

# بازسازی تصویر سنگ مخزن متراکم با شبکه عصبی مولد رقابتی

علی کریمی و سعید صادق‌نژاد\*

گروه مهندسی نفت، دانشکده مهندسی شیمی، دانشگاه تربیت مدرس، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۰۴/۰۶ تاریخ پذیرش: ۱۴۰۱/۰۷/۰۴

## چکیده

بخش قابل توجهی از منابع هیدروکربنی ایران از مخازن شکافدار با ماتریس سنگ متراکم تولید می‌شود. ساختار حفرات این مخازن، پیچیدگی‌های زیادی دارد و حفرات و گلوگاه‌های ریز در ابعاد نانومتری ذخیره هیدروکربن را به‌عهده دارند. با درک ساختار فضای متخلخل و بررسی جریان سیال درون حفرات ریز می‌توان دید بهتری از رفتار فضای متخلخل در مقیاس بزرگ به‌دست آورد. بررسی جریان سیال در سنگ مخزن نیازمند ساختارهای سه‌بعدی با دقت مناسب است. با این وجود استفاده از روش‌های مرسوم برای بازسازی شبکه حفرات پرهزینه است و از طرفی با پیچیده‌تر شدن این ساختارها توانایی این روش‌ها در بازسازی شبکه حفرات به‌طور چشم‌گیری کاهش می‌یابد. در سال‌های اخیر با پیشرفت در علوم کامپیوتر به ویژه هوش مصنوعی دروازه جدیدی به‌منظور بازسازی ساختارهای پیچیده به مانند سنگ مخزن گشوده شده است. با استفاده از روش‌های یادگیری ماشین می‌توان مدل‌های سه‌بعدی با دقت بسیار بالا ایجاد و خواص پتروفیزیکی سنگ را از آن‌ها محاسبه کرد. یکی از این روش‌ها شبکه عصبی مولد رقابتی می‌باشد که توانایی خود در بازسازی شبکه حفرات را ثابت کرده است. در این پژوهش، از یک شبکه عصبی مولد رقابتی با لایه‌های همگشتی به‌منظور بازسازی تصاویر FIB-SEM یک سنگ مخزن متراکم در مقیاس حفره استفاده شده است. با استفاده از شبکه عصبی آموزش داده شده، تحقق‌های مختلفی از شبکه حفرات ساخته می‌شود. تخلخل و تراوایی تصاویر باز ساخته شده بسیار نزدیک به این خواص در نمونه تصویر واقعی بوده و دارای انحراف به‌ترتیب ۱/۰۷٪ و ۵/۲۴٪ برای تخلخل و تراوایی است. مشاهده می‌شود که شبکه عصبی مولد رقابتی توانایی بالایی در بازسازی شبکه حفرات دارد و می‌توان با کمک آن به بررسی شرایط سنگ مخزن در مقیاس حفره پرداخت.

**کلمات کلیدی:** بازسازی تصویر، مدل‌سازی شبکه حفرات، شبکه عصبی مولد رقابتی، سنگ مخزن

متراکم، میکروسکوپ الکترونی باریکه یونی متمرکز

## مقدمه

بنگستانی در جنوب غرب ایران تولید می‌شود. از طرفی، ساختار شبکه حفرات ماتریس این مخازن پیچیدگی‌های زیادی دارد و معمولاً در مقیاس‌های مختلف ظاهر می‌شود.

بخش قابل توجهی از منابع هیدروکربنی ایران از مخازن شکافدار با سنگ ماتریس متراکم<sup>۱</sup> (مخازن

\*مسئول مکاتبات  
آدرس الکترونیکی  
شناسه دیجیتال: (DOI:10.22078/PR.2022.4843.3165) sadeghnejad@modares.ac.ir

مهندسی مخزن [۴-۶] و بهره‌برداری [۷] استفاده شده است. در مقیاس حفره، فنگ و همکاران برای فائق آمدن به کمبود داده‌های تصویری روشی بر مبنای شبکه عصبی cGAN ارائه کردند. در این روش برای به‌دست آوردن الگوی تصاویر ورودی و خروجی به‌جای استفاده از نوفه یا نویز در تولید کننده از قسمتی از تصویر واقعی به‌همراه یک نوفه اضافی- به‌منظور افزایش تنوع- استفاده شده است [۸]. فنگ و همکارانش بعدها روش خود در ساخت شبکه سه‌بعدی از تصاویر دو بعدی را با استفاده از شبکه عصبی BicycleGAN توسعه دادند [۹]. ولخونسکی و همکارانش با استفاده از شبکه عصبی GAN اقدام به بازیابی شبکه سه‌بعدی حفرات در اطراف قسمت مرکزی برش‌های دو بعدی سنگ متخلخل نمودند [۱۰]. ژاو و همکارانش برای ساخت مدل سه‌بعدی شبکه عصبی WGAN را گسترش دادند تا ابتدا توزیع داده‌های حاصل از تصاویر واقعی را بیاموزند. سپس با استفاده از تابع توزیع احتمال و تابع فاصله آغازین<sup>۲</sup> به اصلاح تصاویر ساخته شده پرداختند [۱۱]. والسکی و همکاران یک شبکه عصبی DCGAN توسعه دادند که مستقیم با استفاده از تصاویر دو بعدی به ایجاد تصاویر سه‌بعدی می‌پردازد. اساس کار این شبکه آموزش شبکه تمیزدهنده بر مبنای تصاویر دو بعدی و آموزش شبکه مولد برای ساخت تصاویر سه‌بعدی است. آن‌ها برای اطمینان از نتیجه صحیح فرض کردند که اگر تصویری سه‌بعدی ایجاد شده خلاف واقع باشد به‌علت وجود حداقل یک تصویر دو بعدی غیرواقعی ایجاد شده است [۱۲].

موزر و همکاران استفاده از شبکه عصبی مولد رقابتی با داده‌های سه‌بعدی را به‌عنوان جایگزینی برای روش‌های تصادفی مرسوم در بازسازی شبکه منافذ پیشنهاد کردند [۱۳].

