike-slip

fault has a major impact on the shape, thickness, and mechanical properties of this reservoir [4]. The total thickness of this formation averages 194 m, and the sandstone layer reaches its maximum size of 69 m in Well A. Moreover, most of the oil and gas is located in the sections of shale and sandstone. In this study, 3D seismic data, detailed well logs (such as acoustic, density, and checkshot), and geological surveys of three major wells were used to build a geomechanical model and identify oil and gas-bearing areas. Moreover, the elastic properties of the rocks were obtained using the simultaneous seismic inversion method, which is based on linear relationships between parameters and using the Aki-Richards equations [2]. Furthermore, the correlation coefficient is around 0.99 which indicates the reliability of this method. In this method, parameters such as Poisson's ratio, Young's modulus, lambda-rho, and mu-rho were calculated to distinguish between the rock type (shale, sandstone, limestone) and the fluid type (water, oil, gas). This method helps us to better understand the subsurface layers, prevent unnecessary drilling, and have more accurate planning for exploration and production.

Results and Discussion

An extensive workflow was developed to identify and

evaluate hydrocarbon reservoirs from seismic data and geomechanical properties. First, an integrated attribute was calculated as the product of P-wave impedance, Vp/Vs ratio, Young's modulus, Poisson's ratio, and Mu-Rho. Moreover, lower values of this attribute indicated areas with greater hydrocarbon potential (Fig. 1).

The results were combined with reservoir thickness information to select the best drilling locations that provide a balance between hydrocarbon richness and storage capacity. Moreover, vertical analysis was then performed at the selected area using a set of scatter

plots to separate different fluid and lithology types from each other. Furthermore, these plots, which include: Young's modulus versus Poisson's ratio, P-impedance versus Vp/Vs, Mu-Rho versus Lambda-Rho, and Poisson's ratio versus Lambda-Rho successfully distinguished shale, limestone, gas-bearing limestone, and oil-bearing sandstone. Among them, Mu-Rho vs. Lambda-Rho and Poisson's ratio vs. Lambda-Rho plots provided the best discrimination between rock types and fluid content (as seen in Figs. 2-3). Finally, the parameters obtained from seismic were validated by comparing them with well log data.




Fig. 1 The horizontal slice of the integrated attribute, derived from five geomechanical parameters, highlights a selected area with high hydrocarbon potential.




Fig. 2 illustrates the Mu-Rho versus Lambda-Rho plot for the selected location (Figure 1), demonstrating better lithological separation than previous cross-plots. Shale and oil sandstone are completely separated, while gas limestone displays a distinct trend from regular limestone. Unlike the previous cross-plots, where overlaps or similar trends were sometimes observed, this plot provides clearer lithological distinction.




Fig. 3 displays a Poisson's ratio versus Lambda-Rho cross plot for the selected location (Fig. 1). This plot reveals a distinct pattern where the hydrocarbon-bearing zone, specifically the oil sandstone, stands out clearly. As the most important part of the reservoir, the oil zone is easily distinguishable within this plot.

There was a 90% correlation for P impedance and 80% for Young's modulus, indicating the reliability of this method (Fig. 4). This procedure provides the reservoir

identification and hydrocarbon exploration process with higher accuracy, lower cost, and lower risk.




Fig. 4 Cross-plot comparing inverted P-wave impedance and Young's modulus with P-wave impedance and Young's modulus from Well B.

Conclusions

This study successfully identified areas with high hydrocarbon potential through 3D seismic data and integrated geomechanical attributes. The study used four scatter plots to separate four major lithologies and obtained consistent trends that can be used in other oilfields to reduce risks and make drilling decisions more accurate. Although all scatter plots were effective, some were more accurate based on the quality of the seismic data and inversion techniques. By converting the inversion results into geomechanical parameters, hydrocarbon potential and reservoir thickness, this study provided an economical and convenient method for reservoir characterization and drilling site selection.

References

1. Al-Garbawi, Z. H. A., & Al-Shahwan, M. F. (2019). Petrophysical evaluation for the reservoir units of Nahr-Umr formation in the luhais oil field south of Iraq. *The Iraqi Geological Journal*, 83–100.
2. Hampson, D. P., Russell, B. H., & Bankhead, B. (2005). Simultaneous inversion of pre-stack seismic data. In *SEG Technical Program Expanded Abstracts 2005* (pp. 1633–1637). Society of Exploration Geophysicists.
3. Odoh, B. I., & Nwokeabia, C. N. (2024). Synergy in the Subsurface: Revolutionizing Reservoir Characterization through Integrated Geophysics and Rock Physics. *International Journal of Research and Innovation in Applied Science*, 9(8), 756–764.
4. Riahi, Z. T., Sarkarinejad, K., Faghih, A., Soleimany, B., & Payrovian, G. R. (2021). Impact of inversion tectonics on the spatial distribution of hydrocarbon traps in the NW Persian Gulf and the southern Dezful Embayment, SW Iran. *Marine and Petroleum Geology*, 134, 105364.
5. Sena, A., Castillo, G., Chesser, K., Voisey, S., Estrada, J., Carcuz, J., Carmona, E., & Schneider, R. V. (2011). Seismic reservoir characterization in resource shale plays: “sweet spot” discrimination and optimization of horizontal well placement. *SEG International Exposition and Annual Meeting, SEG-2011*.
6. Zhou, B., Zhang, X., Zhao, L., Zhou, B., Chen, L., & Lu, Y. (2023). Pre-drilling prediction of 3D geomechanical parameters based on seismic data: A case study of Tarim Oilfield. *ARMA US Rock Mechanics/Geomechanics Symposium, ARMA-2023*.

مقایسه معماری خودرمنگار پیچشی و تبدیل کننده بینایی در نویززدایی و بازسازی تصاویر سنگ‌های مخازن شکافدار زیرزمینی

بهراد تبریزی پور

دانشکده مهندسی نفت، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ دریافت: ۱۴۰۴/۰۸/۰۶ تاریخ تغییر: ۱۴۰۴/۰۹/۰۹ تاریخ پذیرش: ۱۴۰۴/۱۱/۱۸

چکیده

سنگ‌های مخزنی شکافدار از مهم‌ترین اهداف در مطالعات مهندسی نفت به‌شمار می‌آیند، زیرا شبکه‌های پیچیده شکستگی‌ها و شکاف‌ها نقش تعیین‌کننده‌ای در تخلخل و نفوذپذیری این مخازن دارند. تصاویر سیتی‌اسکن به‌عنوان ابزاری کلیدی برای تحلیل ساختار درونی این سنگ‌ها استفاده می‌شوند، اما افت کیفیت تصاویر معمولاً بازسازی دقیق آن‌ها را دشوار می‌کند. در این پژوهش، دو معماری یادگیری عمیق شامل خودرمنگار پیچشی و تبدیل کننده بینایی با هدف بهبود کیفیت و بازسازی تصاویر سیتی‌اسکن سنگ‌های مخزنی شکافدار طراحی و مقایسه شدند. وظیفه اصلی مدل‌ها بازسازی و نویززدایی تصاویر شکافدار زیرسطحی بوده و پس از بازسازی، فرآیند بخش‌بندی سه‌کلاسه شامل ماتریکس، شکاف باز و شکاف پر شده با استفاده از روش کلاسیک آستانه‌گذاری اتسو جهت بررسی عملکرد بهتر نتایج تصاویر بازسازی شده روی خروجی مدل‌ها اعمال شد. نتایج کمی و کیفی نشان داد که تبدیل کننده بینایی به‌واسطه بهره‌گیری از سازوکار توجه، عملکرد برتری نسبت به خودرمنگار دارد. این مدل در بازسازی تصاویر به نسبت سیگنال به نویز اوج ۴۵ و شاخص شباهت ساختاری ۰/۹۸ دست یافت، درحالی‌که خودرمنگار به ترتیب مقادیر ۳۹ و ۰/۹۳ را ثبت کرد. در بخش‌بندی سه‌کلاسه مبتنی بر روش اتسو نیز تبدیل کننده بینایی در معیارهای دقت، بازخوانی و امتیاز F1 عملکرد بهتری داشت. برای کلاس ماتریکس، مقادیر دقت، بازخوانی و امتیاز F1 به ترتیب ۰/۹۸۹، ۰/۹۹۰ و ۰/۹۸۹ در مقایسه با ۰/۹۶۹، ۰/۹۷۴ و ۰/۹۲۰ برای خودرمنگار به دست آمد. در کلاس شکاف پر شده، نتایج ۰/۹۷۴، ۰/۹۵۳ و ۰/۹۶۳ و در کلاس شکاف باز ۰/۹۲۳، ۰/۹۲۰ و ۰/۹۲۱ حاصل شد؛ درحالی‌که مدل خودرمنگار مقادیر ۰/۹۶۰، ۰/۹۶۲، ۰/۹۶۱ و ۰/۹۴۰، ۰/۹۳۴، ۰/۹۳۷ را ثبت کرده بود. در مجموع، نتایج نشان می‌دهد که تبدیل کننده بینایی گزینه‌ای کارآمدتر و دقیق‌تر برای بازسازی تصاویر سیتی‌اسکن سنگ‌های شکافدار است و می‌تواند نقش مهمی در بهبود تحلیل‌های عددی خواص سنگ از جمله تخلخل و نفوذپذیری در مطالعات مهندسی مخزن ایفا کند.

کلمات کلیدی: بازسازی تصاویر، معماری خودرمنگار، تبدیل کننده بینایی، نسبت سیگنال به نویز اوج، شاخص شباهت ساختاری.

مقدمه

مخازن شکافدار از پیچیده‌ترین سامانه‌های زمین‌شناختی در مهندسی نفت به‌شمار می‌روند؛ زیرا رفتار جریان سیال در آن‌ها حاصل برهم‌کنش میان ماتریکس سنگ و شبکه شکستگی‌ها است. ناهمگنی هندسی، تغییرپذیری ابعاد و میزان پیوستگی شکستگی‌ها، توصیف دقیق ساختار داخلی این مخازن و پیش‌بینی رفتار تولیدی آن‌ها را با دشواری همراه می‌کند. از این‌رو، شناسایی صحیح شکستگی‌ها و بررسی دقیق ویژگی‌های ساختاری سنگ، نقش مهمی در کاهش عدم قطعیت، بهینه‌سازی عملیات حفاری و مدیریت مؤثر مخزن دارد. در همین راستا، پژوهش‌های متعددی برای شناسایی، مدل‌سازی و تحلیل مخازن شکافدار انجام شده است. در تحقیقی، از شبکه عصبی مصنوعی (ANN) برای شناسایی نقاط شکافدار در مخازن کربناته استفاده شد که پیچیدگی توزیع ترک‌ها و نقش حیاتی آن‌ها در بهینه‌سازی استراتژی‌های حفاری و مدیریت مخزن را نشان می‌دهد [۱]. همچنین، ولسون و همکاران به‌طور جامع به بررسی شناسایی و مدل‌سازی ترک‌ها در مخازن شکافدار طبیعی پرداخته‌اند و تأثیر این ترک‌ها بر افزایش بازیابی نفت را برجسته کرده‌اند [۲]. سان و همکارش نیز بر اهمیت این مخازن به‌عنوان منابع اصلی تأمین انرژی جهانی تأکید دارند و به توسعه طبقه‌بندی‌های دقیق‌تر برای مدیریت مؤثرتر این مخازن پرداخته‌اند [۳]. در مطالعه‌ای از لیو و همکاران، نقش ترک‌ها و شکستگی‌ها به‌عنوان کانال‌های نفوذ و فضای ذخیره‌سازی در سنگ‌های ماسه‌ای فشرده مورد بررسی قرار گرفته که این ویژگی‌ها بر غنی‌سازی و تولید نفت اثرگذار است [۴]. در نهایت، هاشمی و همکاران و الربوی ویژگی‌های منحصر به فرد مخازن شکافدار، شامل تخلخل ماتریکس و هدایت ترک‌ها را تحلیل کرده و اهمیت آن‌ها را در جریان سیالات و بهینه‌سازی تولید بیان کرده‌اند. این تحقیقات نشان‌دهنده

