

## تخمین تخلخل مخازن کربناته با استفاده از مدل شبکه عصبی عمیق ترکیبی براساس داده‌های چاه

امیررضا محرابی<sup>۱</sup>، مجید باقری<sup>۲\*</sup>، مجید نبی بیده‌ندی<sup>۳</sup>، ابراهیم بی نیاز دلجانی<sup>۴</sup> و محمد بهنود<sup>۴</sup>

<sup>۱</sup>دانشجوی دکتری، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، گروه مهندسی نفت، تهران، ایران

<sup>۲</sup>دانشیار، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

<sup>۳</sup>استاد، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

<sup>۴</sup>استادیار، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، گروه مهندسی نفت و شیمی، تهران، ایران

(دریافت: ۱۴۰۳/۰۳/۱۳، پذیرش: ۱۴۰۳/۰۶/۰۵)

### چکیده

تخمین تخلخل در مخازن کربناته به دلیل سیستم حفرات پیچیده و ناهمگنی مشکل و چالش برانگیز است. تخلخل بیانگر ظرفیت ذخیره سیال در مخزن است و به منظور برآورد میزان ذخایر و ظرفیت تولید حائز اهمیت است؛ لذا تخمین دقیق و صحیح تخلخل سنگ مخزن امری ضروری است. روش‌های متداول برای اندازه‌گیری تخلخل مانند آنالیز مغزه و نمودارهای چاه‌پیمایی اغلب گران و زمان‌بر هستند. روش‌ها و الگوریتم‌های یادگیری عمیق با استخراج الگوهای پیچیده از مجموعه داده‌های بزرگ و تجزیه و تحلیل داده‌های چاه می‌توانند تخمین دقیق‌تری را از تخلخل ارائه نمایند. در این مطالعه، یک رویکرد جدید با استفاده از یک مدل شبکه عصبی عمیق ترکیبی برای تخمین تخلخل براساس داده‌های چاه ارائه شده است. داده‌ها از یک مخزن کربناته در جنوب‌غربی ایران جمع‌آوری شدند و شامل داده‌های حاصل از آنالیز مغزه و نمودارهای چاه‌پیمایی (نمودار گاما، نوترون، چگالی، صوتی و مقاومت) می‌باشند. تعداد چاه‌ها ۲ حلقه و تعداد مغزه‌ها ۲۳۶ عدد است. مجموعه داده‌ها شامل ۲۰۰۰ نقطه داده‌ای می‌باشد که به سه بخش آموزشی، ارزیابی و اعتبارسنجی با نسبت‌های ۷۰٪، ۱۵٪ و ۱۵٪ در چاه اول تقسیم شدند و برای ارزیابی عملکرد مدل از چاه شماره دو استفاده شده است. رویکرد این مطالعه شامل جمع‌آوری و آماده‌سازی داده‌ها، طراحی معماری شبکه عصبی ترکیبی، آموزش، بهینه‌سازی و ارزیابی مدل است. برای اعتبارسنجی مدل ترکیبی شبکه عصبی عمیق ساخته شده، از داده‌های مغزه استفاده شده است. مقدار ضریب تعیین برای مدل شبکه عصبی عمیق ترکیبی با مقدار ۰/۹۸ نشان می‌دهد، این مدل دقت بسیار بالایی در پیش‌بینی تخلخل دارد. مقایسه تخلخل پیش‌بینی شده توسط مدل یادگیری عمیق ترکیبی نشان می‌دهد که عملکرد این مدل دقیق‌تر از مدل پرسپترون چند لایه بوده است.

