

بازسازی تصویر سنگ مخزن متراکم با شبکه عصبی مولد رقابتی

علی کریمی و سعید صادق نژاد*

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

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

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 گلوبال‌های 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 می‌باید. 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 آموختن 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 بهتری 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

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^۱ (مخازن

مقدمه

1. Tight

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

پژوهش نفت شماره ۱۲۶، آذر و دی ۱۴۰۱، صفحه ۹۴-۸۳

مهندسی مخزن [۶-۴] و بهره‌برداری [۷] استفاده شده است. در مقیاس حفره، فنگ و همکاران برای فائق آمدن به کمبود داده‌های تصویری روشی بر مبنای شبکه عصبی GAN ارائه کردند. در این روش برای بهدست آوردن الگوی تصاویر ورودی و خروجی به جای استفاده از نوفه یا نویز در تولید کننده از قسمتی از تصویر واقعی به همراه یک نوفه اضافی- به منظور 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 ازتابع توزیع احتمال و تابع فاصله آغازین^۱ به اصلاح تصاویر ساخته شده پرداختند DCGAN [۱۱]. والسکی و همکاران یک شبکه عصبی توسعه دادند که مستقیم با استفاده از تصاویر دو بعدی به ایجاد تصاویر سه‌بعدی می‌پردازد. اساس کار این شبکه آموزش شبکه تمییزدهنده 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 به علت وجود حداقل یک تصویر دو بعدی غیرواقعی ایجاد شده است [۱۲].

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

1. Digital Core Analysis

2. Inception Distance Function

حفرات از ابعاد نانومتری در سنگ‌های متراکم تا میلی‌متر در سنگ‌های دارای تخلخل اتحالی (واگ) گستردۀ می‌شوند. مخازن متراکم نفتی عموماً دارای تخلخل کمتر از ۱۰٪ و نفوذپذیری کمتر از ۰/۱ mD هستند. در ک 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 به دست آورد. در سال‌های اخیر پیشرفت شگرف تجهیزات رایانه‌ای و تصویربرداری باعث گسترش هر چه بیشتر مدل‌سازی فضای متخلخل یا آنالیز مغزه دیجیتال^۲ 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 فازی دارند. پیشرفت تکنولوژی عکس‌برداری سه‌بعدی مانند عکس‌های میکروسکوپی تی‌اسکن، نانوسی‌تی‌اسکن، میکروسکوپ الکترونی روبشی (SEM) و عکس‌برداری باریکه یونی متمرکز (FIB-SEM) سبب گسترش استفاده از روش‌های آنالیز مغزه دیجیتال شده‌اند. میکرو سی‌تی اسکن 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 [۲]،

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 به‌علت تخلخل و تراوایی بسیار پایین به‌کمک روش‌های مستقیم اندازگیری خواص سنگ (آنالیز مغزه روتین و ویژه) بسیار دشوار است. با توجه به اندازه ریز حفرات 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 دارد. به‌منظور صحبت‌سنگی نتایج به‌دست آمده علاوه‌بر محاسبه تخلخل 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 به‌صورت همزمان استفاده می‌نماید. یک شبکه عصبی تمیزدهنده^۱ و دیگری تولیدکننده^۲ نامیده می‌شود. این دو شبکه به‌صورت همزمان فعالیت می‌کنند. هدف تولیدکننده ساخت خروجی مشابه با داده‌های ورودی است و هدف تمیزدهنده 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.

1. Auto Encoder (AE)
2. Discriminator
3. Generator

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 میکروسی‌تی اسکن 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 GAN دقیق‌تر مدل را بالاتر برد [۱۵]. شمس و همکاران برای مدل‌سازی یک سنگ متراکم با تخلخل دوگانه از ترکیب شبکه عصبی GAN و شبکه عصبی خود رمزنگار^۳ استفاده کردند. در این مدل، شبکه عصبی GAN وظیفه بازسازی محیط متخلخل بین دانه‌ای را دارد و شبکه عصبی خود رمزنگار به بازسازی محیط متخلخل درون دانه‌ای می‌پردازد [۱۶]. لیو و همکاران به مشاهده اثر پیش‌پردازش داده‌های یک محیط متخلخل 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 مشکل از دو شبکه عصبی استفاده کرده‌اند که Style based GAN و InfoGAN 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 تخلخل آن‌ها مشابه است [۱۹].