اهمیت شناخت و مدیریت دقیق مخازن شکافدار در توسعه بهینه منابع نفت و گاز هستند [۵ و ۶]. داده‌های تصویری در توصیف دقیق سنگ‌های مخزن اهمیت ویژه‌ای دارند، زیرا امکان بررسی ریزساختار، تخلخل و شکستگی‌ها را به‌صورت غیرمخرب و با جزئیات بالا فراهم می‌کنند. تکنولوژی سیتی اسکن یکی از ابزارهای اصلی و پیشرفته در این حوزه است که توانسته است با ارائه تصویربرداری سه‌بعدی با وضوح بالا، اطلاعات دقیقی از ساختار داخلی سنگ مخزن به‌دست آورد. ژو و همکاران نشان می‌دهند که سیتی اسکن نسبت به روش‌های سنتی که معمولاً مستلزم نمونه‌برداری مخرب و تحلیل‌های مستقیم هستند، مزیت‌های فراوانی دارد که می‌توان به امکان تصویربرداری غیرمخرب، بررسی دقیق‌تر توزیع تخلخل و تحلیل رفتار جریان سیالات در داخل منافذ و ترک‌ها اشاره کرد [۷]. از سوی دیگر، فیسال و همکاران نشان داده‌اند که سیتی اسکن می‌تواند به‌صورت کمی ساختارهای لایه‌های گل حفاری و آسیب‌های مخزن را نیز بررسی کند و با مزیت روش‌های غیرمخرب در مقایسه با تحلیل‌های کلاسیک، اطلاعات ارزشمندی ارائه دهد [۸]. کاپوچینو و همکاران نیز با تأکید بر تصویربرداری سه‌بعدی سیتی اسکن، مزایای این ابزار در مطالعه تخلخل ماتریکس و شکستگی‌ها را برجسته ساخته‌اند که در روش‌های مستقیم و مخرب قابل دسترسی نیست [۹]. این مطالعات نشان می‌دهند که سیتی اسکن نقش بسیار مهمی در افزایش دقت و کیفیت مطالعات مخازن نفت ایفا می‌کند و تبدیل به ابزار ضروری در علم سنگ شده است. این مطالعات به‌صورت جامع چالش‌های موجود در استفاده از داده‌های سیتی اسکن برای مطالعه مخازن نفت را بررسی می‌کنند و راهکارهایی برای بهبود کیفیت تصاویر ارائه می‌دهند که می‌تواند در بهبود دقت تحلیل خواص سنگ‌ها و مدل‌سازی مخازن حیاتی باشد. داده‌های تصویربرداری سیتی اسکن با وجود مزایای فراوانی که ارائه می‌دهند،

روش‌های پیشرفته‌تری مانند BM3D قادر به حذف نویز بدون آسیب‌زدن به ساختارهای بافتی مهم هستند [۱۲]. فنگ و همکاران نیز در زمینه بازسازی تصاویر نویزی سیتی اسکن، گزارش کردند که فیلترهای متداول در مواجهه با ساختارهای پیچیده و ناهمگن سنگ‌های مخزنی عملکرد ضعیفی دارند و در حفظ هندسه شکستگی‌ها ناکام می‌مانند [۱۳]. علاوه‌براین، مطالعات اخیر مانند پژوهش ساهو و همکاران که روش‌های ترکیبی موجک و شبکه‌های عمیق سه‌بعدی را بررسی کرده‌اند، نشان می‌دهد ترکیب فیلترهای موجک با معماری‌های پیچشی می‌تواند در تشخیص و بازسازی ترک‌های ریز در تصاویر میکروسیتی عملکرد بهتری ارائه دهد. با این حال، حتی این روش‌های کلاسیک-ترکیبی نیز در محیط‌های بسیار پیچیده محدودیت دارند [۱۴]. به‌عنوان نمونه، متیو و همکاران در تصویربرداری میکروسیتی جریان‌های چندفازی مخازن متخلخل نشان دادند که روش‌هایی مانند NLM و انتشار ناهمسانگرد علی‌رغم بهبود سیگنال، نمی‌توانند پیوستگی منافذ ریز و ویژگی‌های چندمقیاسی را به‌درستی حفظ کنند [۱۵]. این یافته‌ها تأکید می‌کنند که در مواجهه با ساختارهای پیچیده و نویزی سنگ‌های شکافدار، استفاده از روش‌های پیشرفته‌تر و مبتنی بر یادگیری عمیق ضروری است و روش‌های کلاسیک به‌تنهایی پاسخگوی نیازهای بازسازی دقیق تصاویر نیستند. روش‌های یادگیری عمیق تحول عظیمی در پردازش تصویر ایجاد کرده‌اند و به‌ویژه در تصویربرداری پزشکی و تحلیل ساختارهای پیچیده مانند مخازن نفت کاربردهای گسترده‌ای یافته‌اند. کوئزیر همکاران اصول فنی بازسازی تصویر سیتی اسکن با یادگیری عمیق را بررسی کرده و نشان دادند که این روش‌ها نسبت به تکنیک‌های سنتی، در حفظ جزئیات تصویر دقت بالاتری دارند [۱۶]. همچنین جانسس و همکاران با بهره‌گیری از شبکه‌های مولد متخاصم موفق به افزایش وضوح تصاویر سیتی اسکن و

چالش‌های مهمی نیز همراه دارند که باید به آنها توجه شود. یکی از اصلی‌ترین مشکلات، نویز بالای تصاویر است که به‌دلیل پراکندگی اشعه ایکس و محدودیت‌های رزولوشن دستگاه‌های سیتی اسکن رخ می‌دهد، این مسئله منجر به کاهش کیفیت تصاویر و خطا در تفسیر دقیق خواص سنگ‌ها می‌شود. سلطان محمدی و همکارش این موضوع را به‌صورت جامع بررسی و تأکید دارند که نویز ناشی از شرایط تصویربرداری می‌تواند دقت تحلیل‌های پتروفیزیکی را به‌شدت کاهش دهد [۱۰]. برای حل این مشکل، روش‌های پیشرفته‌ای برای نویززدایی و بازسازی تصویر توسعه یافته‌اند که در تحقیقات خود به معرفی تکنیک‌های نوین بازسازی تصویر پرداخته و بهبود وضوح تصاویر و کاهش خطاهای تفسیر داده‌ها را نشان داده‌اند. همچنین بیژنی و همکاران اهمیت استفاده از الگوریتم‌های یادگیری عمیق جهت افزایش کیفیت داده‌های سیتی اسکن و کاهش نویز را برجسته کرده‌اند که این امر برای تحلیل‌های دقیق‌تر و مدل‌سازی بهتر مخازن حیاتی است [۱۱]. این یافته‌ها بر اهمیت شناسایی دقیق ساختار شکستگی‌ها و تحلیل صحیح رفتار سنگ برای پیش‌بینی واکنش‌های سیال‌سنگ در مخازن شکافدار تأکید دارند. این مطالعات نشان می‌دهند که با وجود چالش‌های موجود، استفاده از روش‌هایی که در پردازش تصاویر سیتی اسکن وجود دارند می‌توانند کیفیت داده‌های نهایی را بهبود بخشند و تفسیر درست خواص سنگ را تسهیل کند.

روش‌های کلاسیک نویززدایی مانند فیلترهای گاوسی، میانه و موجک اگرچه در تصویربرداری سیتی اسکن رایج هستند، اما مطالعات نشان داده‌اند که این روش‌ها در حفظ جزئیات ظریف با محدودیت جدی مواجه‌اند. شاهمرادی و همکاران در بررسی تجربی خود نشان دادند که فیلترهای کلاسیک با وجود کاهش نویز، موجب محوشدگی لبه‌ها و از دست رفتن بافت‌های ریز تصویر می‌شوند، درحالی‌که

بهبود بازسازی سه بعدی شده اند که در تحلیل ساختارهای پیچیده مخازن نقش به سزایی دارد [۱۷]. در سال های اخیر، کاربردهای خاص در تحلیل سنگ ها و نمونه های متخلخل با استفاده از شبکه های عصبی گراف و تکنیک های مبتنی بر یادگیری انتقال پذیر توسعه یافته است. این تحقیقات به طور خاص در تشخیص شکستگی ها و ساختارهای ریز در سنگ های شکاف دار و ناپایدار، با تمرکز بر دقت و سرعت بالا، موفق بوده اند. با این حال، محدودیت اصلی این مطالعات این است که اغلب بر روی سنگ های همگن و غیر شکاف دار تمرکز دارند و کمتر به ساختارهای پیچیده و ناهمگن در مخازن شکاف دار توجه شده است [۱۸]. در حوزه تحلیل مخازن شکاف دار، فن آوری های پیشرفته تر مانند شبکه های مولد متخاصم و روش های ژنراتیو، نتایج قابل توجهی در افزایش وضوح و کاهش نویز ارائه داده اند که در بعضی موارد توانسته اند عملکرد برتری نسبت به روش های سنتی نشان دهند اما هنوز در مواجهه با ساختارهای پیچیده و ناپایدار، دقت کامل حاصل نشده است [۱۹]. در نهایت، همزمان با پیشرفت های فن آوری، چالش های مربوط به دقت، پیچیدگی ساختارهای ناپایدار و محدودیت منابع داده از جمله تصاویر مخازن شکاف دار همچنان باقی است و نیازمند توسعه روش های ترکیبی و نوآورانه در تحلیل های تصویری مخازن شکاف دار است. با وجود پیشرفت های چشمگیر در پردازش تصاویر سیتی اسکن، بازسازی دقیق ساختارهای پیچیده در مخازن شکاف دار همچنان با محدودیت هایی مواجه است. روش های کلاسیک نویززدایی نظیر فیلترهای گاوسی، میانه و موجک علی رغم کارایی اولیه در کاهش نویز، توان کافی در حفظ جزئیات حیاتی مانند ریزترک ها، مرزهای ماتریکس-شکاف و اتصال شکستگی ها را ندارند. از سوی دیگر، اغلب رویکردهای مبتنی بر یادگیری عمیق موجود، عمدتاً بر نمونه های همگن و بدون شکستگی متمرکز بوده و در مواجهه با داده های

پیچیده، نویزی و ناهمگن حاصل از تصویربرداری سنگ های شکاف دار، عملکرد مطلوبی در بازسازی ساختارهای ناپیوسته و حفظ ویژگی های فضایی ارائه نمی دهند. در این تحقیق، با بهره گیری از روش های مرتبط با یادگیری عمیق، چارچوبی نوین برای بازسازی تصاویر سیتی اسکن توسعه داده شده است که ضمن کاهش نویز، قادر به حفظ دقیق جهت گیری، پیوستگی و هندسه شکستگی ها می باشد. طراحی بهینه معماری مدل، انتخاب مناسب ابر پارامترها باعث شده است تا خروجی مدل به طور مستقیم قابل استفاده در تحلیل های پتروفیزیکی از جمله شبیه سازی نفوذپذیری، تخلخل دوگانه و جریان سیال در محیط های مخزنی پیچیده باشد. منظور از تخلخل دوگانه در این پژوهش، تخلخل مخازن شکاف دار با دو مؤلفه مجزای تخلخل ماتریکس (ϕ_m) و تخلخل شکستگی (ϕ_f) است؛ به طوری که ماتریکس نقش اصلی در ذخیره سازی سیال و شکستگی ها نقش غالب در انتقال سیال را دارد و برهم کنش این دو محیط رفتار جریان را تعیین می کند. این رویکرد، گامی مؤثر در بهبود کیفیت داده های تصویری و ارتقاء دقت مدل سازی دیجیتال سنگ محسوب می شود. **جدول ۱** مروری ساختاریافته بر روش ها و معماری های رایج در پردازش تصاویر سنگ ارائه می دهد. همان طور که مشاهده می شود، روش های کلاسیک با وجود سرعت بالا، در حفظ ریزشکاف ها محدودیت دارند، در حالی که معماری های یادگیری عمیق به ویژه مدل های مبتنی بر توجه، توان بالاتری در بازسازی ساختارهای پیچیده و ناپیوسته شکستگی ها نشان داده اند. بر این اساس، در این پژوهش دو معماری CAE و ViT برای ارزیابی نقش معماری در کیفیت بازسازی شکستگی ها مقایسه شده اند. در راستای رفع شکاف های موجود در ادبیات و با توجه به چالش های مطرح شده، این پژوهش مجموعه ای از نوآوری ها و مشارکت های علمی مشخص را ارائه می دهد که در ادامه به صورت خلاصه بیان می شوند:

جدول ۱ مروری بر مطالعات گذشته بروی تصاویر سنگ جهت بازسازی یا نویرزدایی تصویر

Table 1 A Review of Previous Studies on Rock Image Reconstruction and Denoising

Method/Architecture	Representative Author(s)	Main Application in Rock CT Images	Strengths	Limitations	Suitable Application Domain/Scale
Local Classical Methods (Wavelet, Gaussian, and Median Filters)	Shahmoradi et al.	Preliminary denoising	Simple, fast, and requires no training	Edge blurring, loss of microfractures and textures, and poor performance in heterogeneous structures	Rapid preprocessing and low-to-moderate noise levels
Classical Non-Local Methods (NLM and Similar Approaches)	Mathew et al.	Texture-preserving denoising	Better texture preservation than local filters	Parameter sensitivity, high computational cost in 3D, and reduced performance under severe noise	Moderate noise levels and repetitive pore/fracture structures
BM3D/Non-Local Transform Methods	Shahmoradi et al.	Advanced denoising	Better preservation of fine details and edges than local methods	Higher computational cost and limited performance for complex structural noise	CT images with moderate-to-high noise, particularly when microfracture preservation is important
CNN-Based Denoising and Reconstruction Networks (DnCNN, ResNet, CAE, and Similar Models)	Bizhani, Haeri Ardakani, and Little	Denoising and image reconstruction	Learns noise patterns, provides fast inference, and effectively preserves fracture edges	Requires training data and may cause oversmoothing in sparsely distributed fracture structures	Widely used in digital rock physics and CT imaging; suitable for extracting local features
CNN/Residual Super-Resolution Networks (SR-CNN, VDSR, and Residual Attention SR)	Murugesu et al.	Super-resolution and recovery of sub-resolution details	Improves image resolution and the accuracy of pore and fracture boundaries	Requires paired HR/LR data or a robust unsupervised training strategy	Suitable for addressing the field-of-view-resolution trade-off in CT images
Segmentation Transformers (Swin-T, TransUNet, and Hybrid Models)	Chen et al.; Brondolo et al.	Accurate segmentation of multiscale structures	Models long-range dependencies and performs well on discontinuous structures	Requires more training data and computational resources	Heterogeneous and fractured rocks with complex fracture networks
GANs and SRGANs for Digital Rock Physics	Janssens, Huysmans, and Swennen	Super-resolution and reconstruction of textures and microstructures	Recovers high-frequency details and improves pore and fracture connectivity	Risk of hallucinated features, unstable training, and high computational cost	Complex and noisy rock structures where texture preservation is critical

قابل قبول باقی بماند. این تفکیک بیشتر، حجم داده را به بیش از ۱۱,۲۰۰ تصویر افزایش داد. در مرحله پیش پردازش، تصاویر فاقد شکستگی و شامل تنها ماتریکس حذف شدند؛ تعداد این تصویرها حدود ۲۴۰۰ مورد، معادل تقریباً ۲۱٪ از کل تصاویر اولیه بود. پس از حذف این نمونه‌ها، حدود ۸۸۰۰ تصویر باقی ماند. برای ایجاد توازن در نمایش دو نوع شکستگی «شکاف باز» و «شکاف پر شده»، تنها تصاویری انتخاب شدند که نسبت حضور این دو الگو در آنها یکنواخت بود؛ در نتیجه همان ۸۸۰۰ تصویر نهایی (حدود ۷۸٪ تصاویر اولیه) برای مراحل آموزش، اعتبارسنجی و آزمون مورد استفاده قرار گرفت. این داده‌ها در نهایت براساس نسبت ۸۰، ۱۰ و ۱۰٪ به ترتیب به ۷۰۴۰ نمونه آموزشی، ۸۸۰ نمونه اعتبارسنجی و ۸۸۰ نمونه آزمون تقسیم شدند. به منظور افزایش حجم داده‌ها و بهبود تعمیم‌پذیری مدل، از مجموعه‌ای از تبدیل‌های داده‌افزایی مبتنی بر تبدیلات هندسی استفاده شد. برای هر تصویر اولیه، سه نمونه افزوده شده تولید گردید که شامل وارونگی افقی تصادفی، وارونگی عمودی تصادفی و چرخش تصادفی در بازه $15^\circ \pm$ بود. علاوه بر این، برش مرکزی به عنوان مرحله پیش پردازش بر روی تمام تصاویر (اصلی و افزوده شده) اعمال شد تا ناحیه مرکزی تصویر با ابعاد ثابت (۶۴) استخراج شود، بدون آن که خود این تبدیل منجر به افزایش تعداد نمونه‌ها گردد. در نتیجه، تعداد تصاویر آموزشی از ۷۰۴۰ تصویر اولیه (قبل از داده‌افزایی) به ۲۸۱۶۰ تصویر پس از داده‌افزایی افزایش یافت که معادل یک افزایش تقریباً ۴ برابری در حجم داده است (جدول ۲). از آنجا که این تبدیل‌ها هندسه و توپولوژی شکستگی‌ها را حفظ می‌کنند، کیفیت ساختاری داده‌های افزوده شده با داده‌های اصلی هم‌راستا باقی می‌ماند. برای اطمینان از کیفیت، بخشی از داده‌های افزوده شده به صورت تصادفی بازبینی شد؛ نتایج نشان داد که مرز شکستگی‌ها،

(۱) یک چارچوب جدید مبتنی بر یادگیری عمیق برای نوینزدایی و بازسازی تصاویر سنگ‌های مخازن شکافدار، با هدف حفظ هندسه و پیوستگی شکستگی‌ها. (۲) مقایسه جامع دو معماری خودرمنگذار پیش‌بینی و تبدیل‌کننده بینایی برای ارزیابی دقیق تأثیر معماری مدل بر کیفیت بازسازی. (۳) به کارگیری معیارهای استاندارد نسبت سیگنال به نویز اوج، شاخص شباهت ساختاری، برای ارزیابی کمی، که نشان‌دهنده برتری تبدیل‌کننده بینایی در حفظ جزئیات ریز است.

(۴) استفاده از روش اتسو برای بخش‌بندی تصاویر بازسازی شده و واقعی جهت ارزیابی بیشتر تصاویر بازسازی شده نسبت به تصاویر واقعی به کمک معیارهایی نظیر شاخص جاکارد، امتیاز F1 و غیره.

روش کار

پیش پردازش داده‌ها

داده‌های خام این پژوهش از پایگاه Digital Rock Portal و توسط اسپینوزا و همکاران تهیه شده‌اند که شامل تصاویر سی‌تی اسکن از نمونه‌های مخازن شکافدار زغال‌سنگی هستند (آدرس اینترنتی: <https://digi-talporousmedia.org/published-datasets/drp.project.published.DRP-21>). [۲۰] برای افزایش تعداد داده‌ها و تسهیل تحلیل محلی، تصاویر به قطعات 128×128 پیکسلی تقسیم شدند؛ پس از دریافت داده‌های خام، مجموع ۲۶۳۸ تصویر مورد استفاده قرار گرفت و مطابق روال اصلی، پیش از هرگونه پردازش و برای جلوگیری از نشت اطلاعات، با نسبت ۱۰/۱۰/۸۰ به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شد. اسلایس‌های هر بخش سپس با یک اسکریپت اختصاصی به تصاویر 128×128 پیکسل تفکیک شدند. اندازه تصویر به صورت هدفمند انتخاب شد؛ به قدری بزرگ که اطلاعات بافتی و جزئیات لازم برای تشخیص شکستگی را حفظ کند، و در عین حال به اندازه‌ای کوچک که زمان محاسباتی در حد

Table 2. Number of Training Images After the Data Augmentation Process

جدول ۲ تعداد داده‌های آموزش بعد از فرآیند داده افزایی

Data Augmentation Type	Total Number Added	Quality/Effect Description
Random Horizontal Flipping	7,040	Preserves fracture geometry, increases the diversity of horizontal patterns, and maintains the original topology
Random Vertical Flipping	7,040	Increases the spatial diversity of fractures while preserving boundaries and structural continuity
Random Rotation Within $\pm 15^\circ$	7,040	Increases orientation diversity without degrading microfracture structures or boundaries
Total Number of Augmented Images	21,120	Increases the overall dataset size
Final Number of Images After Data Augmentation	28,160	Approximately four times the initial dataset size of 7,040 images

شکاف‌دار، دو معماری یادگیری عمیق شامل خودرمزگذار پیچشی و تبدیل‌کننده‌بینایی طراحی و ارزیابی شدند. داده‌های ورودی شامل برش‌های سیتی اسکن با وضوح بالا بودند که ساختارهای پیچیده‌ای مانند ریزشکاف‌ها، شکستگی‌های متصل و نواحی ناهمگن ماتریکسی را نمایش می‌دادند. هدف اصلی مدل‌ها حذف نویز و تولید تصاویر بازسازی‌شده‌ای بود که هندسه، جهت‌گیری و پیوستگی شکستگی‌ها را بدون تخریب حفظ کنند. نتایج کمی و کیفی نشان داد که تبدیل‌کننده‌بینایی در حفظ جزئیات ریز و ساختارهای چندمقیاسی عملکرد بهتری نسبت به خودرمزگذار دارد و می‌تواند داده‌های قابل اعتمادتری برای مراحل بعدی تحلیل دیجیتال سنگ، مانند شبیه‌سازی نفوذپذیری و جریان سیال، فراهم کند.

بخش‌بندی پایین‌دستی شکاف‌ها با آستانه‌گذاری ا تسو

در این مطالعه، به‌منظور ارزیابی کیفیت بازسازی و میزان حفظ ساختارهای شکستگی، از روش آستانه‌گذاری چندسطحی ا تسو به‌عنوان یک ابزار بخش‌بندی پایین‌دستی استفاده شد. این روش که مبتنی بر تحلیل هیستوگرام است و نیازی به آموزش ندارد، ماسک‌های سه‌کلاسه شامل ماتریکس، شکاف باز و شکاف پرشده را تولید می‌کند تا امکان بررسی تفکیک‌پذیری و حفظ مرزهای شکستگی پس از بازسازی فراهم شود.

پیوستگی شبکه‌شکستگی‌ها و توزیع شدت پیکسل‌ها در تصاویر افزوده‌شده پایدار بوده و هیستوگرام آن‌ها تفاوت معناداری با داده‌های اصلی ندارد. این روش‌ها تنوع هندسی داده‌ها را افزایش داده و محدودیت تعداد نمونه‌های واقعی (مانند نمونه‌های مغزه) را جبران کردند، که در فیزیک سنگ دیجیتال برای شبیه‌سازی خواص فیزیکی مانند نفوذپذیری حیاتی است. داده‌های افزوده‌شده به تنسورهای پایتورچ تبدیل و نرمال‌سازی شدند تا توزیع مناسب برای ورودی مدل‌های یادگیری عمیق فراهم شود. این نرمال‌سازی، پایداری گرادین‌ها را در آموزش تضمین کرده و همگرایی را تسریع می‌کند، که برای پردازش تصاویر سیتی‌اسکن با کنتراست بالا در فیزیک سنگ دیجیتال ضروری است. همچنین لازم به ذکر است که نحوه نرمال‌سازی براساس میانگین و انحراف معیار واقعی داده‌های آموزش تعیین شده است؛ به این معنا که مقادیر آماری مجموعه‌داده ابتدا محاسبه شده و سپس روش نرمال‌سازی به‌گونه‌ای انتخاب شده که با توزیع شدت‌های تصاویر سازگار باشد. این رویکرد داده‌محور، توزیع ورودی یکنواخت‌تری ایجاد کرده و موجب پایداری عددی بیشتر در فرآیند آموزش مدل شد.

بازسازی تصاویر با استفاده از خودرمزگذار و تبدیل‌کننده بینایی

برای بازسازی تصاویر سیتی سنگ‌های مخازن

بدون نظارت یاد می‌گیرند. ارزیابی تفاوت این دو نوع شکستگی از طریق بخش‌بندی پایین‌دستی انجام شد؛ بدین صورت که آستانه‌گذاری چندسطحی اتسو سه کلاس ماتریکس، شکاف باز و شکاف پر شده را براساس سطوح شدت خاکستری از یکدیگر جدا می‌کند (شکاف‌های باز معمولاً نواحی کم شدت/تیره‌تر و شکاف‌های پر شده نواحی با شدت بالاتر نسبت به شکاف باز هستند). **جدول ۳ و ۴** نشان‌دهنده پارامترهای بهینه استفاده شده در مدل‌سازی نهایی خودرمزگذار و تبدیل‌کننده بینایی می‌باشد.

سپس معیارهای $F1\text{-score}$ ، $Recall$ ، $Precision$ و $Jac\text{-}card$ برای هر کلاس به صورت مستقل محاسبه شده و عملکرد مدل‌ها در بازسازی و حفظ مرزهای «شکاف باز» و «شکاف پر شده» به طور جداگانه مقایسه گردید (**جدول‌های ۴ و ۵** در بخش نتایج). ماتریس سردرگمی نیز میزان اشتباه بین این دو کلاس را نشان می‌دهد. بنابراین مقادیر مربوط معیارهای ارزیابی این قسمت در این پژوهش تنها برای ارزیابی کیفیت بازسازی و میزان حفظ جزئیات شکستگی‌ها استفاده شده‌اند و نشان‌دهنده عملکرد مدل در یک وظیفه مستقل بخش‌بندی نیستند.