کلمه‌های کلیدی: تخلخل، مخازن کربناته، یادگیری عمیق، مدل ترکیبی، داده چاه

## مقدمه

تخمین ویژگی‌های سنگ‌های مخازن کربناته به دلیل ماهیت پیچیده و ناهمگن آنها معمولاً چالش برانگیز است. ویژگی‌های پتروفیزیکی مخزن برای مشخصه‌سازی سنگ مخزن و تصمیم‌گیری‌های مهندسی اهمیت زیادی دارند (باقری و همکاران، ۲۰۲۰). تخلخل یک ویژگی مهم پتروفیزیکی است که برای بررسی پتانسیل ذخیره هیدروکربن در یک مخزن استفاده می‌شود (مازولو، ۲۰۰۴؛ بورچت، ۲۰۱۲). در مخازن کربناته، تخمین تخلخل به دلیل تاریخچه رسوبی پیچیده و فرآیندهای دیاژنتیکی که بر ساختار منافذ و ارتباط آنها با یکدیگر تأثیر می‌گذارد، می‌تواند چالش برانگیز باشد (آلن و همکاران، ۲۰۱۲). لذا تخمین دقیق تخلخل در مخازن کربناته نیازمند درک جامعی از سنگ‌شناسی، محیط رسوبی و تاریخچه دیاژنتیکی آن است. روش‌های متداول تخمین تخلخل از جمله آنالیز مغزه، آنالیز تصویر سنگ و تفسیر نمودارهای چاه‌پیمایی زمان‌بر هستند و هزینه زیادی دارند (تیاب، ۲۰۱۹؛ لای و همکاران، ۲۰۱۹). هدف از این تحقیق، توسعه یک روش نوین و کارآمد برای تخمین تخلخل در مخازن کربناته است که بتواند دقت بالایی داشته باشد و در عین حال زمان و هزینه‌های مربوط به ارزیابی مخزن را کاهش دهد (موسوی و همکاران، ۲۰۲۴). این مطالعه بر روی استفاده از تکنیک‌های یادگیری ماشین برای تخمین تخلخل متمرکز است، که با تحلیل داده‌های موجود و شناسایی الگوهای پیچیده در داده‌ها، می‌تواند تخمین‌های دقیقی را ارائه دهد. با استفاده از این روش، می‌توان بطور موثرتری ویژگی‌های مخازن کربناته را تحلیل و مدیریت نمود، که نهایتاً منجر به تصمیم‌گیری‌های بهتری در زمینه بهره‌برداری از منابع هیدروکربنی خواهد شد.

اگرچه داده‌های آنالیز مغزه اندازه‌گیری مستقیم تخلخل را فراهم می‌کنند، اما از نظر توزیع مکانی محدود هستند. از طرف دیگر، نمودارهای چاه‌پیمایی اندازه‌گیری خواص

سنگ را در امتداد عمق چاه ارائه می‌دهند و درک جامع‌تری از توزیع تخلخل مخزن را ارائه می‌دهند (استادمولر و جزینا، ۲۰۲۳). روابط تجربی، همبستگی بین تخلخل و سایر پارامترهای نمودارهای چاه‌پیمایی مانند چگالی، نوترون و نمودارهای صوتی را ایجاد می‌کنند (تیان و همکاران، ۲۰۲۲). این روابط اغلب از داده‌های مغزه بدست می‌آیند و سپس برای تخمین مقادیر تخلخل در کل مخزن در نمودارهای چاه‌پیمایی اعمال می‌شوند (بوست و همکاران، ۲۰۱۱).

روش‌های یادگیری ماشین و یادگیری عمیق در سال‌های اخیر به‌طور گسترده‌ای برای تخمین ویژگی‌های پتروفیزیکی از جمله تخلخل و تراوایی با استفاده از نمودارهای چاه‌پیمایی و داده‌های آنالیز مغزه به کار گرفته شده‌اند (ژو و همکاران، ۲۰۲۲؛ اوکون و آبا، ۲۰۲۱). روش‌های یادگیری ماشین، توانایی پردازش حجم زیادی از داده‌ها و کشف الگوهای پیچیده در داده‌ها را دارند (باقری و ریاحی، ۲۰۱۳). روش‌های مختلف یادگیری ماشین از جمله شبکه‌های عصبی، ماشین بردار پشتیبان و منطق فازی برای پیش‌بینی تخلخل استفاده شده‌اند (موسوی و همکاران، ۲۰۲۳). همچنین می‌توان از داده‌های لرزه‌نگاری برای مدل‌سازی بهتر رخساره‌ها و تخلخل توسط روش‌های یادگیری ماشین استفاده نمود (زارع و همکاران، ۲۰۲۰). همچنین استفاده از مدل‌های یادگیری عمیق برای تخمین تخلخل بر اساس داده‌های نمودارهای چاه‌پیمایی و آنالیز مغزه نیز مورد مطالعه قرار گرفته است که نتایج آن‌ها، دقت و عملکرد بهتری را در مقایسه با مدل‌های یادگیری ماشین معمولی اعمال شده بر روی داده‌های مشابه نشان داده است (تیان و همکاران، ۲۰۲۲؛ احمدی و چن، ۲۰۱۹). علاوه بر این، مطالعات دیگری از مدل‌های یادگیری عمیق با ساختارهای مختلف برای تخمین تخلخل در مخازن کربناته استفاده شده است که دقت آنها به داده‌های مورد