حفرات از ابعاد نانومتری در سنگ‌های متراکم تا میلی‌متر در سنگ‌های دارای تخلخل انحلالی (واگ) گسترده می‌شوند. مخازن متراکم نفتی معمولاً دارای تخلخل کمتر از ۱۰٪ و نفوذپذیری کمتر از ۰/۱ mD هستند. درک فضای متخلخل و پیش‌بینی خواص سنگ‌های متراکم یکی از چالش‌های مهم صنعت نفت است که با فهم صحیح خواص پتروفیزیکی در مقیاس ریز می‌توان دید بهتری از رفتار فضای متخلخل در مقیاس بزرگ به‌دست آورد. در سال‌های اخیر پیشرفت شگرف تجهیزات رایانه‌ای و تصویربرداری باعث گسترش هر چه بیشتر مدل‌سازی فضای متخلخل یا آنالیز مغزه دیجیتال<sup>۱</sup> شده است. با کمک این تکنولوژی می‌توان بدون تولید از مخازن به بررسی فرآیندهای جابه‌جایی در مخزن در مقیاس حفره برای چنین سنگ‌هایی پرداخت. این روش‌ها امکان مشاهده پیچیدگی‌های مخزن را فراهم می‌آورند و از طرفی، قدرت بالایی در ساخت هندسه متخلخل و شبیه‌سازی جریان‌های چند فاز دارند. پیشرفت تکنولوژی عکس‌برداری سه‌بعدی مانند عکس‌های میکروسی‌تی‌اسکن، نانوسی‌تی‌اسکن، میکروسکوپ الکترونی روبشی (SEM) و عکس‌برداری باریکه یونی متمرکز (FIB-SEM) سبب گسترش استفاده از روش‌های آنالیز مغزه دیجیتال شده‌اند. میکروسی‌تی‌اسکن سه‌بعدی، پرکاربردترین روش تصویربرداری است. با توجه به محدودیت ذاتی این دستگاه در تصویربرداری از حفرات مقیاس ریز و عدم دسترسی به تصاویر سه‌بعدی با وضوح بالا، گروهی از محققان اقدام به توسعه روش‌هایی برای ساخت مدل سه‌بعدی شبکه حفرات از تصاویر دو بعدی با وضوح بالا در ترکیب با تصاویر سه‌بعدی کرده‌اند. استفاده از روش‌های تصویربرداری در مقیاس نانومتری مانند FIB-SEM و همچنین نانوسی‌تی‌اسکن، می‌تواند به شناخت بیشتر از رفتار سنگ‌های متراکم بپردازد. از هوش مصنوعی در کاربردهای متعددی در مهندسی نفت از جمله در حوزه‌های، اکتشاف [۱ و ۲]، حفاری [۳]،

1. Digital Core Analysis  
2. Inception Distance Function

است. همچنین از ظهور و استفاده آن در بازسازی شبکه حفرات مدت زمان زیادی نمی‌گذرد. در این مطالعه، کارآیی یک شبکه عصبی DCGAN در بازسازی تصاویر سنگ مخزن متراکم، که در منابع کمتر به آن توجه شده است، استفاده شده است. پیش‌بینی خواص چنین نمونه‌هایی به علت تداخل و تراوایی بسیار پایین به کمک روش‌های مستقیم اندازه‌گیری خواص سنگ (آنالیز مغزه روتین و ویژه) بسیار دشوار است. با توجه به اندازه ریزحفرات سنگ مخزن متراکم (غالباً در ابعاد نانو)، از تصاویر سه‌بعدی حاصل از دستگاه FIB-SEM استفاده شده است. این روش تصویربرداری توانایی نمایش حفرات در ابعاد نانومتری را دارا است. به منظور صحت‌سنجی نتایج به دست آمده علاوه بر محاسبه تداخل و تراوایی نمونه‌های ساخته شده و نمونه واقعی، تابع احتمال دونقطه‌ای و تابع مسیر خطی نمونه اصلی با نمونه‌های ساخته شده از شبکه عصبی مقایسه می‌شود.

## روش کار

### شبکه عصبی مولد رقابتی

برای نخستین بار گودفلو و همکارانش [۲۰] روش شبکه عصبی مولد رقابتی یا به اختصار GAN را معرفی کردند. این مدل رویه‌ای متفاوت از سایر الگوریتم‌های عصبی دارد و از دو شبکه عصبی به صورت هم‌زمان استفاده می‌نماید. یک شبکه عصبی تمییزدهنده<sup>۲</sup> و دیگری تولیدکننده<sup>۳</sup> نامیده می‌شود. این دو شبکه به صورت هم‌زمان فعالیت می‌کنند. هدف تولیدکننده ساخت خروجی مشابه با داده‌های ورودی است و هدف تمییزدهنده این است که مشخص کند آیا داده‌های وارد شده واقعی هستند یا دروغین. رقابت ایجاد شده بین دو شبکه باعث پیشرفت هر دوی آن‌ها می‌شود و خروجی کلی مدل نزدیک به داده‌های ورودی خواهد بود.