معیارهایی مانند جاکارد، امتیاز $F1$ براساس این ماسک‌ها محاسبه شدند و نقش آن‌ها تنها سنجش کیفیت بازسازی بوده است، زیرا بخش‌بندی هدف اصلی مدل‌ها نبوده و صرفاً برای ارزیابی نتایج بازسازی مورد استفاده قرار گرفته است. در این پژوهش، هدف اصلی مدل‌ها انجام بازسازی و نویززدایی تصاویر سنگ‌های مخازن شکاف‌دار است و بخش‌بندی نقش آموزشی یا مدل‌سازی ندارد. از آنجا که بخش‌بندی تنها به عنوان یک مرحله پایین‌دستی و برای ارزیابی میزان حفظ ساختارها پس از بازسازی استفاده شده است، به کارگیری یک معماری پیچیده و آموزش محور مانند U-Net که برای وظایف بخش‌بندی کاملاً نظارت‌شده طراحی شده است، در چارچوب مسئله حاضر ضرورت نداشته است. به همین دلیل، از روش کلاسیک آستانه‌گذاری چندسطحی اتسو استفاده شد که بدون نیاز به آموزش، امکان تولید ماسک‌های سه کلاسه (ماتریکس، شکاف باز و شکاف پر شده) را فراهم می‌کند و برای سنجش تفکیک‌پذیری ساختارها در تصاویر بازسازی‌شده کفایت می‌کند. در این پژوهش، تفکیک بین «شکاف باز» و «شکاف پر شده» در مرحله آموزش مدل‌ها انجام نمی‌شود و مدل‌ها صرفاً بازسازی تصویر را به صورت

جدول ۴ ابرپارامترهای بهینه بعد از استفاده جستجو شبکه در معماری تبدیل‌کننده بینایی

Table 4 Optimal Hyperparameters Obtained Using Grid Search for the Vision Transformer Architecture

Hyperparameter	Value
Batch Size	128
Loss Function	MSE
Optimizer	Adam
Optimizer Beta Parameters	(0.999, 0.9)
Weight Decay	0
Learning Rate	0.01
Number of Encoder Layers	8
Number of Attention Heads in the Encoder and Decoder	4
Feature Vector Size for Each Image	512

جدول ۳ ابرپارامترهای بهینه بعد از استفاده جستجو شبکه در معماری خودرمزگذار

Table 3 Optimal Hyperparameters Obtained Using Grid Search for the Autoencoder Architecture

Hyperparameter	Value
Batch Size	8
Loss Function	MAE
Optimizer	Adam
Optimizer Beta Parameters	(0.999, 0.9)
Weight Decay	0
Learning Rate	0.0001
Embedding Vector Size	128

جدول ۵ اطلاعات لازمه محاسباتی هردو مدل بازسازی تصویر

Table 5 Computational Requirements of the Two Image Reconstruction Models

Criterion	Autoencoder	Vision Transformer
GPU Model	RTX 3050	RTX 3050
Minimum Required GPU Memory	4 GB is sufficient	At least 8 GB for stable execution
System RAM Usage	2–3 GB	GB 7–4
Processing Speed	450–600 images/s	images/s 230–180
Time per Epoch	18–20 s	s 38–32
Number of Epochs to Convergence	25–30	50–40
Sensitivity to Increased Batch Size	Excellent scalability	Severe out-of-memory limitations
Training Stability	Moderate	Very high
Ability to Learn Non-Local Features	Limited	Very strong
Suitability for Large-Scale Datasets	Moderate	Excellent, but computationally expensive
Recommended Application	Resource-limited projects and rapid training	High-accuracy projects involving complex fracture structures
Overall Computational and Time Cost	Low	High, approximately 1.5–2 times that of the autoencoder

معماری خودرمزگذار تحقیق

معماری پایه خودرمزگذار توسط هینتون و همکارانش و به شکل گسترده تر معرفی شد که آن را به عنوان روشی برای کاهش ابعاد بدون استفاده از برچسب پیشنهاد دادند [۲۱ و ۲۲]. خودرمزگذار شامل دو بخش اصلی رمزگذار و رمزگشا می باشد. رمزگذار از چندین لایه پیچشی با فیلترهای ۳۲، ۶۴ و ۱۲۸ (به ترتیب برای لایه های اول تا سوم) برای کاهش بعد تشکیل شده است تا ویژگی های محلی مانند لبه های شکاف ها و بافت ماتریکس استخراج شوند. این لایه ها با تابع فعال ساز ReLU و max-pooling با کرنل ۲×۲ همراه بودند تا نویز تصاویر مانند نویز ناشی از محدودیت های تصویربرداری سی تی اسکن فیلتر شود. رمزگشا از لایه های پیچشی جابجا شده با ساختار معکوس برای افزایش بعد استفاده کرد تا تصاویر بازسازی شده با رزولوشن اصلی (۱۲۸×۱۲۸ پیکسل) تولید شوند. این معماری برای بازسازی جزئیات محلی شکاف ها بسیار مناسب است، زیرا در فیزیک سنگ دیجیتالی، دقت در مقیاس های

کوچک برای شبیه سازی جریان سیال در شکاف ها حیاتی است. برای تنظیم دقیق، از تکنیک عادی سازی دسته ای در لایه های میانی استفاده شد تا پایداری آموزش بهبود یابد.

معماری تبدیل کننده بینایی تحقیق

در این روش، برای بازسازی دقیق تصاویر سی تی اسکن سنگ های شکاف دار از معماری تبدیل کننده بینایی استفاده شد. این معماری نخستین بار توسط دوسوویتسکی و همکارانش معرفی شد [۲۳]. تفاوت اصلی آن با معماری های پیچشی رایج، استفاده از سازوکار توجه برای مدل سازی وابستگی های غیر محلی بین بخش های تصویر است که باعث می شود ساختارهای پیچیده تری مانند شکاف های متصل و ریز ترک ها به درستی شناسایی و بازسازی شوند.

ساختار پایه معماری تبدیل کننده بینایی

فرآیند تحلیل تصویر در تبدیل کننده بینایی به جای کانولوشن، مبتنی بر تقسیم تصویر به تصاویر مجزا و بررسی روابط بین آن ها است.

این ساختار شامل مراحل کلیدی زیر می‌باشد:

تقسیم تصویر به تصاویر ثابت

ابتدا تصویر سی‌تی اسکن با اندازه‌ی ثابت (مثلاً 128×128 پیکسل) به بخش‌های کوچک‌تر با اندازه مساوی (مثلاً 16×16 پیکسل) تقسیم می‌شود. هر تصویر دوبعدی به یک بردار ویژگی یک‌بعدی با طول ثابت تبدیل می‌شود. برای این کار، از یک لایه‌ی مسطح‌ساز برای تبدیل هر تصویر به یک بردار و سپس یک لایه کاملاً متصل برای نگاشت آن به فضای ویژگی استفاده می‌شود. معمولاً مقدار برابر با ۵۱۲ یا ۷۶۸ انتخاب می‌شود. این بردارها نشان‌دهنده ویژگی‌های آماری، بافتی و ساختاری هر تصویر هستند و پایه‌ای برای مدل‌سازی توجه بین تصاویرها در مراحل بعدی فراهم می‌کنند. از آنجا که تبدیل‌کننده‌بینایی برخلاف شبکه عصبی پیچشی فاقد سازوکار ضمنی برای درک موقعیت مکانی اجزای تصویر است، به هر بردار ویژگی یک بردار مکانی افزوده می‌شود تا موقعیت نسبی هر تصویر در تصویر حفظ گردد.

پردازش با لایه‌های رمنگار

پس از آماده‌سازی توالی تصاویر کدگذاری‌شده، این بردارها به لایه‌های متعدد خودتوجهی چندوجهی و شبکه عصبی مصنوعی وارد می‌شوند. سازوکار توجه سراسری در این لایه‌ها روابط بین تصاویر مختلف را بدون در نظر گرفتن فاصله مکانی، مدل‌سازی می‌کند. در این پژوهش، ۸ لایه رمزگذار با ۴ سازوکار توجه که دارای ضرب داخلی، مقیاس‌پذیری، گذر از تابع فعال‌ساز softmax و سپس ضرب داخلی مجدد میباشد (خروجی این ۴ سازوکار توجه با هم پیوند داده میشود) و بردار ویژگی با بعد ۵۱۲ استفاده شد.

بازسازی یا طبقه‌بندی نهایی با رمزگشا

خروجی نهایی معماری تبدیل‌کننده بینایی می‌تواند برای اهداف متنوعی از جمله بازسازی تصویر، طبقه‌بندی اجزا و تشخیص الگوها مورد استفاده قرار گیرد. لایه رمزگشا سه ورودی دریافت می‌کند؛

دو ورودی از سمت لایه رمزگذار و یک ورودی از خود رمزگشا. در این لایه نیز از سازوکار توجه بهره گرفته می‌شود، با این تفاوت که پس از مرحله‌ی مقیاس‌گذاری، یک ماسک به آن افزوده می‌شود که این فرآیند با عنوان توجه ماسک‌دار شناخته می‌شود. در این سازوکار، بخش بالایی مثلثی ماتریس توجه پس از عبور از تابع Softmax صفر می‌شود تا در عملیات ضرب برداری بعدی، مدل تنها به ورودی‌های جاری و پیشین تمرکز داشته باشد و از دسترسی به اطلاعات آینده، که از سمت رمزگذار تأمین می‌شوند، جلوگیری شود. زمانی که مدل به مرحله پردازش آن ورودی‌ها برسد، امکان توجه به تمامی ورودی‌ها از جمله ورودی‌های آینده نیز فراهم می‌گردد. در نهایت، با استفاده از لایه‌های رمزگشا، تصویر بازسازی‌شده‌ی نهایی تولید می‌شود. مزایای تبدیل‌کننده‌بینایی در تحلیل تصاویر سی‌تی اسکن مخازن شکاف‌دار

یکی از چالش‌های اصلی در تحلیل تصاویر سی‌تی اسکن سنگ‌های مخزن، پراکندگی شدید شکاف‌ها و نبود ساختار پیوسته در تصویر است. معماری تبدیل‌کننده‌بینایی با درک وابستگی‌های دوربرد قادر است الگوهای شکستگی را حتی اگر در فواصل زیاد از یکدیگر قرار داشته باشند، به خوبی شناسایی و بازسازی کند. همچنین، استفاده از بردارهای ویژگی برای هر تصویر، موجب می‌شود مدل نه تنها شکل هندسی، بلکه بافت و شدت خاکستری مناطق مختلف تصویر را نیز در نظر بگیرد.

معماری تبدیل‌کننده‌بینایی تحقیق

برای بازسازی دقیق تصاویر سی‌تی اسکن از سنگ‌های شکاف‌دار، مدلی مبتنی بر معماری تبدیل‌کننده‌بینایی طراحی شد. هدف این مدل، حفظ و بازسازی ساختارهای پیچیده مانند شکاف‌های متصل و ریزترک‌ها در تصاویر نویزی و کم‌وضوح است. در مرحله اول، تصویر ورودی با اندازه ۱۲۸ در ۱۲۸ پیکسل به تصاویری با ابعاد ۱۶ در ۱۶ تقسیم شد.

بینایی، داده‌های آماده و پیش‌پردازش شده به سه مجموعه تقسیم شدند: ۸۰٪ برای آموزش، ۱۰٪ برای اعتبارسنجی، و ۱۰٪ برای آزمایش. این تقسیم‌بندی به‌منظور اطمینان از تعادل بین یادگیری مدل، تنظیم ابر پارامترها، و ارزیابی عملکرد در داده‌های نادیده‌شده انجام شد. داده‌های آموزشی شامل تصاویر 128×128 پیکسل از مخازن شکافدار مانند سیتی اسکن بودند که با تکنیک‌های داده‌افزایی (مانند چرخش تصادفی و برش مرکزی) تقویت شده بودند تا تنوع کافی برای یادگیری الگوهای پیچیده شکاف‌ها فراهم شود. آموزش مدل‌ها با استفاده از کتابخانه پایتورچ و بهینه‌ساز آدام (با نرخ یادگیری اولیه ۰/۰۰۱) انجام شد. برای بهبود همگرایی و جلوگیری از بیش‌بردازش، از یک scheduler پویا برای تنظیم نرخ یادگیری که در این تحقیق از کاهش خطی برای هر دو مدل پس از ۵۰ اپوک استفاده شد.

نحوه بهبود مدل و بهینه‌سازی

در این مرحله، برای بهینه‌سازی عملکرد مدل روی داده‌های خاص مخازن شکافدار، تنظیم دقیق روی مدل‌های آموزش‌دیده انجام شد. وزن‌های لایه‌های پیچیده در خودرمزگذار و تبدیل‌کننده بینایی با استفاده از ۱۰٪ داده‌های اعتبارسنجی به‌روزرسانی شدند تا مدل حساسیت بیشتری به ویژگی‌هایی مانند میکروشکاف‌ها و اتصال شبکه شکاف‌ها پیدا کند. برای جلوگیری از بیش‌برازش، از تکنیک دراپ‌اوت با نرخ ۰/۲ در لایه‌های میانی استفاده شد. این کار باعث افزایش تعمیم‌پذیری مدل در مواجهه با داده‌های محدود و متنوع پایگاه Digital Rock Portal شد.

تنظیم ابرپارامترها با استفاده از روش جستجوی شبکه انجام شد تا مقادیر بهینه برای پارامترهای کلیدی شامل نرخ یادگیری (بین ۰/۰۰۰۱ تا ۰/۱)، اندازه دسته (۱۶، ۳۲، ۶۴)، توابع هزینه (MSE و MAE)، و توابع بهینه‌ساز (Adam, AdamW, SGD, RMSProp) تعیین شوند.