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

پژوهش نفت شماره ۱۲۶، آذر و دی ۱۴۰۱، صفحه ۹۴-۸۳

$P_g = P_{data}$ مقدار بهینه در نظر گرفته می‌شود. برای شبکه مولد ثابت مقدار بهینه تمیزدهنده (x) از $D_G^*(x)$ از طریق رابطه ۲ محاسبه می‌شود [۲۰].

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

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

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

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

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

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

تابع اتلاف \circ

بیشتر الگوریتم‌ها در یادگیری ماشین، برمبنای 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 تابع هزینه^۱ 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^۲ 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 هم‌زنمان شبکه مولد (G) و تمیزدهنده (D) تخمین زده می‌شود. الگوریتم مولد توزیع داده‌ها را به دست می‌آورد و الگوریتم تمیزدهنده 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 تمیزدهنده دیگر قادر به تشخیص داده‌های ساختگی و واقعی نباشد. برای یادگیری توزیع مولد P_g بر داده‌های x یک نویه اولیه بر داده‌های ورودی (z) P_z تعریف می‌شود. سپس یک نگاشت به فضای داده‌ها به صورت $G(z; \theta_g)$ تعیین می‌شود که G یک تابع تمايز است که توسط یک پرسپترون^۳ چندلایه با مقدار θ_g نمایش داده می‌شود. یک پرسپترون چندلایه دوم $(x; \theta_d)$ نیز تعریف می‌شود که خروجی آن به صورت عددی^۴ است. این الگوریتم آموزش می‌بیند تا احتمال تخصیص برچسب صحیح توسط تمیزدهنده 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 تمیزدهنده بازی حداقل-حداکثر^۵ دو نفره زیر را با تابع مقدار $V(G, D)$ انجام می‌دهند که با استفاده از مقدار چشم‌داشتی^۶ E می‌توان رابطه را به صورت زیر نوشت [۲۰]:

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

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 نویه 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،

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 استفاده شده است. Batchnormalization هم استفاده شده است. برای شبکه تمیزدهنده 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 تمیزدهنده 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 مجهرز 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 مخلخل در فاز حفره را مشخص کرد. با فرض ثابت بودن، این تابع معادل کواریانس بدون مرکز^۳ است [\[۱۳\]](#).

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

1. Binary Cross-Entropy

2. Learning Rate

3. Uncentered Covariance

بهینه‌ساز

بهینه‌سازها روش‌ها یا الگوریتم‌هایی هستند که برای تغییر ویژگی‌های شبکه عصبی مانند وزن و نرخ یادگیری^۱ به منظور کاهش اتلاف به کار می‌روند. الگوریتم تخمین گشتوار تطبیقی یا Adam به عنوان یکی از پرکاربردترین الگوریتم‌های بهینه‌ساز در مدل‌سازی محیط مخلخل 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 موقعي که داده‌ها و یا پارامترها بزرگ هستند، از شبکه‌های عصبی عمیق استفاده می‌شود. همچنین در موقعي که داده‌های ورودی پیچیدگی دارند یا که نویه 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