آن‌ها در ادامه با گسترش شبکه توسعه داده شده خود موفق به بازسازی شبکه حفرات یک مدل سنگ آهکی با مقیاس بزرگتر بدون نیاز به تقسیم‌بندی فاز از روی داده‌های میکروسی‌تی‌اسکن شدند [۱۴]. ژنگ و همکاران در بررسی‌های خود به این نتیجه رسیدند در زمانی که داده‌های ورودی کم است می‌توان با اضافه کردن یک‌سری از داده‌ها به صورت دستی به شبکه عصبی cGAN دقت مدل را بالاتر برد [۱۵]. شمس و همکاران برای مدل‌سازی یک سنگ متراکم با تداخل دوگانه از ترکیب شبکه عصبی GAN و شبکه عصبی خود رمزنگار<sup>۱</sup> استفاده کردند. در این مدل، شبکه عصبی GAN وظیفه بازسازی محیط متداخل بین دانه‌های را دارد و شبکه عصبی خود رمزنگار به بازسازی محیط متداخل درون دانه‌های می‌پردازد [۱۶]. لیو و همکاران به مشاهده اثر پیش پردازش داده‌های یک محیط متداخل همگن و ناهمگن در شبکه عصبی GAN پرداختند. آن‌ها دریافتند که عملیات‌های پیش‌پردازش باعث افزایش سرعت همگرایی مدل GAN می‌شود [۱۷]. در کار با داده‌های سه‌بعدی، محدودیت‌های سیستم همواره یکی از موانع کار محققان بوده است. کائو و همکارانش برای غلبه بر این مشکل از مدلی متشکل از دو شبکه عصبی InfoGAN و Style based GAN استفاده کرده‌اند که اصطلاحاً به آن CIS-GAN گفته می‌شود [۱۸]. ژائو و همکاران با استفاده از شبکه عصبی DCGAN اقدام به بازسازی شبکه حفرات یک ماسه سنگ متراکم کردند. آن‌ها با بررسی توزیع اندازه حفرات و تابع توزیع احتمال دریافتند که یک شبکه عصبی DCGAN در صورت آموزش صحیح نتایجی بسیار نزدیک به داده‌های ورودی ایجاد می‌نماید. نمونه‌های ساخته شده با یک مدل آموزش دیده ساختار حفراتی متفاوت از سنگ اصلی دارند اما توزیع تداخل آن‌ها مشابه است [۱۹].

شبکه عصبی GAN علی‌رغم ظاهر ساده‌ای که دارد، پیچیدگی‌های فراوانی را در عمق خود پنهان کرده

1. Auto Encoder (AE)

2. Discriminator

3. Generator

در این الگوریتم مدل سازنده بر مبنای رقابت پیوسته و هم‌زمان شبکه مولد (G) و تمییزدهنده (D) تخمین زده می‌شود. الگوریتم مولد توزیع داده‌ها را به دست می‌آورد و الگوریتم تمییزدهنده مشخص می‌کند که آیا داده‌های ورودی چه میزانی مشابه مدل واقعی هستند یا که توسط الگوریتم مولد ساخته شده‌اند. هدف این شبکه عصبی افزایش دقت الگوریتم مولد تا جایی است که شبکه تمییزدهنده دیگر قادر به تشخیص داده‌های ساختگی و واقعی نباشد. برای یادگیری توزیع مولد  $P_g$  بر داده‌های  $x$  یک نوفه اولیه بر داده‌های ورودی  $P_z(z)$  تعریف می‌شود. سپس یک نگاشت به فضای داده‌ها به صورت  $G(z; \theta_g)$  تعیین می‌شود که  $G$  یک تابع تمایز است که توسط یک پرسپترون<sup>۱</sup> چندلایه با مقدار  $\theta_g$  نمایش داده می‌شود. یک پرسپترون چندلایه دوم  $D(x; \theta_d)$  نیز تعریف می‌شود که خروجی آن به صورت عددی<sup>۲</sup> است. این الگوریتم آموزش می‌بیند تا احتمال تخصیص برچسب صحیح توسط تمییزدهنده بر روی داده‌های ورودی واقعی و داده‌های ساخته شده با مولد افزایش یابد. در همین حال، مولد آموزش می‌بیند تا مقدار  $\log(1-D(G(z)))$  به کم‌ترین مقدار ممکن برسد. به بیان دیگر، مولد و تمییزدهنده بازی حداقل-حداکثر<sup>۳</sup> دو نفره زیر را با تابع مقدار  $V(G, D)$  انجام می‌دهند که با استفاده از مقدار چشم‌داشتی<sup>۴</sup>  $E$  می‌توان رابطه را به صورت زیر نوشت [۲۰]:

$$D_G^*(x) = \frac{P_{data}(x)}{P_{data}(x) + P_g(x)} \quad (2)$$

معیار آموزش تمییزدهنده با توجه به هر مولدی به حداکثر رساندن تابع مقدار  $V(G, D)$  نمایش داده شده در رابطه ۳ است.

$$V(G, D) = \int_x P_{data}(x) \log(D(x)) dx + \int_z P_z(z) \log(1-D(G(z))) dx + \int_x P_{data}(x) \log(D(x)) + P_g(x) \log(1-D(x)) dx \quad (3)$$

بازی حداقل-حداکثر رابطه ۱ را اکنون می‌توان به صورت رابطه ۴ دوباره نویسی نمود.

$$C(G) = \max_D V(G, D) = E_{x \sim P_{data}} [\log D_G^*(x)] + E_{z \sim P_z} [\log(1-D_G^*(G(z)))] = E_{x \sim P_{data}} [\log D_G^*(x)] + E_{x \sim P_g} [\log(1-D_G^*(x))] = E_{x \sim P_{data}} \left[ \log \frac{P_{data}(x)}{P_{data}(x) + P_g(x)} \right] + E_{x \sim P_g} \left[ \log \frac{P_g(x)}{P_{data}(x) + P_g(x)} \right] \quad (4)$$

مقدار حداقل تابع مقدار  $C(G)$  تنها زمانی به دست می‌آید که  $P_g = P_{data}$  باشد [۲۰].

#### تابع اتلاف<sup>۵</sup>

بیشتر الگوریتم‌ها در یادگیری ماشین، بر مبنای کمینه یا بیشینه‌سازی تابع هدف، عمل می‌کنند. گروهی از توابع هدف که قرار است کمینه شوند به توابع اتلاف معروف‌اند. البته به این توابع در مباحث هوش مصنوعی گاهی توابع هزینه<sup>۶</sup> نیز می‌گویند. هدف از توابع اتلاف محاسبه مقداری است که یک مدل باید در طول آموزش به دنبال به حداقل رساندن آن باشد.