هر تصویر به‌عنوان یک واحد مستقل، پس از مسطح‌سازی، به برداری با طول ۵۱۲ نگاشت شد تا اطلاعات محلی آن در قالب بردار ویژگی حفظ گردد. این بردارها از طریق یک لایه خطی به فضای ویژگی منتقل شدند. سپس برای حفظ موقعیت مکانی هر تصویر در ساختار تصویر، بردارهای موقعیتی به توالی افزوده شد و مجموعه‌ی حاصل به‌عنوان ورودی به رمزگذار تبدیل‌کننده بینایی ارسال گردید. رمزگذار شامل یک یا چند لایه توجه با چند سر توجه بوده که با هدف درک روابط بین تصویرها در تصویر، وابستگی‌های غیرمحلی را نیز مدل می‌کند. پس از رمزگذاری بردارهای خروجی با میانگین‌گیری، فشرده‌سازی شده و به بردار نهفته‌ای در فضای ویژگی کاهش داده شدند. این بردار برای مرحله بازسازی به تعداد تصویرها تکرار شده و به‌عنوان ورودی دیکدر مورد استفاده قرار گرفت.

رمزگشا که ساختاری مشابه رمزگذار داشت، با استفاده از حافظه خروجی رمزگذار، توالی‌ای از بردارهای بازسازی‌شده تولید نمود. این بردارها سپس مجدداً به تصاویر تصویری بازگردانده شده و در موقعیت مکانی اولیه خود جای‌گذاری شدند تا تصویر نهایی با وضوح بالا بازسازی گردد. همچنین ابرپارامترهای بهینه مورد استفاده در این شبکه نیز در جدول‌های ۱ و ۲ مشخص شده است. تصاویر بازسازی‌شده با رزولوشن 128×128 پیکسل به‌عنوان تصاویر دیجیتال مخزن برای شبیه‌سازی عددی و پیش‌بینی خواص فیزیکی مانند نفوذپذیری، تخلخل دوگانه، و جریان سیال استفاده شدند. این خروجی‌ها در فیزیک سنگ دیجیتال برای پیش‌بینی رفتار مخزن در سناریوهای واقعی مانند تزریق آب یا شکست هیدرولیکی کاربرد دارند.

مدل‌سازی

نحوه آموزش و آزمایش

برای آموزش معماری‌های خودرمزگذار و تبدیل‌کننده

ساختاری (مانند لبه‌های شکاف) در فیزیک سنگ دیجیتال ضروری است. شاخص شباهت ساختاری با تمرکز بر حفظ ساختارهای فضایی و الگوهای شکاف (مانند اتصال شبکه‌های شکاف)، کیفیت بازسازی را از منظر شباهت ساختاری بررسی کرد. دیگر معیارهای ارزیابی مانند دقت، بازیابی، امتیاز F1، ماتریس سردرگمی و شاخص جاکارد نیز در این تحقیق برای بررسی دقت بازیابی کلاس‌های متنوع ماتریس، شکاف پر شده و شکاف خالی بین تصاویر اصلی و تصاویر بازسازی شده مورد استفاده قرار گرفت.

ارزیابی کمی کیفیت بازسازی تصاویر با شاخص‌های شاخص نسبت سیگنال به نویز اوج، شاخص شباهت ساختاری و معیارهای طبقه بندی

شاخص نسبت سیگنال به نویز اوج

نسبت سیگنال به نویز اوج یکی از متداول‌ترین معیارهای ارزیابی کیفیت بازسازی تصویر است که برای ارزیابی کیفیت تصویری در سیستم‌های فشرده‌سازی دیجیتال معرفی و به‌صورت گسترده در پردازش تصویر و یادگیری عمیق مورد استفاده قرار گرفت [۲۴]. این شاخص میزان انحراف تصویر بازسازی‌شده از تصویر مرجع را برحسب دسی‌بل بیان می‌کند و به‌صورت زیر تعریف می‌شود:

$$PSNR = 10 * \log_{10}((MAX^2)/MSE) \quad (1)$$

$$MSE = (1/(m * n)) * \sum_{i=1}^m \sum_{j=1}^n (I_{r(I_{ij})} - I_{t(I_{ij})})^2 \quad (2)$$

که در آن:

MAX: بیشترین مقدار ممکن برای یک پیکسل در تصویر. برای مثال در تصاویر ۸ بیتی خاکستری مقدار ۲۵۵ است چون پیکسل‌ها از ۰ تا ۲۵۵ مقدار می‌گیرند

MSE: میانگین مربعات خطا^۱ بین تصویر مرجع و تصویر بازسازی‌شده. هر چه MSE کمتر باشد، خطا کمتر و کیفیت بالاتر است.

از آنجاکه جستجوی شبکه به‌طور سنتی برای الگوریتم‌های یادگیری ماشین طراحی شده و در یادگیری عمیق به‌دلیل پیچیدگی محاسباتی مستقیماً قابل استفاده نیست، از یک ارتباط‌دهنده برای ارتباط دادن جستجوی شبکه با مدل‌های یادگیری عمیق استفاده شد. این ارتباط‌دهنده امکان جستجوی خودکار ابرپارامترها را در فضای بزرگ پارامترها فراهم کرد. فرآیند تنظیم با ارزیابی معیارهای عملکرد (مانند F1-score برای کلاس شکاف و شاخص شباهت ساختاری برای کیفیت بازسازی) روی مجموعه اعتبارسنجی انجام شد تا بهترین ترکیب ابرپارامترها انتخاب شود. علاوه‌براین، از تکنیک توقف زودهنگام استفاده شد تا آموزش در صورت عدم بهبود عملکرد روی مجموعه اعتبارسنجی پس از ۱۰ اپوک متوقف شود، که زمان محاسبات را کاهش داد و از بیش‌برازش جلوگیری کرد. برای بهبود کارایی محاسباتی، آموزش روی GPU مدل NVIDIA RTX 3050 انجام شد تا پردازش تصاویر ۱۲۸×۱۲۸ پیکسل با حجم بالا تسریع شود. این سخت‌افزار امکان اجرای سریع‌تر آموزش و تنظیم مدل‌ها را فراهم کرد، که برای مدیریت داده‌های پیچیده مخازن شکاف‌دار ضروری بود.

نحوه ارزیابی مدل روی داده‌های دیده نشده و آزمایش

ارزیابی با استفاده از معیارهای کمی شامل شاخص جاکارد، نسبت سیگنال به نویز اوج، شاخص شباهت ساختاری، و دیگر معیارهای ارزیابی پرکاربرد مدل‌های طبقه بندی انجام شد. دقت بخش‌بندی شکاف‌ها را در برابر ماتریکس سنجید، که به دلیل عدم تعادل ذاتی داده‌های مخازن شکاف‌دار (کمتر از ۱۰٪ شکاف در تصاویر) وجود دارد. شاخص جاکارد، میزان همپوشانی بین مناطق پیش‌بینی‌شده شکاف و مناطق واقعی را ارزیابی کرد. نسبت سیگنال به نویز اوج کیفیت بازسازی تصاویر را از نظر شباهت پیکسل‌به‌پیکسل با تصاویر مرجع سنجید، که برای اطمینان از حفظ جزئیات

1. Mean Squared Error

مقدار ۱ نشان‌دهنده شباهت کامل بین دو تصویر است. برخلاف نسبت سیگنال به نویز اوج که صرفاً براساس اختلاف پیکسل‌ها محاسبه می‌شود، شاخص شباهت ساختاری ساختارهای محلی تصویر را مقایسه کرده و حساسیت بیشتری نسبت به تغییرات بافت و روشنایی دارد.

دقت

شاخص دقت، نسبت پیکسل‌هایی را نشان می‌دهد که مدل به‌درستی به‌عنوان «مثبت» (مانند ناحیه شکاف) پیش‌بینی کرده است، نسبت به کل پیکسل‌هایی که مدل به‌عنوان مثبت تشخیص داده است [۲۶]. مقدار بالای دقت بیانگر توانایی مدل در کاهش خطاهای مثبت کاذب^۱ است؛ یعنی مدل از برچسب‌گذاری اشتباه نواحی غیرشکاف به‌عنوان شکاف جلوگیری می‌کند. این ویژگی در کاربردهایی مانند شناسایی شکستگی‌ها اهمیت بالایی دارد، زیرا از «بیش‌برآورد نواحی شکاف‌دار» جلوگیری می‌کند. فرمول محاسبه دقت به‌صورت زیر است:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (۴)$$

که در آن:

- TP (True Positive) تعداد پیکسل‌هایی است که مدل به‌درستی به‌عنوان شکاف (کلاس مثبت) پیش‌بینی کرده است.
- FP (False Positive) مواردی است که مدل به‌اشتباه پیکسل‌هایی را به‌عنوان شکاف شناسایی کرده درحالی‌که در واقع ماتریکس هستند.

بازخوانی یا یادآوری

شاخص بازخوانی نشان‌دهنده نسبت پیکسل‌های واقعی شکاف است که مدل آن‌ها را به‌درستی شناسایی کرده است. مقدار بالای این معیار به این معناست که مدل بیشتر شکاف‌های واقعی را تشخیص داده و نواحی شکستگی را از دست نداده است [۲۷].

فرمول آن به شکل زیر است:

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (۵)$$

1. False Positive

$I_r(i,j)$: مقدار پیکسل در سطر i و ستون j از تصویر واقعی

$I_t(i,j)$: مقدار پیکسل در همان موقعیت (i,j) از تصویر بازسازی‌شده یا فشرده‌شده

m : تعداد ستون‌های تصویر (عرض تصویر به تعداد پیکسل)

n : تعداد سطرهای تصویر (ارتفاع تصویر به تعداد پیکسل)

در واقع، هرچه مقدار نسبت سیگنال به نویز اوج بالاتر باشد، کیفیت بازسازی بهتر و میزان نویز در تصویر کمتر است.

شاخص شباهت ساختاری

شاخص شباهت ساختاری معرفی شد و به‌عنوان جایگزینی دقیق‌تر برای نسبت سیگنال به نویز اوج مطرح گردید، زیرا به‌جای تمرکز صرف بر اختلاف پیکسل‌ها، ساختار، روشنایی و کنتراست تصویر را نیز در نظر می‌گیرد [۲۵]. شاخص شباهت ساختاری یکی از دقیق‌ترین معیارهای ارزیابی کیفیت تصویری به‌ویژه در کاربردهای پزشکی و مهندسی سنگ است.

فرمول اصلی شاخص شباهت ساختاری به‌صورت زیر تعریف می‌شود:

$$\text{SSIM}(x, y) = \frac{((2 * \mu_x * \mu_y + C1) * (2 * \sigma_{xy} + C2))}{((\mu_x^2 + \mu_y^2 + C1) * (\sigma_x^2 + \sigma_y^2 + C2))} \quad (۳)$$

که در آن:

x و y : دو تصویر مورد مقایسه (یکی تصویر بازسازی‌شده، دیگری تصویر مرجع)

μ_x, μ_y : میانگین شدت پیکسل‌های دو تصویر x و y

σ_x^2, σ_y^2 : واریانس شدت پیکسل‌های دو تصویر

σ_{xy} : کوواریانس بین دو تصویر (میزان همبستگی بین x و y)

$C1, C2$: ضرایب پایدارسازی برای جلوگیری از تقسیم بر صفر

L : بیشترین مقدار شدت پیکسل در تصویر (برای تصاویر ۸ بیتی معمولاً ۲۵۵)

مقدار شاخص شباهت ساختاری بین ۰ و ۱ قرار دارد؛

که در آن:

FN (False Negative) پیکسل‌هایی هستند که به فرض مثال مدل به اشتباه آن‌ها را به عنوان ماتریکس شناسایی کرده درحالی که در واقع شکاف بوده‌اند.

در حوزه تحلیل تصاویر سیتی اسکن سنگ‌های مخازن، مقدار بازخوانی بالا از اهمیت ویژه‌ای برخوردار است، زیرا از نادیده گرفته شدن بخش‌هایی از شبکه شکستگی جلوگیری می‌کند.

امتیاز-F1

امتیاز F1 میانگین هارمونیک دو شاخص دقت و بازخوانی است و تعادلی میان خطاهای مثبت کاذب و منفی کاذب برقرار می‌کند. این معیار در داده‌هایی با عدم تعادل بین کلاس‌ها (مانند نسبت کم شکاف‌ها نسبت به ماتریکس) اهمیت زیادی دارد، زیرا از تأثیر نامتوازن هر یک از معیارها جلوگیری می‌کند. فرمول آن به صورت زیر بیان می‌شود:

$$F1\text{-score} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall}) \quad (6)$$

مقدار بالاتر F1 نشان‌دهنده عملکرد کلی بهتر مدل در تشخیص صحیح نواحی شکستگی و جلوگیری از خطاهای طبقه‌بندی است.