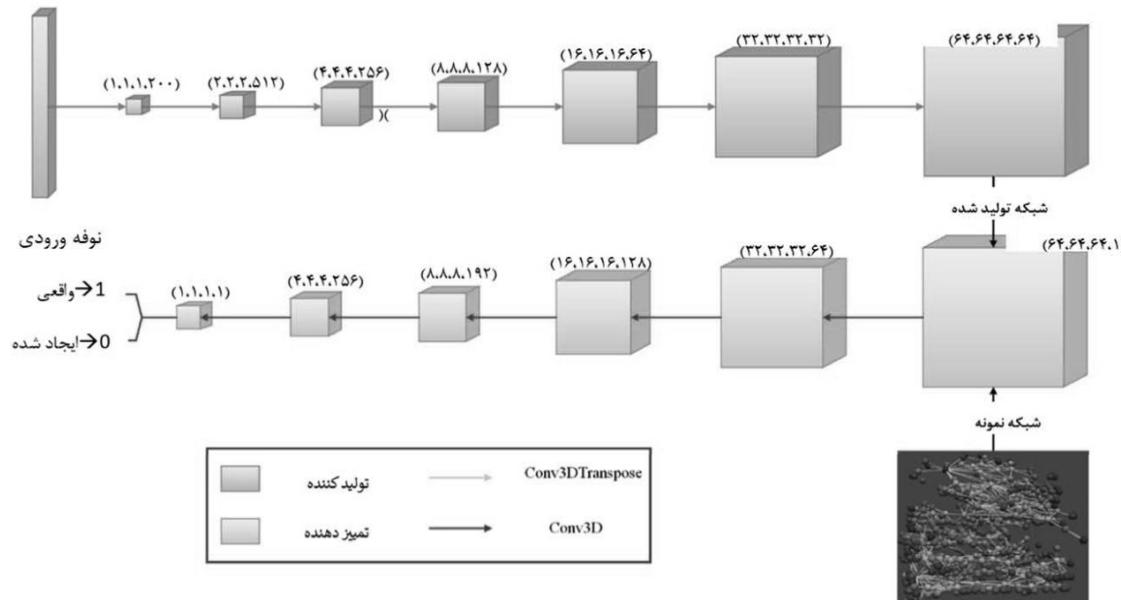
شبکه مولد	شبکه تمیزدهنده	پارامتر
آنتروپی متقاطع دودویی	میانگین مربعات	تابع اتلاف
Adam	Adam	بهینه‌ساز
10^{-5}	10^{-4}	نرخ یادگیری

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 زائو و همکاران [\[۱۹\]](#) الهام گرفته شده و مدل مناسب با شرایط سنگ متراکم مورد استفاده و داده‌های

جدول ۲ ساختار شبکه عصبی مولد و تمییزدهنده

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



شکل ۱ شماتیک شبکه عصبی مولد رقابتی به کار رفته

جدول ۳ مشخصات سیستم رایانه‌ای مورد استفاده

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

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 نشان‌دهنده فشارهای وارد و f نیروهای وارد بر سطح را نشان می‌دهد. هدایت هیدرولیکی که به عنوان ضریب تراوایی شناخته شده است بین دو حفره α و β با استفاده از رابطه هیگن-پوالسه به صورت زیر قابل محاسبه است:

$$g_{H,i,j} = g_{H,t} = \pi / 128 (D_t^4) / L_t \quad (9)$$

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

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

آنچه نشانگر ویسکوزیته و P فشار حفره را نشان می‌دهد. سپس با استفاده از رابطه دارسی، 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 وسیله‌ی 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.

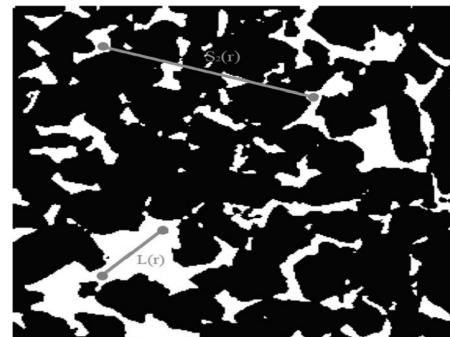
P احتمال بین دو نقطه $x+r$ و x است که با بردار τ از یکدیگر جدا شده‌اند. دو نقطه با فاصله r هر دو در فاز حفره (p) قرار دارند. هرچند که (r, S_2) را می‌توان برای هر دو فاز سنگ یا حفره در فضای متخلخل تعریف کرد که $(0, S_2)$ بیانگر تخلخل محیط متخلخل است [۱۱].

تابع مسیر خطی

یکی دیگر از روش‌هایی که در بررسی دقیق ریزساختارهای ساخته شده به کار می‌رود تابع مسیر خطی است. این تابع اتصال منافذ را با محاسبه احتمال این که خط τ 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، τ مبدأ خط r ، $I(u)$ یک نشانگر و $I(u+1) = 1$ 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