توابع اتلاف انواع مختلفی دارند در این پژوهش از دو تابع میانگین مربعات (MSE) و آنتروپی متقاطع دودویی<sup>۱</sup> استفاده شده است [۲۱].

1. Perceptron  
2. Scalar  
3. Minmax  
4. Expected Value  
5. Loss Function  
6. Cost Function

در این الگوریتم مدل سازنده بر مبنای رقابت پیوسته و هم‌زمان شبکه مولد (G) و تمییزدهنده (D) تخمین زده می‌شود. الگوریتم مولد توزیع داده‌ها را به دست می‌آورد و الگوریتم تمییزدهنده مشخص می‌کند که آیا داده‌های ورودی چه میزانی مشابه مدل واقعی هستند یا که توسط الگوریتم مولد ساخته شده‌اند. هدف این شبکه عصبی افزایش دقت الگوریتم مولد تا جایی است که شبکه تمییزدهنده دیگر قادر به تشخیص داده‌های ساختگی و واقعی نباشد. برای یادگیری توزیع مولد  $P_g$  بر داده‌های  $x$  یک نوفه اولیه بر داده‌های ورودی  $P_z(z)$  تعریف می‌شود. سپس یک نگاشت به فضای داده‌ها به صورت  $G(z; \theta_g)$  تعیین می‌شود که  $G$  یک تابع تمایز است که توسط یک پرسپترون<sup>۱</sup> چندلایه با مقدار  $\theta_g$  نمایش داده می‌شود. یک پرسپترون چندلایه دوم  $D(x; \theta_d)$  نیز تعریف می‌شود که خروجی آن به صورت عددی<sup>۲</sup> است. این الگوریتم آموزش می‌بیند تا احتمال تخصیص برچسب صحیح توسط تمییزدهنده بر روی داده‌های ورودی واقعی و داده‌های ساخته شده با مولد افزایش یابد. در همین حال، مولد آموزش می‌بیند تا مقدار  $\log(1-D(G(z)))$  به کم‌ترین مقدار ممکن برسد. به بیان دیگر، مولد و تمییزدهنده بازی حداقل-حداکثر<sup>۳</sup> دو نفره زیر را با تابع مقدار  $V(G, D)$  انجام می‌دهند که با استفاده از مقدار چشم‌داشتی<sup>۴</sup>  $E$  می‌توان رابطه را به صورت زیر نوشت [۲۰]:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1-D(G(z)))] \quad (1)$$

در این رابطه،  $z$  یک توزیع تصادفی به عنوان داده‌های ورودی به مولد است و  $G(z)$  نمونه ساخته شده با استفاده از ورودی تصادفی به عنوان نوفه اولیه است. مولد به طور ضمنی توزیع احتمال  $P_g$  را به عنوان توزیع نمونه‌های  $G(z)$  هنگامی که  $z \sim P_z$  به دست می‌آید، تعریف می‌کند. در این روش، تلاش می‌شود تا الگوریتم به یک تخمین مناسب از  $P_{data}$  برسد. در این بازی حداقل-حداکثر،

## بهینه‌ساز

بهینه‌سازها روش‌ها یا الگوریتم‌هایی هستند که برای تغییر ویژگی‌های شبکه عصبی مانند وزن و نرخ یادگیری<sup>۲</sup> به منظور کاهش اتلاف به کار می‌روند. الگوریتم تخمین گشتاور تطبیقی یا Adam به عنوان یکی از پرکاربردترین الگوریتم‌های بهینه‌ساز در مدل‌سازی محیط متخلخل با استفاده از شبکه عصبی به کار رفته است. پیاده‌سازی این روش به سادگی قابل انجام است و از نظر محاسباتی کارآمد و به حافظه کمی نیاز دارد. در مواقعی که داده‌ها و یا پارامترها بزرگ هستند، از شبکه‌های عصبی عمیق استفاده می‌شود. همچنین در مواقعی که داده‌های ورودی پیچیدگی دارند یا که نوفه ورودی زیاد است این روش بهتر از سایر الگوریتم‌ها عمل می‌کند. همچنین در بهینه‌سازی شبکه‌های عصبی که ورودی آن‌ها داده‌های تصویری است نیاز به تنظیمات کمی دارد [۲۲]. مشخصات توابع اتلاف و تابع بهینه‌ساز به کار رفته در این پژوهش را می‌توان در **جدول ۱** مشاهده کرد.

**جدول ۱** مشخصات توابع اتلاف و بهینه‌ساز به کار رفته در شبکه عصبی مولد رقابتی

پارامتر	شبکه مولد	شبکه تمییزدهنده
تابع اتلاف	میانگین مربعات	آنتروپی متقاطع دودویی
بهینه‌ساز	Adam	Adam
نرخ یادگیری	$10^{-4}$	$10^{-5}$

## ساختار شبکه عصبی به کار رفته

در این مطالعه از یک شبکه عصبی DCGAN متشکل از لایه‌های عصبی همگشتی استفاده شده است. به منظور طراحی معماری مناسب لایه‌ها از مدل ارائه شده شمس و همکاران [۱۶] و ژائو و همکاران [۱۹] الهام گرفته شده و مدل مناسب با شرایط سنگ متراکم مورد استفاده و داده‌های

ورودی ساخته شده است. به این صورت که در شبکه عصبی مولد از ۶ لایه عصبی همگشتی برای ایجاد تصاویر استفاده می‌نماید. هر کدام از این لایه‌ها از یک تابع فعال‌ساز ReLU استفاده می‌نمایند و در آخرین لایه از تابع فعال‌ساز tanh استفاده شده است. به صورت تناوبی از لایه‌های Batchnormalization هم استفاده شده است. برای شبکه تمییزدهنده نیز از ۵ لایه عصبی همگشتی استفاده شده است. در انتهای هر لایه از یک تابع فعال‌ساز LeakyReLU استفاده شده است همچنین در لایه آخر برای تشخیص تصاویر واقعی از تصاویر ایجاد شده، از یک تابع فعال‌ساز sigmoid استفاده شده است. در شبکه عصبی تمییزدهنده تنها در لایه یکی مانده به آخر از لایه Batchnormalization استفاده شده است. در **جدول ۲** ساختار شبکه عصبی به کار رفته آورده شده است. شماتیک ساختار شبکه عصبی مولد رقابتی به کار رفته در این پژوهش در **شکل ۱** به نمایش در آمده است. با توجه به ساختار و فلسفه شبکه‌های عصبی برای بهره گرفتن از آن‌ها لازم است از سیستم‌های رایانه‌ای مجهز به پردازنده گرافیکی استفاده بشود در غیر این صورت زمان اجرا بسیار طولانی خواهد بود. مشخصات سیستم رایانه‌ای مورد استفاده را می‌توان در **جدول ۳** مشاهده کرد.