شاخص جاکارد

برای ارزیابی جامع‌تر عملکرد مدل، از شاخص جاکارد استفاده شد. این شاخص میزان هم‌پوشانی بین نواحی پیش‌بینی‌شده و نواحی واقعی را اندازه‌گیری کرده و به صورت زیر تعریف می‌شود [۲۸]:

$$\text{Jaccard Score} = |A \cap B| / |A \cup B| \quad (7)$$

که در آن مجموعه A مجموعه مقادیر پیش‌بینی‌شده است و مجموعه B مجموعه مقادیر واقعی. عبارت $A \cup B$ شامل هر چیزی است که در هر یک از دو مجموعه A و B وجود دارد، و $A \cap B$ نشان‌دهنده بخش هم‌پوشان (اشتراک) بین دو کلاس است. تمام معیارها برای هر کلاس به صورت جداگانه محاسبه شده‌اند و سپس میانگین گرفته شده تا هم امتیازهای ویژه هر کلاس و هم عملکرد کلی به دست

آید. محاسبات با استفاده از کتابخانه‌های استاندارد و معتبر انجام شدند و شامل مقایسه پیکسل به پیکسل بین ماسک‌های سگمنتیشن پیش‌بینی‌شده و برچسب‌های واقعی در مجموعه داده‌ی آزمایشی بودند. شاخص جاکارد بین ۰ تا ۱ تغییر می‌کند؛ هرچه مقدار آن به ۱ نزدیک‌تر باشد، تطابق بیشتری بین تصویر بازسازی‌شده و تصویر مرجع وجود دارد. **مقایسه جامع هزینه‌های محاسباتی و نیازهای زیرساختی دو معماری بازسازی تصویر**

اگرچه معماری تبدیل‌کننده‌بینایی در اغلب معیارهای کمی و کیفی عملکرد دقیق‌تری نسبت به خودرمنگذار ارائه داد، اما بررسی جامع هزینه‌های محاسباتی نشان می‌دهد که انتخاب این معماری مستلزم برخورداری از زیرساخت‌های سخت‌افزاری قوی‌تر است. برای پردازش تصاویر 128×128 ، مدل خودرمنگذار به دلیل کانولوشن‌های محلی و تعداد پارامترهای کمتر، مصرف حافظه GPU در حدود ۱ تا ۱/۲ گیگابایت داشته و می‌تواند با بچ سایزهای بزرگ‌تری (تا ۶۴) بدون افت عملکرد اجرا شود. در مقابل، مدل تبدیل‌کننده‌بینایی به علت وجود لایه‌های توجه چندسری و تعبیه‌های با ابعاد ۵۱۲، بین ۲ تا ۲/۸ گیگابایت حافظه VRAM مصرف می‌کند. از نظر زمان آموزش، خودرمنگذار در هر اپوک بین ۱۸ تا ۲۰ ثانیه زمان نیاز دارد، درحالی که تبدیل‌کننده‌بینایی به طور متوسط ۳۲ تا ۳۸ s برای هر اپوک صرف می‌کند و برای رسیدن به همگرایی نیز به تعداد تکرارهای بیشتری نیازمند است، که مجموع زمان آموزش را ۱.۵ تا ۲ برابر افزایش می‌دهد. علاوه بر GPU، بررسی مصرف RAM نشان داد که خودرمنگذار با ۲ تا ۳ گیگابایت RAM به خوبی اجرا می‌شود، درحالی که تبدیل‌کننده‌بینایی به علت ذخیره تصویرها، تعبیه‌ها و توالی‌های توجه، نیاز به ۴ تا ۷ گیگابایت RAM دارد. همچنین تحلیل توان پردازشی نشان داد که در سراسر مدل خودرمنگذار حدود ۴۵۰ تا ۶۰۰ تصویر در ثانیه است، درحالی که در تبدیل‌کننده‌بینایی این مقدار به حدود ۱۸۰ تا

۲۳۰ تصویر در ثانیه کاهش می‌یابد. در نهایت، اگرچه تبدیل‌کننده‌بینایی در بازسازی ساختارهای پیچیده مخازن شکافدار عملکرد برتری دارد، اما هزینه محاسباتی بالاتر، سرعت پایین‌تر، نیاز به GPU با حداقل ۸ گیگابایت حافظه و وابستگی بیشتر به تنسور هسته‌ها باعث می‌شود که در پروژه‌های وسیع، تکرارشونده یا زیرساخت‌های محدود، مدل خودرمزگذار گزینه‌ای عملی‌تر و مقرون‌به‌صرفه‌تر باشد. انتخاب بین این دو معماری باید بر پایه سطح پیچیدگی داده‌ها، حجم کل داده‌ها، محدودیت GPU و الزام به دقت بازسازی انجام گیرد. در **جدول ۵** نیز اطلاعات لازمه مشخص شده است.

نتایج و بحث

در این پژوهش، دو معماری متفاوت از معماری‌های یادگیری عمیق برای بازسازی و نویززدایی تصاویر سی‌تی اسکن سنگ‌های مخازن شکافدار مورد مقایسه قرار گرفتند:

۱. معماری خودرمزگذار

۲. معماری تبدیل‌کننده بینایی


نتایج به‌دست‌آمده نشان می‌دهد که معماری تبدیل‌کننده‌بینایی در اغلب معیارها عملکرد بهتری

نسبت به معماری خودرمزگذار داشته است. به‌ویژه در شاخص نسبت سیگنال به نویز اوج با عدد بیشتر از ۴۰ (**شکل b ۱**)، معماری تبدیل‌کننده‌بینایی توانست وضوح بالاتری در بازسازی تصویر ایجاد کند که نشان‌دهنده بازتولید دقیق‌تر شدت پیکسل‌ها و جزئیات ریز شکاف‌ها نسبت به مدل خودرمزگذار (**شکل b ۲**) است. همچنین، شاخص شباهت ساختاری برای تبدیل‌کننده‌بینایی مقادیر بالاتری (نزدیک‌تر به ۱) (**شکل c ۱**) نسبت به شاخص شباهت ساختاری برای مدل خودرمزگذار (**شکل c ۲**) را ثبت کرده است، که بیانگر حفظ بهتر ساختار فضایی و همبستگی‌های موضعی در تصویر می‌باشد. شاخص جاکارد نیز نشان داده است که مدل تبدیل‌کننده توانایی بیشتری در تفکیک دقیق نواحی شکاف باز و ماتریکس سنگ داشته است (**شکل a ۱ و a ۲**). در مقابل، معماری خودرمزگذار در بازسازی بخش‌های همگن عملکرد قابل قبولی داشته اما در بازتولید تصاویر و شکاف‌ها مقداری نویز در بر گرفته است. در ادامه، برای بررسی دقیق‌تر عملکرد دو معماری در مقیاس ریز و میزان حفظ میکروشکاف‌ها، یک ارزیابی دستی مبتنی بر مقیاس وکسل انجام شد که مبنای آن در ادامه بیان می‌شود.

جدول ۵ اطلاعات لازمه محاسباتی هر دو مدل بازسازی تصویر


Table 5 Computational Requirements of the Two Image Reconstruction Models

Criterion	Autoencoder	Vision Transformer
GPU Model	RTX 3050	RTX 3050
Minimum Required GPU Memory	GB is sufficient 4	At least 8 GB for stable execution
System RAM Usage	GB 3-2	GB 7-4
Processing Speed	images/s 600-450	images/s 230-180
Time per Epoch	s 20-18	s 38-32
Number of Epochs to Convergence	30-25	50-40
Sensitivity to Increased Batch Size	Excellent scalability	Severe out-of-memory limitations
Training Stability	Moderate	Very high
Ability to Learn Non-Local Features	Limited	Very strong
Suitability for Large-Scale Datasets	Moderate	Excellent, but computationally expensive
Recommended Application	Resource-limited projects and rapid training	High-accuracy projects involving complex fracture structures
Overall Computational and Time Cost	Low	High, approximately 1.5-2 times that of the autoencoder



شکل ۱ شاخص‌های (A) جاکارد نزدیک به ۸۷۵/۰ که میانگین هر سه بخش می‌باشد، (B) نسبت سیگنال به نویز بالاتر از ۴۰ با یک عملکرد عالی، (C) شاخص شباهت ساختاری نزدیک به ۱ و نشان‌دهنده عملکرد عالی و (D) تابع هزینه روی داده‌های آزمایش مدل تبدیل‌کننده مرتبط با بازسازی تصویر

Fig. 1 The metrics include: (a) a Jaccard index close to 0.875, representing the average of all three classes; (b) a peak signal-to-noise ratio above 40, indicating excellent performance; (c) a structural similarity index close to 1, demonstrating excellent performance; and (d) the loss function on the test data of the transformer-based image reconstruction model




شکل ۲ شاخص‌های (A) جاکارد نزدیک به ۸۰ که میانگین هر سه بخش می‌باشد، (B) نسبت سیگنال به نویز نزدیک به ۴۰ و نشان‌دهنده عملکرد خوب مدل، (C) شاخص شباهت ساختاری نزدیک به ۱ ولی مقداری کمتر از این شاخص در مدل تبدیل‌کننده بینایی و (D) تابع هزینه روی داده‌های آزمایش شبکه خودرمزگذار مرتبط با بازسازی تصویر


Fig. 2 The metrics include: (a) a Jaccard index close to 0.80, representing the average of all three classes; (b) a peak signal-to-noise ratio close to 40, indicating the good performance of the model; (c) a structural similarity index close to 1, but slightly lower than that obtained by the Vision Transformer model; and (d) the loss function on the test data of the autoencoder network used for image reconstruction

با توجه به ماهیت داده‌های استفاده شده، تصاویر روی یک شبکه گسسته از وکسل‌ها نمونه‌برداری می‌شوند؛ بنابراین کوچک‌ترین واحد مکانی قابل تفکیک در تصویر برابر با اندازه یک وکسل است. علاوه بر این، اثرات ذاتی تصویربرداری نظیر پخش‌شدگی نقطه‌ای، نویز و پدیده حجم جزئی باعث می‌شود تعیین دقیق موقعیت مرز شکستگی‌ها در تصویر مرجع با عدم قطعیتی در حدود ± 1 وکسل همراه باشد. از این رو، حفظ عرض شکستگی در بازسازی در محدوده خطای یک وکسل به عنوان معیار عملی و فیزیکی ارزیابی حفظ میکروشکاف‌ها در نظر گرفته شد. در معماری خودرم‌گذار پیچشی، به دلیل ماهیت محلی کانولوشن‌ها و میدان دید موضعی فیلترها، ویژگی‌های ریزمقیاس نظیر لبه‌های شکستگی و بافت‌های نزدیک به مرز ماتریکس-شکاف به صورت مستقیم مدل‌سازی می‌شوند. ارزیابی دستی عرض میکروشکاف‌ها در نمونه‌های منتخب از طریق اندازه‌گیری پیکسل‌به‌پیکسل و تبدیل آن به مقیاس واقعی براساس اندازه وکسل دیتاست نشان داد که در بسیاری از موارد اختلاف عرض شکستگی بین تصویر مرجع و تصویر بازسازی شده خودرم‌گذار در محدوده خطای یک وکسل باقی می‌ماند. در مقابل، معماری تبدیل‌کننده بینایی به واسطه‌ی سازوکار خودتوجه قادر است وابستگی‌های دوربرد بین تصاویر تصویر را بدون محدودیت میدان دید موضعی مدل کند؛ بنابراین پیوستگی طولی شکستگی‌ها، جهت‌گیری و اتصال ساختارهای چندمقیاسی را دقیق‌تر بازسازی می‌نماید. ارزیابی دستی عرض و پیوستگی میکروشکاف‌ها در نمونه‌های منتخب (با همان رویکرد پیکسل‌به‌پیکسل و تبدیل به مقیاس واقعی بر مبنای وکسل دیتاست) نشان داد که تبدیل‌کننده بینایی در اغلب موارد اختلاف عرض شکستگی را در حد خطای یک وکسل حفظ کرده و هم‌زمان با کاهش گسست‌های مصنوعی، مسیرهای شکستگی را پیوسته‌تر و طبیعی‌تر بازسازی می‌کند.