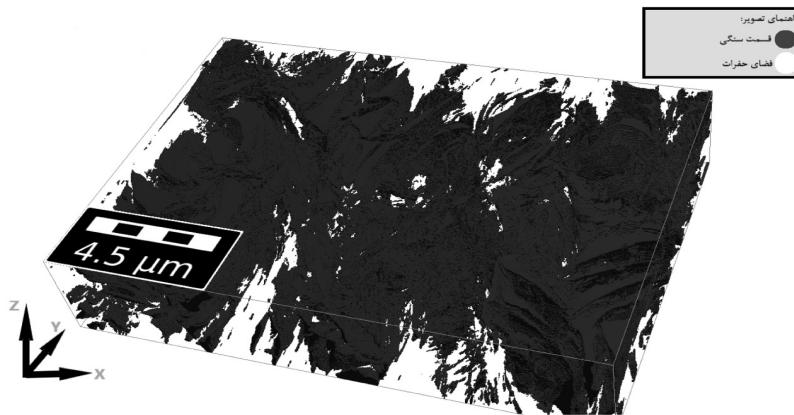
برای محاسبه تخلخل حجم فضاهای خالی محاسبه می‌شود و با تقسیم حجم کل فضای حفرات به حجم کل نمونه تخلخل محاسبه می‌گردد.

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

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

پژوهش نفت

شماره ۱۲۶، آذر و دی ۱۴۰۱، صفحه ۸۳-۹۴



شکل ۳ تصویر سه بعدی FIB-SEM از نمونه

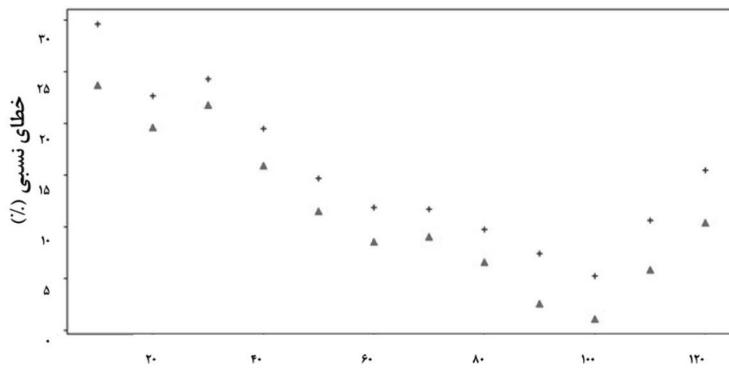
قسمتی از داده‌ها از شبکه است. تقسیم داده‌ها به قسمت‌های کوچکتر به منظور مدیریت حافظه و کنترل بیشتر بر روی یادگیری انجام می‌شود. برای انتخاب بهترین تعداد تکرار در ابتدا ۲۰۰ نمونه کاملاً تصادفی از داده‌های ورودی انتخاب و تخلخل و تراویبی میانگین این نمونه‌ها محاسبه می‌شود. پس از هر ده بار آموزش شبکه، ۲۰۰ نمونه تصادفی از شبکه حفرات ساخته می‌شود و تخلخل و تراویبی 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 تراویبی می‌باشند، برای نمونه‌های ساخته شده و نمونه‌های برداشته شده از تصویر واقعی سنگ مورد مقایسه قرار گرفته‌اند.

1. Binary

وضوح واکسل‌های این تصویر برابر با 12.5 nm و اندازه کلی تصویر $18 \text{ در } 13 \text{ در } 3.75 \mu\text{m}$ است. لازم به ذکر است تصویر مورد استفاده از مؤسسه زمین‌شناسی دانشگاه ماینتس آلمان گرفته شده است [۲۵]

نتایج و بحث

شبکه‌های عصبی به جای حل مسائل با راه حل‌های 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^۱ تبدیل می‌شود. از آن جایی 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 ۳۷۸۰ تصویر سه بعدی در ابعاد $64 \times 64 \times 64$ به عنوان ورودی شبکه عصبی مولد روابطی 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 ۲۰۰ تکرار حاصل می‌شود. در هر بار آموزش شبکه، کل داده‌ها از الگوریتم گذرانده می‌شود و هر تکرار برابر با عبور