## تابع احتمال دو نقطه‌ای

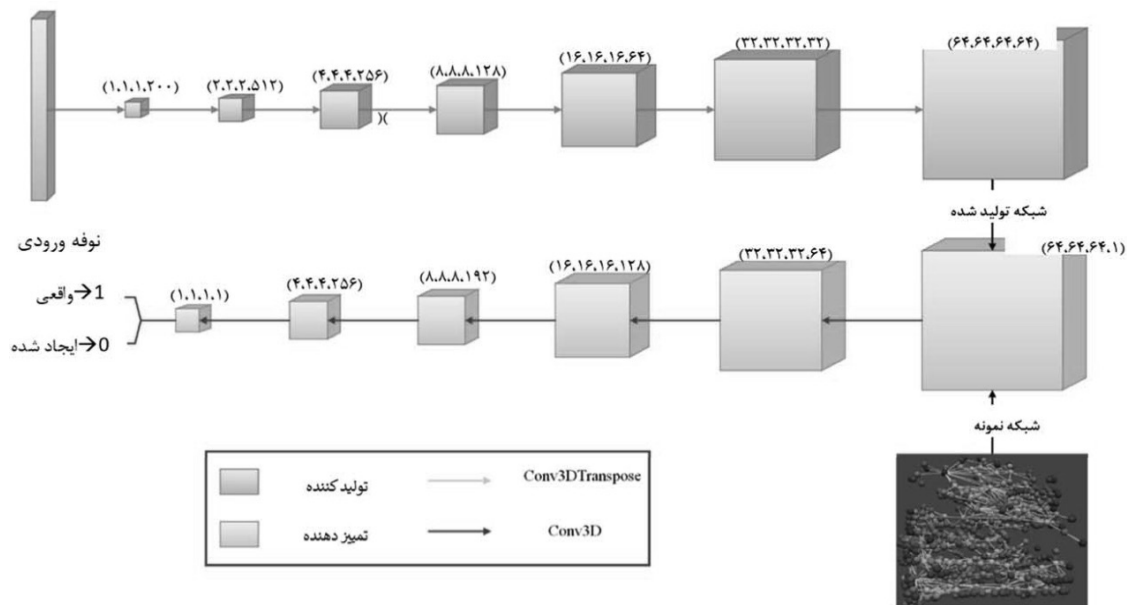
برای بررسی کیفیت ریزساختارهای ایجاد شده با استفاده از شبکه عصبی مولد رقابتی با شرط ایستایی تصاویر ایجاد شده یکی از روش‌های مورد استفاده تابع احتمال دو نقطه‌ای است. با استفاده از این تابع می‌توان ساختار مرتبه دوم محیط متخلخل در فاز حفره را مشخص کرد. با فرض ثابت بودن، این تابع معادل کوواریانس بدون مرکز<sup>۳</sup> است [۱۳].

$$S_2(r) = P(x \in p, x+r \in p) \text{ for } x, r \in \mathbb{R}^d \quad (5)$$

1. Binary Cross-Entropy  
2. Learning Rate  
3. Uncentered Covariance

جدول ۲ ساختار شبکه عصبی مولد و تمییزدهنده

لایه	مدل	فیلتر	کرنل یا هسته	شیفت	نرمال سازی بیچ	فعال ساز
شبکه مولد						
۱	Conv3DTranspose	۵۱۲	۴*۴*۴	۲	بله	ReLU
۲	Conv3DTranspose	۲۵۶	۴*۴*۴	۲	خیر	ReLU
۳	Conv3DTranspose	۱۲۸	۴*۴*۴	۲	بله	ReLU
۴	Conv3DTranspose	۶۴	۴*۴*۴	۲	خیر	ReLU
۵	Conv3DTranspose	۳۲	۴*۴*۴	۲	بله	ReLU
۶	Conv3DTranspose	۱	۴*۴*۴	۲	خیر	tanh
شبکه تمییزدهنده						
۱	Conv3D	۶۴	۴*۴*۴	۲	خیر	LeakyReLU
۲	Conv3D	۱۲۸	۴*۴*۴	۲	خیر	LeakyReLU
۳	Conv3D	۱۹۲	۴*۴*۴	۲	خیر	LeakyReLU
۴	Conv3D	۲۵۶	۴*۴*۴	۲	بله	LeakyReLU
۵	Conv3D	۱	۴*۴*۴	۲	خیر	sigmoid



شکل ۱ شماتیک شبکه عصبی مولد رقابتی به کار رفته

جدول ۳ مشخصات سیستم رایانه‌ای مورد استفاده

پردازنده	مدل	تعداد هسته	سرعت پایه	نرخ کلاک	حافظه موقت
پردازنده مرکزی	Intel(r) xeon(r) gold 6140	۳۶	۲۳۰۰ MHz	۳۷۰۰ MHz	۳۷۷ GB
پردازنده گرافیکی	NVIDIA Tesla V100 PCIe	۵۱۲۰ CUDA	۱۲۴۵ MHz	۱۳۸۰ MHz	۳۲ GB