شکل‌های مقایسه‌ای بین تصاویر واقعی و بازسازی شده برای هر دو مدل نیز مؤید همین نتایج بازسازی تصاویر هستند. در این تصاویر مشاهده می‌شود که معماری تبدیل‌کننده بینایی جزئیات ظریف‌تر شکستگی‌ها و اتصالات بین شکاف‌ها را با دقت بالاتری بازسازی کرده (شکل ۳ و نویز تصویری کمتری تولید نموده است. در حالی که مدل خودرم‌گذار در تصاویر بازسازی شده نسبت به تصاویر اصلی، نواحی خاکستری دارای بافتی دانه‌دانه‌تر و نویز بیشتری هستند (شکل ۴). علاوه بر ارزیابی دیداری، ماتریس‌های سردرگمی برای سه کلاس تعریف شده (ماتریکس، شکاف باز و شکاف پر شده) نیز محاسبه شد. در مقایسه دو معماری خودرم‌گذار و تبدیل‌کننده بینایی، هر دو در تشخیص سه دسته «ماتریکس»، «شکاف پر شده» و «شکاف باز» عملکرد بسیار خوبی دارند، اما تفاوت‌های ظریفی میان آن‌ها دیده می‌شود. معماری تبدیل‌کننده بینایی دقت کلی بالاتری دارد و در تشخیص نواحی مربوط به ماتریکس بسیار دقیق‌تر عمل کرده است (حدود ۹۹٪ در برابر ۹۷٪ در معماری خودرم‌گذار). در مقابل، معماری خودرم‌گذار در شناسایی شکستگی‌های باز کمی بهتر بوده است (۹۳/۴٪ در برابر ۹۲٪). در مجموع، تبدیل‌کننده بینایی در جدا کردن بخش‌های ماتریکس از نواحی شکستگی‌ها عملکرد برتری دارد، اما خودرم‌گذار در حفظ توازن بین همه‌ی دسته‌ها و در تفکیک نوع شکستگی‌ها (پر شده و باز) اندکی دقیق‌تر و پایدارتر عمل کرده است. در نتیجه، به طور کلی معماری تبدیل‌کننده بینایی نتیجه‌ی بهتری را نشان داده است (شکل ۵ و ۶). در مقایسه دو معماری خودرم‌گذار و تبدیل‌کننده بینایی، هر دو در تشخیص سه دسته‌ی «ماتریکس»، «شکستگی پر شده» و «شکستگی باز» عملکرد بسیار خوبی دارند، اما تفاوت‌های ظریفی میان آن‌ها دیده می‌شود.




شکل ۳ تصاویر واقعی و بازتولید شده توسط مدل تبدیل‌کننده روی داده‌های اعتبارسنجی
Fig. 3 Original and Reconstructed Images Generated by the Transformer Model on the Validation Dataset



شکل ۴ تصاویر واقعی و بازتولید شده توسط شبکه خودرمزگذار روی داده‌های اعتبارسنجی
Fig. 4 Original and Reconstructed Images Generated by the Autoencoder Network on the Validation Dataset



شکل ۵ ماتریس‌های سردرگمی روی داده‌های آزمایش شبکه خودرمزنگار مرتبط با بخش‌بندی تصویر
Fig. 5 Confusion Matrices on the Test Dataset for the Autoencoder-Based Image Segmentation Model



شکل ۶ ماتریس‌های سردرگمی روی داده‌های آزمایش شبکه تبدیل‌کننده بینایی مرتبط با بخش‌بندی تصویر
Fig. 6 Confusion matrices on the test dataset for the vision transformer-based image segmentation model

امتیاز-F1 برابر با ۰/۹۶۳ نسبت به خودرمزگذار با مقدار ۰/۹۶۱، عملکردی اندکی بهتر نشان داده است. درحالی‌که در طبقه «شکستگی باز» تفاوت میان دو مدل کمتر است و مقادیر امتیاز-F1 به ترتیب ۰/۹۲۱ برای تبدیل‌کننده بینایی و ۰/۹۳۷ برای خودرمزگذار به دست آمده است (جدول ۷).

معماری تبدیل‌کننده بینایی در شاخص‌های دقت، یادآوری و امتیاز-F1 به‌ویژه در طبقه «ماتریکس»، عملکرد بهتری داشته است (به ترتیب ۰/۹۸۹، ۰/۹۹۰ و ۰/۹۸۹ در برابر ۰/۹۸۰، ۰/۹۶۹ و ۰/۹۷۴ در معماری خودرمزگذار) (جدول ۶). در طبقه «شکستگی پرشده» نیز تبدیل‌کننده بینایی با

جدول ۶ معیارهای گزارش طبقه‌بندی روی داده‌های آزمایش معماری تبدیل‌کننده‌بینایی مرتبط با بخش‌بندی تصویر

Table 6 Classification Report Metrics on the Test Dataset for the Vision Transformer-Based Image Segmentation Model

Jaccard Index	F1-Score	Recall	Precision	Class Label
0.92	0.989	0.990	0.989	Matrix (0)
0.90	0.963	0.953	0.974	Filled Fracture (1)
0.85	0.921	0.920	0.923	Open Fracture (2)

جدول ۷ معیارهای گزارش طبقه‌بندی روی داده‌های آزمایش برای مدل بخش‌بندی تصویر مبتنی بر خودرمزگذار

Table 7 Classification Report Metrics on the Test Dataset for the Autoencoder-Based Image Segmentation Model


Jaccard Index	F1-Score	Recall	Precision	Class Label
0.83	0.974	0.969	0.980	Matrix (0)
0.81	0.961	0.962	0.960	Filled Fracture (1)
0.80	0.937	0.934	0.940	Open Fracture (2)

بازسازی در نواحی شکستگی را نشان می‌دهد. بزرگ‌نمایی‌های ارائه‌شده بیانگر آن است که مدل تبدیل‌کننده‌بینایی جزئیات شکستگی‌ها را با دقت بیشتری بازتولید می‌کند، در حالی که خودرمزگذار نیز در بازسازی الگوهای کلی ساختاری عملکردی پایدار و قابل قبول دارد. این مقایسه نشان می‌دهد هر دو مدل بسته به نوع ساختار سنگ، رفتار متفاوتی داشته و ویژگی‌های خاص خود را در فرآیند بازسازی ارائه می‌کنند. همان‌گونه که در **شکل ۸** مشاهده می‌شود، نواحی بزرگ‌نمایی‌شده نمونه‌هایی از بخش‌هایی هستند که بازسازی آن‌ها برای مدل‌ها چالش‌برانگیز بوده است. در تصویر a، بخش مشخص‌شده در ناحیه ماتریکس همچنان مقداری نویز باقی‌مانده را نشان می‌دهد و مدل تبدیل‌کننده‌بینایی نتوانسته است این قسمت را به‌طور کامل صاف‌سازی و بازسازی کند. تصویر b نشان می‌دهد که مدل خودرمزگذار در ناحیه حاوی شکاف پرشده، بخشی از ساختار را به‌صورت محو بازسازی کرده و مرز شکستگی به‌طور کامل حفظ نشده است. همچنین در تصویر c، خروجی مدل خودرمزگذار نویز بیشتری را نشان می‌دهد و بخش علامت‌گذاری‌شده از شکاف خالی به‌طور دقیق بازتولید نشده است و مقداری نویز بیشتر در تصویر بازسازی شده به کمک خودرمزگذار وجود دارد.

به‌طور کلی، معماری تبدیل‌کننده‌بینایی به‌دلیل دقت و یادآوری بالاتر در تشخیص نواحی «ماتریکس» و «شکستگی پرشده»، عملکرد کلی بهتری از خودرمزگذار دارد، هرچند خودرمزگذار در تفکیک دقیق‌تر نواحی «شکستگی باز» اندکی موفق‌تر بوده است. از نظر تابع هزینه، منحنی‌های آموزش نشان دادند که معماری تبدیل‌کننده‌بینایی به پایداری همگرایی بیشتری رسیده و مقدار هزینه نهایی پایین‌تری نسبت به خودرمزگذار داشته است، که این امر نشانگر توانایی بالاتر در یادگیری روابط پیچیده بین تصاویر تصویر است. در افق آینده، به‌کارگیری چنین مدل‌هایی می‌تواند علاوه‌بر افزایش دقت بازسازی تصاویر، منجر به استخراج دقیق‌تر ویژگی‌های پتروفیزیکی همچون تخلخل دوگانه، نفوذپذیری مؤثر، جهت‌گیری شکستگی‌ها و پیوستگی شبکه‌ی شکاف‌ها شود [۲۹]. در نتیجه، این رویکرد می‌تواند جایگزین روش‌های مخرب سنتی گردد، هزینه و زمان تحلیل را کاهش دهد و در نهایت بهره‌وری مدیریت مخازن پیچیده را بهبود بخشد. این پژوهش نشان می‌دهد که تلفیق یادگیری عمیق با داده‌های سی‌تی‌اسکن می‌تواند مسیر تحول در مدل‌سازی دیجیتال سنگ و درک رفتار دینامیکی مخازن شکاف‌دار را هموار کند.


نقاط قوت و محدودیت‌های مدل‌های بازسازی

تصاویر **شکل ۷** نمونه‌هایی از عملکرد دو مدل



شکل ۷ شکل A و B نشان‌دهنده نقاطی از تصویر که مدل تبدیل‌کننده بینایی توانسته به‌خوبی بازسازی انجام دهد و همچنین شکل C برای مدل خودرمزگذار که در بخش مورد نظر در این تصویر توانسته مانند مدل تبدیل‌کننده بینایی خوب عمل کند

Fig. 7 Successful image reconstruction by the Vision Transformer model in (a) and (b), and comparable reconstruction performance of the autoencoder model in the specified region in (c).



شکل ۸ محدودیت‌های بازسازی تصویر در مدل‌های تبدیل‌کننده بینایی و خودرمزگذار: (a) نویز باقی‌مانده در ناحیه ماتریس؛ (b) بازسازی ناقص ناحیه مشخص‌شده؛ (c) ایجاد نویز و کاهش دقت بازسازی در مدل خودرمزگذار

Fig. 8 Image reconstruction limitations of the Vision Transformer and autoencoder models: (a) residual noise in the matrix region; (b) incomplete reconstruction of the specified region; and (c) noise generation and reduced reconstruction accuracy in the autoencoder model.

بر کاربردپذیری نتایج در تحلیل‌های عملی مخزن متمرکز شود. نخست، استفاده از تصاویر بازسازی‌شده برای ساخت مدل‌های دیجیتال سه‌بعدی دقیق‌تر شبکه شکستگی‌ها می‌تواند دقت شبیه‌سازی‌هایی مانند نفوذپذیری مؤثر، تخلخل دوگانه و جریان سیال را افزایش دهد. توسعه یک مسیر خودکار شامل بازسازی، بخش‌بندی و استخراج ویژگی نیز امکان استفاده صنعتی از این روش را فراهم می‌کند. علاوه‌براین، به‌کارگیری مدل‌های آموزش‌دیده در وظایفی مانند تشخیص شکستگی، ارزیابی آسیب مخزن و تحلیل عملیات‌هایی نظیر شکست هیدرولیکی از دیگر زمینه‌های توسعه است. ترکیب تصاویر با داده‌های مکمل نظیر برش نازک، NMR و FMI نیز می‌تواند به ایجاد یک مدل چندمنبعی دقیق‌تر برای توصیف مخزن منجر شود. در نهایت، تعمیم مدل به لیتولوژی‌ها، رزولوشن‌ها و شرایط نویزی مختلف و همچنین توسعه نسخه‌های سبک‌تر برای استفاده در محیط‌های عملیاتی، از مهم‌ترین مسیرهای تحقیقاتی آینده به‌شمار می‌روند.

نتیجه‌گیری

در این پژوهش، با بهره‌گیری از دو معماری پیشرفته یادگیری عمیق شامل خودرمزگذار پیچشی و تبدیل‌کننده بینایی، فرآیند بازسازی و نویززدایی تصاویر سیتی‌اسکن سنگ‌های مخازن شکافدار طبیعی مورد بررسی قرار گرفت. هدف اصلی، بازتولید دقیق ساختارهای درونی شامل ماتریکس سنگ، شکاف‌های باز و شکاف‌های پرشده با مواد معدنی بود. نتایج اولیه نشان داد که هر دو مدل توانایی بازسازی ساختارهای شکافدار را با دقت قابل‌قبولی دارند، با این حال تبدیل‌کننده بینایی در حفظ جزئیات ریز، مرزهای ساختاری و کاهش نویز، برتری محسوسی نسبت به خودرمزگذار داشت.

- از نظر کمی، تبدیل‌کننده بینایی در بازسازی تصاویر عملکرد برتری نسبت به خودرمزگذار

این موارد بیانگر آن است که هر دو معماری، با وجود عملکرد کلی مناسب، در نواحی با هندسه پیچیده یا نسبت سیگنال به نویز پایین، با محدودیت‌هایی در بازسازی کامل ساختار مواجه هستند.