اپوک

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



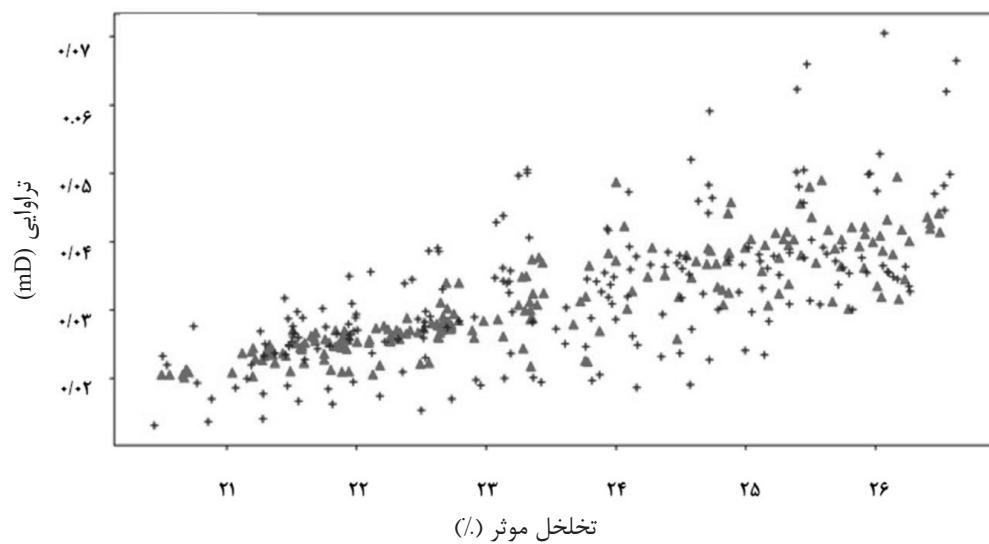
شکل ۵ برش دو بعدی از ریزساختارها: (الف) تصویر واقعی گرفته شده با FIB-SEM و (ب) تصویر ساخته شده با شبکه عصبی DCGAN

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 نمونه‌ها 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.

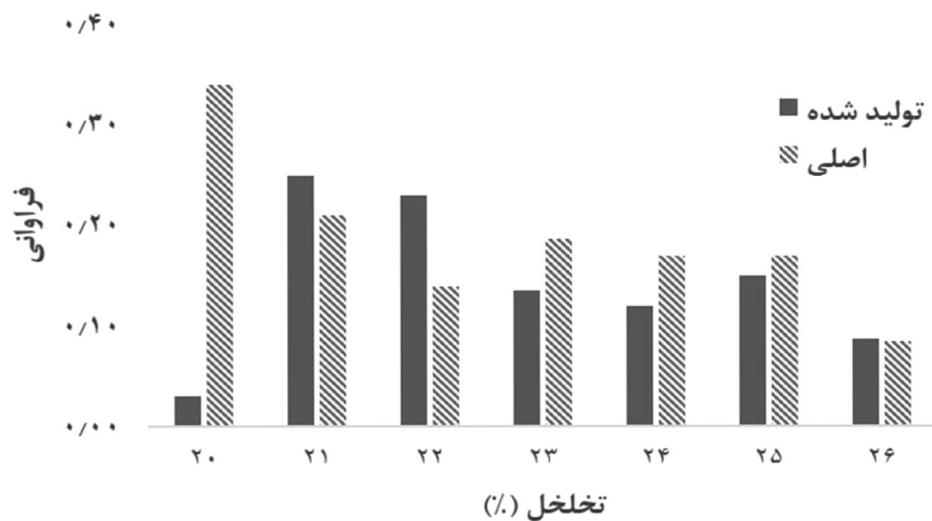
در نمونه‌های [شکل ۹](#) تعداد ۵۰ نمونه از شبکه‌های ساخته شده انتخاب و مقدار میانگین آن‌ها در مقایسه با داده‌های واقعی محاسبه شده از سنگ آورده شده است.

برای مقایسه نمونه‌های ساخته شده با نمونه اصلی، تعداد ۲۰۰ عدد نمونه به صورت 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 آموخته 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