استوکس نیروی غالب جریان از نوع نیروهای ویسکوز است که عدد رینولدز آن کوچکتر از یک است. از آن جایی که نیروهای ویسکوز نیروی غالب در این جریان است از نیروهای داخلی صرف نظر می‌شود در نتیجه با حذف پارامترهای تعادل انرژی جنبشی در رابطه ناویر-استوکس تعادل جنبشی به صورت زیر حاصل می‌شود:

$$\nabla \cdot P + f = 0 \quad (8)$$

در رابطه بالا، P نشان دهنده فشارهای وارده و f نیروهای وارد بر سطح را نشان می‌دهد. هدایت هیدرولیکی که به عنوان ضریب تراوایی شناخته شده است بین دو حفره i و j با استفاده از رابطه هگن-پوالسه به صورت زیر قابل محاسبه است:

$$g_{H,i,j} = g_{H,i} = \pi/128 (D_i^4)/L_i \quad (9)$$

در این رابطه،  $D_i$  حجم و  $L_i$  طول گلوگاه را نشان می‌دهند. برای محاسبه جریان بین دو حفره رابطه زیر مورد استفاده قرار می‌گیرد:

$$q_{i,j} = \pi/128 \mu (D_i^4)/L_i (P_j - P_i) = g_{H,i} \Delta P_{i,j} \quad (10)$$

$\mu$  نشانگر ویسکوزیته و P فشار حفره را نشان می‌دهد. سپس با استفاده از رابطه داریسی، تراوایی‌ها در سه جهت محاسبه و میانگین آن‌ها به عنوان تراوایی کل محاسبه می‌گردد [۲۴].

#### تصویربرداری

برای تصویربرداری از نمونه سنگ از دستگاه FIB-SEM استفاده شده است. روش کار دستگاه FIB-SEM به این صورت است که ابتدا با استفاده از میکروسکوپ الکترونی از نمونه عکس گرفته می‌شود. سپس با بمباران نمونه به وسیله یون‌ها لایه‌ای از روی سطح نمونه برداشته می‌شود و این روند تکرار می‌شود تا یک سری تصویر دو بعدی پشت سر هم به دست آید که با اتصال آن‌ها به یکدیگر می‌توان یک تصویر سه بعدی از نمونه ایجاد کرد. برای انجام این کار از زبان برنامه نویسی پایتون و نرم افزار پردازش تصویر ImageJ استفاده می‌شود. تصویر سه بعدی به دست آمده از این دستگاه را در شکل ۳ می‌توان مشاهده نمود.


P احتمال بین دو نقطه x و  $x+r$  است که با بردار تأخیر r از یکدیگر جدا شده‌اند. دو نقطه با فاصله هر دو در فاز حفره (p) قرار دارند. هر چند که  $S_2(r)$  را می‌توان برای هر دو فاز سنگ یا حفره در فضای متخلخل تعریف کرد که  $S_2(0)$  بیانگر تخلخل محیط متخلخل است [۱۱].

#### تابع مسیر خطی

یکی دیگر از روش‌هایی که در بررسی دقت ریزساختارهای ساخته شده به کار می‌رود تابع مسیر خطی است. این تابع اتصال منافذ را با محاسبه احتمال این که خط  $L_r$  به طول r به طور کامل در فضای خالی باشد، بررسی می‌کند [۱۵]. این تابع به صورت زیر تعریف می‌شود:

$$L(r) = \text{prob} \{I(u)=1, I(u+1)=1, \dots, I(u+r)=1\} \quad (6)$$

در این تابع، u مبدأ خط  $L_r$ ، I(u) یک نشانگر  $I(u+1)=1$  تمام نقاط خط، در فضای حفره است [۱۵]. شماتیک توابع احتمال دو نقطه‌ای و مسیر خطی را می‌توان در شکل ۲ مشاهده کرد.




شکل ۲ توابع احتمال دو نقطه‌ای و مسیر خطی [۲۳]

#### نحوه محاسبه تخلخل و تراوایی

برای محاسبه تخلخل حجم فضاهای خالی محاسبه می‌شود و با تقسیم حجم کل فضای حفرات به حجم کل نمونه تخلخل محاسبه می‌گردد.

$$\phi = \sum V_p / L_x \times L_y \times L_z \quad (7)$$

به منظور محاسبه تراوایی مطلق شبکه جریان در سه جهت برقرار و از معادلات جریان استوکس در محاسبه دبی جریان استفاده می‌شود. در جریان



شکل ۳ تصویر سه‌بعدی FIB-SEM از نمونه

قسمتی از داده‌ها از شبکه است. تقسیم داده‌ها به قسمت‌های کوچکتر به منظور مدیریت حافظه و کنترل بیشتر بر روی یادگیری انجام می‌شود. برای انتخاب بهترین تعداد تکرار در ابتدا ۲۰۰ نمونه کاملاً تصادفی از داده‌های ورودی انتخاب و تخلخل و تراوایی میانگین این نمونه‌ها محاسبه می‌شود. پس از هر ده بار آموزش شبکه، ۲۰۰ نمونه تصادفی از شبکه حفرات ساخته می‌شود و تخلخل و تراوایی میانگین آن‌ها محاسبه می‌گردد. همان‌طور که در شکل ۴ مشاهده می‌شود، کمترین میزان خطا در ۱۰۰ تکرار به دست می‌آید. در شکل ۵ می‌توان یک برش دو بعدی از یک تصویر ساخته شده با شبکه عصبی را در مقایسه با برش دو بعدی یک تصویر ورودی از نمونه واقعی را مشاهده کرد. در این شکل می‌توان از لحاظ کیفی و بصری تصاویر را با یکدیگر مقایسه کرد و می‌توان تشابه الگوی حفرات در تصویر ساخته شده در مقایسه با نمونه اصلی مشاهده نمود. پس از آموزش شبکه عصبی می‌توان شبکه آموزش دیده را ذخیره کرد و هر زمان که نیاز به ساخت تصاویری منطبق بر داده‌های ورودی بود دوباره آن را بازخوانی کرد. به منظور مقایسه داده‌های واقعی و شبکه ساخته شده دو تا از مهم‌ترین خواص پتروفیزیکی سنگ که تخلخل و تراوایی می‌باشند، برای نمونه‌های ساخته شده و نمونه‌های برداشته شده از تصویر واقعی سنگ مورد مقایسه قرار گرفته‌اند.