نقاط قوت و محدودیت‌ها

یکی از محدودیت‌های مهم این پژوهش به قابلیت تعمیم‌پذیری مدل‌ها مربوط می‌شود. داده‌های به‌کاررفته عمدتاً شامل تصاویر سیتی‌اسکن از نمونه‌های زغال‌سنگی شکافدار در مقیاس ریز بوده‌اند؛ بنابراین تعمیم مستقیم نتایج به لیتولوژی‌های متفاوت نظیر سنگ‌های کربناته، ماسه‌سنگی یا شیل و نیز به داده‌هایی با اندازه و کسل، شدت تابش، اندازه متفاوت تصاویر یا شرایط تصویربرداری متفاوت، بدون ارزیابی مجدد قابل تضمین نیست. از آنجاکه ویژگی‌های بافتی، تخلخل، هندسه شکستگی‌ها و الگوی نویز در هر نوع سنگ و هر مقیاس تصویربرداری می‌تواند به‌طور معناداری تغییر کند، در مواجهه با داده‌های جدید پدیده‌ی ناهمخوانی دامنه و مقیاس محتمل بوده و ممکن است عملکرد مدل را تحت تأثیر قرار دهد. با این حال، چون هر دو معماری خودرمزگذار و تبدیل‌کننده بینایی ذاتاً قابلیت یادگیری مقیاس‌ناوابسته دارند، در صورت فراهم بودن داده‌های هدف، می‌توان مدل‌های آموزش‌دیده را روی آن داده‌ها با تنظیم مجدد ابرپارامترها^۱ سازگار کرد. بر این اساس، ارزیابی تجربی روی مجموعه داده‌های متنوع‌تر، لیتولوژی‌های مختلف و مقیاس‌های تصویری بزرگ‌تر (از جمله داده‌های رخنمونی) به‌عنوان یک مسیر ضروری برای تثبیت پایداری و تعمیم‌پذیری روش در مطالعات آینده پیشنهاد می‌شود.

کارهای آینده

با توجه به عملکرد مطلوب مدل‌ها در بازسازی تصاویر مخازن شکافدار، مسیرهای آینده می‌تواند

تبدیل‌کننده‌بینایی دارای وضوح بیشتر، نویز کمتر و بازسازی دقیق‌تر شکستگی‌ها و اتصالات بودند. در مقابل، مدل خودرمزگذار خروجی‌هایی با بافت دانه‌دانه، خطوط محو و نویز بالاتر تولید کرد. تبدیل‌کننده توانست ساختارهای ظریف و شکستگی‌های ناپیوسته را با پیوستگی بهتری بازسازی کند که برای تحلیل دقیق شبکه شکاف‌ها بسیار مهم است.

• بررسی منحنی‌های یادگیری دو مدل نشان داد که تبدیل‌کننده‌بینایی در طول فرآیند آموزش از همگرایی پایدارتر و نرخ کاهش تابع هزینه سریع‌تری برخوردار است. این ویژگی بیانگر قابلیت بالای آن در یادگیری روابط پیچیده و وابستگی‌های بلندبرد بین تصاویر تصویر است، درحالی‌که خودرمزگذار در تکرارهای اولیه آموزش نوسانات بیشتری نشان داد و به حداقل محلی تابع هزینه نزدیک‌تر شد.

• نتایج نشان دادند که علاوه بر نوع معماری، روش‌های پیش‌پردازش مانند آستانه‌گذاری چندسطحی اتسو و تقویت داده‌ها تأثیر زیادی در بهبود کیفیت بازسازی دارند. همچنین استفاده از ابرپارامترهای بهینه و آموزش روی GPU باعث افزایش دقت و سرعت همگرایی مدل‌ها شد، که برای پردازش داده‌های حجیم سی‌تی اسکن در تحلیل‌های پتروفیزیکی مانند تخلخل و نفوذپذیری اهمیت بالایی دارد.

پیچشی داشت. این مدل به نسبت سیگنال به نویز اوج ۴۵ و شاخص شباهت ساختاری ۰/۹۸ دست یافت، درحالی‌که خودرمزگذار به ترتیب مقادیر ۳۹ و ۰/۹۳ را ثبت کرد. بررسی شاخص جاکارد نیز نشان داد که تبدیل‌کننده در تفکیک دقیق‌تر نواحی تصویر به‌ویژه مرزبندی ماتریکس و شکاف‌های پرشده موفق‌تر بوده و توانسته است ارتباط‌های فضایی و ساختاری تصویر را بهتر حفظ کند، درحالی‌که مدل پیچشی در نواحی با جزئیات ریز دچار افت وضوح و از دست‌رفتن ساختار شده است.

• در تحلیل شاخص‌های بخش‌بندی سه‌کلاسه، تبدیل‌کننده‌بینایی برای کلاس ماتریکس مقادیر دقت، بازخوانی و امتیاز F1 را به ترتیب ۰/۹۸۹، ۰/۹۹۰ و ۰/۹۸۹ به‌دست آورد. برای شکاف‌های پرشده، این مقادیر برابر با ۰/۹۷۴، ۰/۹۵۳ و ۰/۹۶۳۰ و برای شکاف‌های باز ۰/۹۲۳، ۰/۹۲۰ و ۰/۹۲۱ بود. در مقابل، خودرمزگذار پیچشی برای همین سه کلاس به ترتیب نتایج ۰/۹۸۰، ۰/۹۶۹ و ۰/۹۷۴، ۰/۹۶۰، ۰/۹۶۲ و ۰/۹۶۱ و ۰/۹۴۰، ۰/۹۳۴ و ۰/۹۳۷ را ارائه داد. این مقایسه نشان می‌دهد که تبدیل‌کننده‌بینایی در شاخص‌های دقت و یادآوری به‌ویژه در طبقه ماتریکس و شکاف‌های پرشده عملکرد برتری دارد، هرچند خودرمزگذار در تشخیص برخی شکاف‌های باز باریک عملکرد نزدیک‌تری ارائه کرده است.

• از نظر کیفی، تصاویر بازسازی‌شده با

مراجع

- [1]. Nguyen, K. L., Jumah, M., Verma, N., & Quttainah, R. (2023). Identifying Fracture Sweet Spots Using Artificial Neural Network Approach: A Case Study in Najmah/Sargelu Reservoir, Kra Al-Marū Field, West Kuwait. Middle East Oil, Gas and Geosciences Show, doi.org/10.2118/213770-MS
- [2]. Wilson, T. H., Smith, V., & Brown, A. (2015). Developing a model discrete fracture network, drilling, and enhanced oil recovery strategy in an unconventional naturally fractured reservoir using integrated field, image log, and three-dimensional seismic data. AAPG Bulletin, 99(4), 783–808. doi.org/10.1306/10031414015
- [3]. Sun, S., & Pollitt, D. A. (2021). Optimising development and production of naturally fractured reservoirs using a large empirical dataset. Petroleum Geoscience, 27(3), petgeo2020-079. doi.org/10.1144/petgeo2020-079
- [4]. Lyu, W., Zeng, L., Zhou, S., Du, X., Xia, D., Liu, G., Li, J., & Weng, J. (2019). Natural fractures in tight-oil sandstones: A case study of the Upper Triassic Yanchang Formation in the southwestern Ordos Basin, China. AAPG Bulletin, 103(1), 135–154. https://doi.org/10.1306/0130191608617115
- [5]. Hashemi, R., Saberi, F., Asoude, P., & Soleimani, B. (2024). Enhancing Reservoir Zonation through Triple Porosity System: A Case Study. SPE Journal, 29(06), 3043–3062. doi.org/10.2118/219491-pa.

- [6]. Al-Rbeawi, S. (2020). The performance of complex-structure fractured reservoirs considering natural and induced matrix block size, shape, and distribution. *Journal of Natural Gas Science and Engineering*, 81, 103400. doi.org/10.1016/j.jngse.2020.103400.
- [7]. Zhu, Y., Hou, D., Lan, M., Sun, X., & Ma, X. (2019). A comparison of ultra-high-resolution CT target scan versus conventional CT target reconstruction in the evaluation of ground-glass-nodule-like lung adenocarcinoma. *Quantitative Imaging in Medicine and Surgery*, 9(6), 1087–1094. doi.org/10.21037/qims.2019.06.09.
- [8]. Faisal, R. S., Salih, N. M., Kamal, I., & Pr  at, A. (2023). X-ray computed tomography (CT) to scan the structure and characterize the mud cake incorporated with various magnetic NPs concentration: An application to evaluate the wellbore stability and formation damage. *Nanomaterials*, 13(12), 1843. doi.org/10.3390/nano13121843.
- [9]. Cappuccio, F., Toy, V. G., Mills, S., & Adam, L. (2020). Three-dimensional separation and characterization of fractures in X-ray computed tomographic images of rocks. *Frontiers in Earth Science*, 8, 529263. doi.org/10.3389/feart.2020.529263.
- [10]. Soltanmohammadi, R., & Faroughi, S. A. (2023). A comparative analysis of super-resolution techniques for enhancing micro-CT images of carbonate rocks. *Applied Computing and Geosciences*, 20, 100143. doi.org/10.1016/j.acags.2023.100143.
- [11]. Bizhani, M., Haeri Ardakani, O., & Little, E. (2022). Reconstructing high fidelity digital rock images using deep convolutional neural networks. *Scientific Reports*, 12, Article 4264. doi.org/10.1038/s41598-022-08170-8.
- [12]. Shahmoradi, M., Rekabdar, G., & Adibi, S. (2016). A comparative study of new and current methods for dental micro-CT image denoising. *Dentomaxillofacial Radiology*, 45(3), 20150302. doi.org/10.1259/dmfr.20150302.
- [13]. Feng, X., Zhang, W., Su, X., & Xu, Z. (2021). Optical Remote Sensing Image Denoising and Super-Resolution Reconstructing Using Optimized Generative Network in Wavelet Transform Domain. *Remote. Sens.*, 13, 1858. doi.org/10.3390/rs13091858.
- [14]. Sahu, P., Kumar, A., & Rout, S. (2022). Wavelet guided 3D deep model to improve dental microfracture detection. In *Applied Medical Artificial Intelligence* (pp. 1–12). Springer. doi.org/10.1007/978-3-031-17721-7_16.
- [15]. Mathew, E. S., Singh, K., & Arbogast, B. (2025). Deep learning assisted denoising of fast polychromatic X-ray micro-CT imaging of multiphase flow in porous media. *Computers & Geosciences*, 204, 105990. doi.org/10.1016/j.cageo.2025.105990.
- [16]. Koetzier, L. R., Mastrodicasa, D., Szczykutowicz, T. P., van der Werf, N. R., Wang, A. S., Sandfort, V., van der Molen, A. J., Fleischmann, D., & Willeminck, M. J. (2023). Deep Learning Image Reconstruction for CT: Technical Principles and Clinical Prospects. *Radiology*, 306(3), e221257. doi.org/10.1148/radiol.221257.
- [17]. Janssens, N., Huysmans, M., & Swennen, R. (2020). Computed Tomography 3D Super-Resolution with Generative Adversarial Neural Networks: Implications on Unsaturated and Two-Phase Fluid Flow. *Materials* (Basel, Switzerland), 13(6), 1397. doi.org/10.3390/ma13061397.
- [18]. Shirmard, H., Farahbakhsh, E., Heidari, E., Beiranvand Pour, A., Pradhan, B., M  ller, D., & Chandra, R. (2022). A comparative study of convolutional neural networks and conventional machine learning models for lithological mapping using remote sensing data. *Remote Sensing*, doi.org/10.3390/rs14040819.
- [19]. Liu, L., Chang, B., Prodanovi  , M., & Pyrcz, M. J. (2025). AI-based digital rocks augmentation and assessment metrics. *Water Resources Research*, 61, e2024WR037939. doi.org/10.1029/2024WR037939.
- [20]. Espinoza, D. N., Shovkun, I., Makni, O., & Lenoir, N. (2016). Natural and induced fractures in coal cores imaged through X-ray computed microtomography: Impact on desorption time. *International Journal of Coal Geology*, 154–155, 165–175. doi.org/10.1016/j.coal.2015.12.012.
- [21]. Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507. doi.org/10.1126/science.1127647.
- [22]. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. doi.org/10.1038/323533a0.
- [23]. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). An image is worth 16×16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*. arxiv.org/abs/2010.11929.
- [24]. Huynh-Thu, Q., & Ghanbari, M. (2008). Scope of validity of PSNR in image/video quality assessment. *Electronics Letters*, 44(13), 800–801. doi.org/10.1049/el:20080522.

- [25]. Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. doi.org/10.1109/TIP.2003.819861.
- [26]. Tatbul, N., Lee, T. J., Zdonik, S., Alam, M., & Gottschlich, J. (2018). Precision and recall for time series. In *Proceedings of the 32nd Conference on Neural Information Processing Systems (NeurIPS 2018)*, Montréal, Canada. doi.org/10.48550/arXiv.1803.03639.
- [27]. Foody, G. M. (2023). Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient. *PLOS ONE*, 18(10), e0291908. doi.org/10.1371/journal.pone.0291908.
- [28]. Wang, Z., Ning, X., & Blaschko, M. B. (2023). Jaccard metric losses: Optimizing the Jaccard index with soft labels. *Proceedings of the 37th Conference on Neural Information Processing Systems (NeurIPS 2023)*. doi.org/10.48550/arXiv.2302.05666.
- [29]. Sobhani Oghaz, A., & Emami Niri, M. (2022). Effect of fracture geometrical properties on flow behavior and dynamic sensitivity analysis of fracture parameters in fractured reservoirs. *Petroleum Research*, 127, 49–64. doi.org/10.22078/PR.2022.4893.3188.