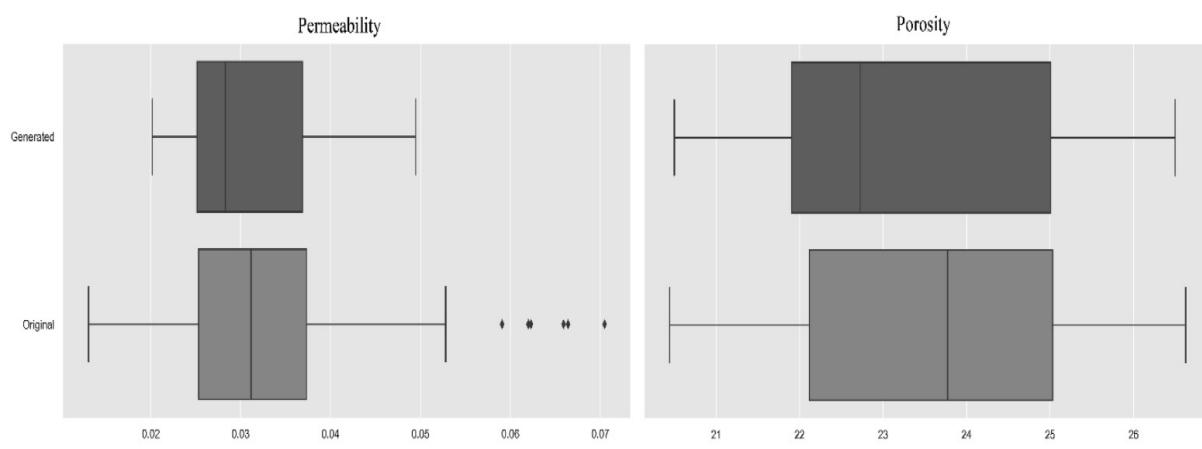
پژوهش نفت شماره ۱۲۶، آذر و دی ۱۴۰۱، صفحه ۸۳-۹۴



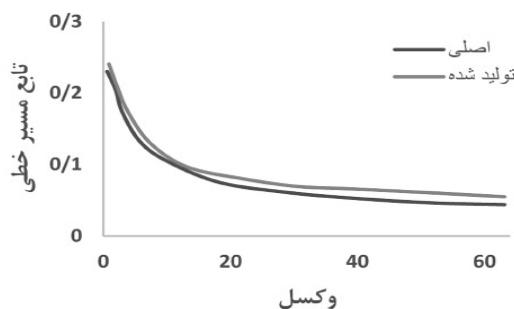
شکل ۶ مقایسه بین تخلخل و تراوایی نمونه‌های جدا شده از سنگ واقعی (+) در مقابل نمونه‌های ساخته شده (▲) با شبکه عصبی



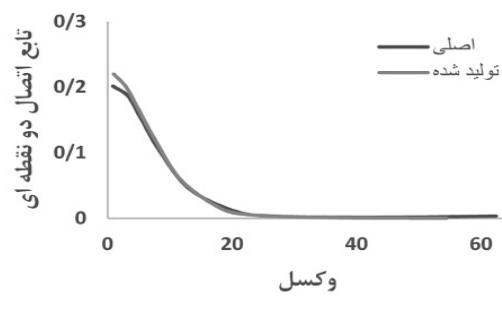
شکل ۷ نمودار توزیع میله‌ای درصد فراوانی بر حسب تخلخل



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



(ب)



(الف)

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 دارد.

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]. Tofiqhi F, Armani P, Chehrazi 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, Khamehchi 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, RahimiBahr 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]. Volkonskiy D, Muravleva E, Sudakov O, Orlov D, Belozerov 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]. Müter D, Sørensen H, Jha D, Harti R, Dalby K, Suhonen H, Feidenhans'l 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, Moravcová 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.

**Petroleum Research**

Petroleum Research, 2023(December-January), Vol. 32, No. 126, 21-23

DOI:10.22078/PR.2022.4843.3165

Pore-scale Reconstruction of Tight Reservoirs Using Generative Adversarial Networks

Ali Karimi and Saeid Sadeghnejad*

Department of Petroleum Engineering, Faculty of Chemical Engineering, Tarbiat Modares University, Tehran, Iran

sadeghnejad@modares.ac.ir

DOI:10.22078/PR.2022.4843.3165

Received: June/27/2022

Accepted: September/26/2022

Introduction

A significant amount of Iranian hydrocarbon resources is produced from fractured reservoirs with tight matrix rocks (Bangestan reservoirs in the southwest of Iran). On the other hand, the matrix pore structure of these reservoirs is so complex and heterogeneous, and it usually appears on different scales. Pores range from nanometers in tight matrices to millimetres in rocks with dissolution porosity (vugs). Understanding the porous media behaviour and predicting the properties of tight stones is one of the crucial challenges in the oil industries. In recent years, the tremendous advance in computer and imaging equipment has led to expanding porous space modelling or digital core analysis. With the help of this technology, it is possible to investigate the displacement processes in a reservoir at the pore scale for such tight rocks.

Feng et al. presented a method based on the cGAN neural network to overcome the lack of image data [1]. Feng et al. later developed their technique in constructing a 3-D network of 2-D images using the BicycleGAN neural network [2]. Volkhonskiy et al. developed a neural network that directly uses 2-D images to create 3-D images [3].