وضوح و اکسل‌های این تصویر برابر با  $12/5 \text{ nm}$  و اندازه کلی تصویر ۱۸ در ۱۳ در  $3/75 \mu\text{m}$  است. لازم به ذکر است تصویر مورد استفاده از مؤسسه زمین‌شناسی دانشگاه ماینس آلمان گرفته شده است [۲۵]

### نتایج و بحث

شبکه‌های عصبی به جای حل مسائل با راه‌حل‌های مشخص، تلاش می‌کنند تا ارتباط داده‌های ورودی و خروجی را با استفاده از الگوریتم‌های تعریف شده، به دست آورند. در نتیجه، اطلاعات ورودی نقش مهمی در دقت این روش‌ها دارند. به منظور آماده‌سازی اطلاعات ورودی محتوای خام به دست آمده از FIB-SEM با استفاده از نرم‌افزار ImageJ به فایل باینری<sup>۱</sup> تبدیل می‌شود. از آنجایی که نوفه بسیار کمی در این تصاویر وجود داشت، تصاویر به صورت مستقیم به مرحله تقسیم فاز-جدایش فاز حفره و سنگ-رفتند و از روش‌های پالایش نوفه استفاده نشد. با تقسیم تصویر اصلی به قطعات کوچکتر تعداد  $3780$  تصویر سه‌بعدی در ابعاد  $64 \times 64 \times 64$  به عنوان ورودی شبکه عصبی مولد رقابتی آماده‌سازی می‌شود. پس از بررسی نتایج به دست آمده از شبکه عصبی مشخص گردید بهترین و دقیق‌ترین نتایج در این شبکه ۱۰۰ بار آموزش شبکه یا ۲۰۰۰ تکرار حاصل می‌شود. در هر بار آموزش شبکه، کل داده‌ها از الگوریتم گذرانده می‌شود و هر تکرار برابر با عبور

1. Binary





اپوک

شکل ۴ خطای نسبی تخلخل (▲) و تراوایی (+) شبکه‌های ساخته شده با مدل DCGAN برحسب تعداد تکرار




شکل ۵ برش دو بعدی از ریزساختارها: الف) تصویر واقعی گرفته شده با FIB-SEM و ب) تصویر ساخته شده با شبکه عصبی DCGAN


بوده است حضور پر رنگ‌تری دارند. در شکل ۸ نمودار جعبه‌ای تخلخل و تراوایی ۲۰۰ نمونه واقعی در مقابل ۲۰۰ نمونه ساخته شده با مدل مشاهده می‌شود. همان‌طور که در این نمودارها دیده می‌شود تطابق خوبی بین نمونه‌های ساخته شده با داده‌های واقعی برقرار است. دو تابع اتصال دو نقطه‌ای و مسیر خطی نیز دید خوبی از دقت نمونه‌های ساخته شده با شبکه عصبی GAN به ما می‌دهند.

در نمودارهای شکل ۹ تعداد ۵۰ نمونه از شبکه‌های ساخته شده انتخاب و مقدار میانگین آن‌ها در مقایسه با داده‌های واقعی محاسبه شده از سنگ آورده شده است.


برای مقایسه نمونه‌های ساخته شده با نمونه اصلی، تعداد ۲۰۰ عدد نمونه به‌صورت اتفاقی از هر کدام از داده‌های واقعی و تولید شده انتخاب شده است. نمودار تراوایی و تخلخل این نمونه‌ها در شکل ۶ به نمایش در آمده است. با دقت در نمودار بالا مشخص است که تجمع شبکه‌های ساخته شده مایل به نقاطی است که پراکندگی داده‌ها در آن منطقه بیشتر است. این تجمع براساس خواص ذاتی آموزش شبکه‌های عصبی است که وزن شبکه بیشتر متمایل به مناطقی است که تجمع داده‌ها در آن نقاط بیشتر از سایرین است. همان‌طور که در شکل ۷ مشاهده می‌شود شبکه‌های ساخته شده در اطراف نقاطی که تجمع داده‌های ورودی بیشتر




شکل ۶ مقایسه بین تخلخل و تراوایی نمونه‌های جدا شده از سنگ واقعی (+) در مقابل نمونه‌های ساخته شده (▲) با شبکه عصبی




شکل ۷ نمودار توزیع میله‌ای درصد فراوانی برحسب تخلخل



شکل ۸ نمودار جعبه‌ای تخلخل و تراوایی ۲۰۰ نمونه حقیقی و ساخته شده با شبکه عصبی



(ب)



(ف)

شکل ۹ الف) توابع فاصله دو نقطه‌ای و ب) مسیر خطی نمونه سنگ در مقابل میانگین ۵۰ شبکه ساخته شده با الگوریتم DCGAN

مورد نیاز برای آموزش این شبکه عصبی نزدیک به یک ساعت بوده است که در مقایسه با سایر روش‌ها مانند MPS بسیار سریعتر محسوب می‌شود و از طرفی تنها با یکبار آموزش می‌توان به دفعات در کسری از ثانیه شبکه‌های جدیدی ایجاد کرد. نشان داده شد در صورت پیکربندی مناسب این شبکه عصبی توانایی ایجاد خروجی‌هایی منطبق با داده‌های ورودی حتی در صورتی که در تعداد داده‌های ورودی محدودیت وجود داشته باشد را دارا است.