Despite their simple appearance, GANs hide many complexities in their depth. In this study, the efficiency of a DCGAN in reconstructing the pore space of a tight reservoir rock is investigated, which received less attention in the literature. It is challenging to predict the properties of such samples due to very low porosity and permeability with the help of direct methods of measuring rock properties (routine and special core analysis). Due to the size of the micro-pores of tight reservoir rocks (often in nano sizes), three-dimensional images obtained from a FIB-SEM device were used.

This imaging method has the ability to display pores in nanometer dimensions. To validate the obtained results, in addition to calculating the porosity and permeability of the reconstructed pore-scale images with that of the actual sample, the two-point probability function and the linear path function of the original sample were compared with the samples reconstructed from GAN.

Materials and Methods

GAN

For the first time, Goodfellow et al. introduced the adversarial generative neural network method or GAN. This model differs from other neural algorithms and uses two neural networks simultaneously. One neural network is called the discriminator, and the other is called the generator. These two networks operate simultaneously. The purpose of the generator is to produce output similar to the input data, and the purpose of the discriminator is to determine whether the input data is true or false. The competition between the two networks will improve both of them, and the overall output of the model will be close to the input data [4].

This study uses a DCGAN neural network consisting of convolutional neural layers. The generator uses six convolutional neural layers to create images. Each layer uses a ReLU activation function, and the last layer uses the tanh activation function. Batch normalization layers also were used periodically. The discriminator network uses five convolutional neural layers to distinguish fake from actual images.

At the end of each layer, a LeakyReLU is used as an activation function. Also, in the last layer, a sigmoid activation function is used to distinguish actual images

from generated images. In the discriminator, the batch normalization layer is used only in the previous layer.

Two-point Probability Function

To check the quality of the microstructures created by using a GAN with the condition of image stability, one of the methods used is the two-point probability function. Using this function, the second-order structure of a porous medium in the cavity phase (i.e., pores) can be determined [5].

Linear Path Function

Another method used to check the accuracy of the built microstructures is the linear path function. This function checks for pore connectivity by calculating the probability that a line, l_r , of length r is entirely in pore spaces [6].

Results and Discussion

Instead of solving problems with specific solutions, neural networks strive to connect input and output data using defined algorithms. As a result, input information plays an essential role in the accuracy of these methods. The raw image obtained from FIB-SEM is converted

into a binary file using ImageJ software to prepare the input data. By dividing the original image into smaller pieces, 3780 of 3D images with a size of $64 \times 64 \times 64$ voxels were ready for the training of the network. After examining the results obtained from GAN, it was determined that the best and most accurate results in this network were obtained in 100 epochs. In Figure 1, a 2-D cut of an image made with GAN was compared to a 2-D cut of an actual sample.

To compare the actual data and the generated networks, two of the most important petrophysical properties of rocks, porosity and permeability, have been compared for the reconstructed samples with the samples taken from the actual image of the rock. 200 images were randomly selected from each of the actual and generated data to compare the generated samples with the original sample. The permeability and porosity diagram of these samples is depicted in Figure 2.

The two-point probability function and the Lineal-path function also give us a good view of the accuracy of the generated models. In Figure 3, 50 image samples have been generated by GAN, and their average value is compared with the actual images of the tight rock.

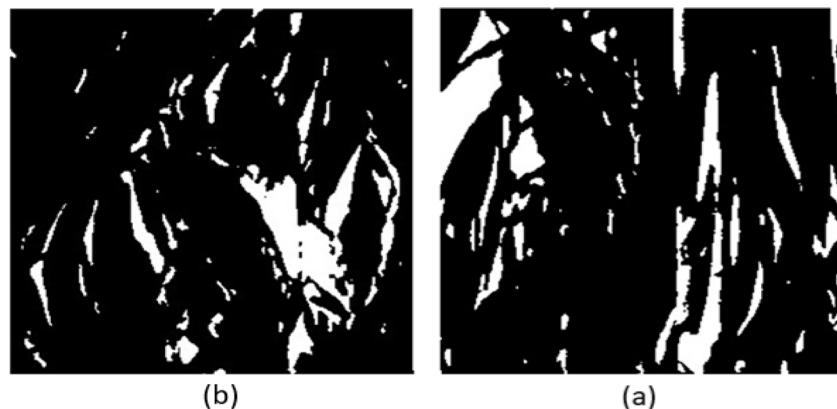


Fig. 1 2-D cut of microstructures a) Actual image was taken with FIB-SEM b) Image reconstructed by DCGAN.