### نتیجه‌گیری

در این پژوهش از یک شبکه عصبی DCGAN برای بازسازی شبکه حفرات یک نمونه سنگ متراکم استفاده شد. همان‌طور که در نتایج نشان داده شد نمونه‌های ساخته شده با شبکه عصبی آموزش داده شده تخلخل و تراوایی منطبق با نمونه‌های واقعی داشتند و از طرفی نمودارهای تابع احتمال دو نقطه‌ای و تابع مسیر خطی نیز مهر تایید دیگری بر دقت شبکه توسعه داده شده می‌باشند. کل زمان

### مراجع

- [1]. Seyedali S R, Alizadeh B, Zahmatkesh I, Sarafdokht H (2022) Estimation of total organic carbon content and kerogen type from well log data by combining artificial neural network and metaheuristic algorithms, Journal of Petroleum Research, 32, 1401-3: 112-130.
- [2]. Tofighi F, Armani P, Chehrizi A, Alimoradi A (2021) Comparison of the function of conventional neural networks for estimating porosity in one of the southeastern Iranian oil fields, Journal of Petroleum Research, 31, 400-3: 90-105.
- [3]. Moazzeni A, Khomehchi E (2019) Drilling rate optimization by automatic lithology prediction using hybrid machine learning, Journal of Petroleum Science and Technology, 9, 4: 77-88.
- [4]. Alipour Shahsavari M, Memarian H, Tokhmchi B, Sadigh S (2017) Reservoir rock type identification using Gustafson Kessel algorithm and LOLIMOT estimator, Journal of Petroleum Research, 26, 95-5: 184-196.
- [5]. Kadkhodaie A (2022) Reservoir quality evaluation based on integration of artificial intelligence and NMR-derived electrofacies, Journal of Petroleum Science and Technology.
- [6]. Khoshbakht F, Mohammadnia M, RahimiBahar A A, Beiraghdar Y (2015) Evaluating different approaches to permeability prediction in a carbonate reservoir, Journal of Petroleum Science and Technology, 5, 1: 79-90.
- [7]. Mirzaie Harsini F A, NazariSaram M (2022) Nonlinear model predictive controller for electrical submersible pump lifted wells, Journal of Petroleum Research.
- [8]. Feng J, He X, Teng Q, Ren C, Chen H, Li Y (2019) Reconstruction of porous media from extremely limited information using conditional generative adversarial networks, Physical Review E, 100, 3: 033308.
- [9]. Feng J, Teng Q, Li B, He X, Chen H, Li Y (2020) An end-to-end three-dimensional reconstruction framework of porous media from a single two-dimensional image based on deep learning, Computer Methods in Applied Mechanics and Engineering, 368: 113043.
- [10]. Volkhonskiy D, Muravleva E, Sudakov O, Orlov D, Belozero B, Burnaev E, Koroteev D (2019) Reconstruction of 3d porous media from 2d slices, arXiv preprint arXiv:1901.10233.

- [11]. Zha W, Li X, Xing Y, He L, Li D (2020) Reconstruction of shale image based on Wasserstein Generative Adversarial Networks with gradient penalty, *Advances in Geo-Energy Research*, 4, 1: 107-114.
- [12]. Valsecchi A, Damas S, Tubilleja C, Arechalde J (2020) Stochastic reconstruction of 3D porous media from 2D images using generative adversarial networks, *Neurocomputing*, 399: 227-236.
- [13]. Mosser L, Dubrule O, Blunt M J (2017) Reconstruction of three-dimensional porous media using generative adversarial neural networks, *Physical Review E*, 96, 4: 043309.
- [14]. Mosser L, Dubrule O, Blunt M J (2018) Stochastic reconstruction of an oolitic limestone by generative adversarial networks, *Transport in Porous Media*, 125, 1: 81-103.
- [15]. Zheng Q, Zhang D (2022) Digital rock reconstruction with user-defined properties using conditional generative adversarial networks, *Transport in Porous Media*, 1-27.
- [16]. Shams R, Masihi M, Boozarjomehry R B, Blunt M J (2020) Coupled generative adversarial and auto-encoder neural networks to reconstruct three-dimensional multi-scale porous media, *Journal of Petroleum Science and Engineering*, 186: 106794.
- [17]. Liu S, Zhong Z, Takbiri-Borujeni A, Kazemi M, Fu Q, Yang Y (2019) A case study on homogeneous and heterogeneous reservoir porous media reconstruction by using generative adversarial networks, *Energy Procedia*, 158: 6164-6169.
- [18]. Cao D, Hou Z, Liu Q, Fu F (2022) Reconstruction of three-dimension digital rock guided by prior information with a combination of InfoGAN and style-based GAN, *Journal of Petroleum Science and Engineering*, 208, 109590.
- [19]. Zhao J, Wang F, Cai J (2021) 3D tight sandstone digital rock reconstruction with deep learning, *Journal of Petroleum Science and Engineering*, 207, 109020.
- [20]. Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y (2014) Generative adversarial nets, *Advances in Neural Information Processing Systems*, Proceedings of the 27th International Conference on Neural Information Processing Systems, 2, 2672-2680.
- [21]. Mütter D, Sørensen H, Jha D, Harti R, Dalby K, Suhonen H, Feidenhansl R, Engstrøm F, Stipp S (2014) Resolution dependence of petrophysical parameters derived from X-ray tomography of chalk, *Applied Physics Letters*, 105, 4: 043108.
- [22]. Kingma D P, Ba J (2014) Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980.
- [23]. Zhang F, He X, Teng Q, Wu X, Dong X (2022) 3D-PMRNN: Reconstructing three-dimensional porous media from the two-dimensional image with recurrent neural network, *Journal of Petroleum Science and Engineering*, 208: 109652.
- [24]. Gostick J T (2017) Versatile and efficient pore network extraction method using marker-based watershed segmentation, *Physical Review E*, 96, 2: 023307.
- [25]. Jacob A, Peltz M, Hale S, Enzmann F, Moravcova O, Warr L N, Grathoff G, Blum P, Kersten M (2021) Simulating permeability reduction by clay mineral nanopores in a tight sandstone by combining computer X-ray microtomography and focussed ion beam scanning electron microscopy imaging, *Solid Earth*, 12, 1: 1-14.