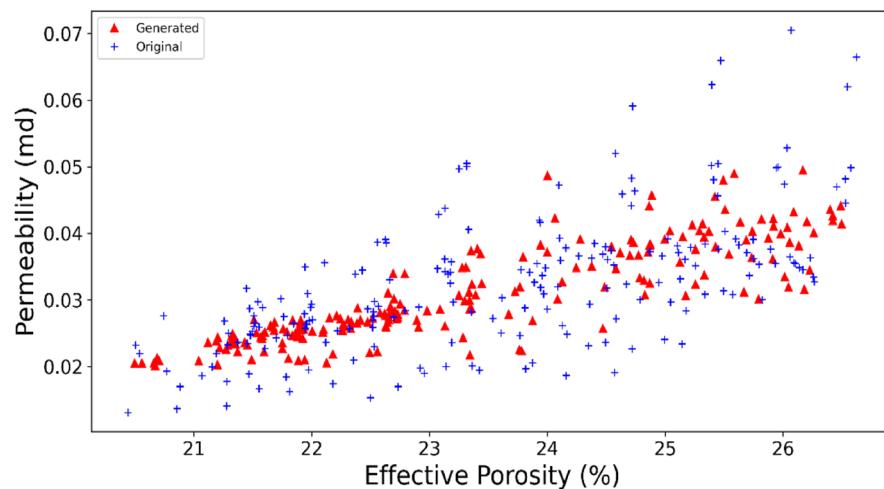


Fig. 2 Comparison of porosity and permeability deviated from actual rocks against samples reconstructed by GAN.

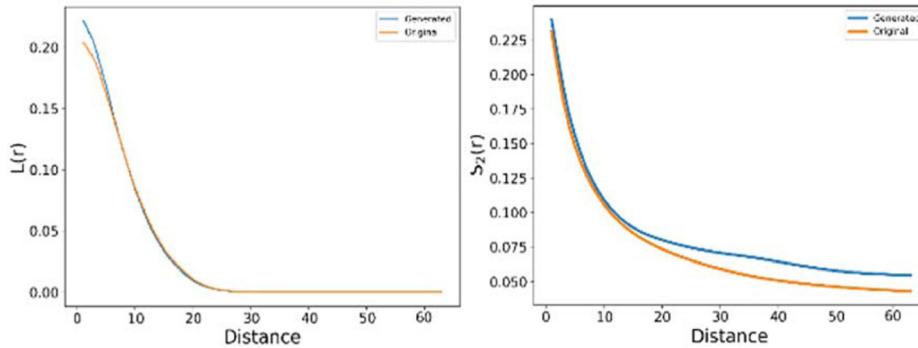


Fig. 3 Two-point probability function and lineal-path function of the rock sample versus the average of 50 samples generated by the DCGAN.

Conclusions

In this study, a DCGAN neural network is used to reconstruct a nano-scale porous medium of a tight reservoir rock sample. As shown in the results, the samples generated with the trained DCGAN had porosity and permeability consistent with the actual samples. Moreover, the two-point probability function and the lineal-path function confirm the accuracy of the generated pore-scale images. The total time needed to train this neural network was nearly one hour, much faster than other methods such as MPS. Moreover, new pore-scale images can be generated many times in a fraction of a second. It was shown that if properly configured, this GAN has the ability to generate networks matching the input data even if there is a limitation in the number of input data.

References

1. 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.
2. 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.
3. Volkhonkiy D, Muravleva E, Sudakov O, Orlov D, Belozerov B, Burnaev E, Koroteev D (2019) Reconstruction of 3d porous media from 2d slices. arXiv preprint arXiv: 1901.10233.
4. 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*, 27: 2672-2680.
5. Mosser L, Dubrule O, Blunt MJ (2017) Reconstruction of three-dimensional porous media using generative adversarial neural networks. *Physical Review E*. 96.4: 043309.
6. Zheng Q, Zhang D (2022) Digital rock reconstruction with user-defined properties using conditional generative adversarial networks. *Transport in Porous Media* 2022: 1-27.