در این پژوهش برای تخمین تخلخل در مخازن کربناته از روش یادگیری عمیق ترکیبی استفاده شده است. شبکه های عصبی کانولوشن برای استخراج ویژگی های مکانی از داده ها مناسب هستند، در حالی که شبکه حافظه کوتاه مدت طولانی برای استخراج ویژگی های زمانی از داده ها مناسب هستند (محرابی و همکاران، ۲۰۲۴). این ویژگی های متمایز از این دو نوع شبکه مورد استفاده، باعث می شود که ترکیب مناسبی برای تخمین تخلخل در نظر گرفته شوند (کریستوفر و همکاران، ۲۰۲۳).

در شبکه عصبی کانولوشنی، شبکه با جابه جایی و اعمال فیلترهای کانولوشن با اندازه های مختلف بر روی داده های ورودی، ویژگی های مهم و قابل استخراج برای آموزش را در مدل استفاده می کند. شبکه های حافظه کوتاه مدت طولانی، مدلی از شبکه های عصبی بازگشتی هستند که بطور خاص برای پردازش داده های دنباله ای طراحی شده اند. در این نوع از شبکه های عصبی، یک واحد متشکل از چندین لایه مرتبط به هم تشکیل شده است که هر کدام دارای دروازه هایی هستند و می توانند عبور یا مسدود شدن اطلاعات را کنترل نمایند. دروازه ها شامل دروازه فراموشی، دروازه ورود و دروازه خروج هستند که هدف آنها کنترل جریان اطلاعات و حفظ اطلاعات مهم در طول زمان است. هر واحد از مدل شبکه عصبی معمولاً با یک ورودی و یک حالت اولیه آغاز می شود و با پردازش داده های ورودی، حالت های جدید تولید می کند. در هر مرحله از پردازش، حالت های قبلی، حافظه قبلی و سیگنال خروج قبلی به همراه ورودی جدید به واحد وارد می شوند و دروازه ها تعیین می کنند که کدام اطلاعات باید حفظ شوند و کدام اطلاعات باید فراموش شوند. سپس از اطلاعات حفظ شده در لایه های پیشین برای تولید خروجی استفاده می شود (آرون و یوشوآ، ۲۰۱۶).

همچنین برای مقایسه نتایج این مدل ترکیبی، از مدل شبکه عصبی پرسپترون چند لایه استفاده شده است. این

استفاده و فرضیات بکار رفته محدود می شود (وانگ و همکاران، ۲۰۲۲؛ ژو و همکاران، ۲۰۲۳).

مدل های ترکیبی شبکه عصبی عمیق، نسبت به روش های سنتی در برابر نویز و عدم قطعیت در داده های ورودی مقاوم تر هستند. همچنین می توانند الگوهای پیچیده تری را از داده ها کشف کنند، که آنها را برای تخمین تخلخل در مخازن کربناته ناهمگن مناسب می سازد (ژانگ و همکاران، ۲۰۱۹؛ وانگ و همکاران؛ ۲۰۲۲). اکثر نمودارهای چاه پیمایی فاقد تفکیک مناسب برای بدست آوردن خواص سنگ با جزئیات مورد نیاز در یک سازند ناهمگن هستند (موسوی و همکاران، ۲۰۲۲). بنابراین، ادغام داده های آنالیز مغزه با نمودارهای چاه پیمایی انجام می شود که این امر خود پرهزینه و زمان بر است. از طرفی استفاده از روش های یادگیری ماشین معمولی به دلیل عدم دقت لازم برای مخازن کربناته پیچیده و ناهمگن، نیاز به استفاده از روش های پیشرفته با دقت بیشتر را ضروری می نماید.

در این مطالعه با ترکیب الگوریتم های یادگیری عمیق، رویکرد جدیدی برای تخمین تخلخل با دقت بالا در مخازن کربناته ارائه شده است. این مدل شبکه عصبی عمیق ترکیبی شبکه های عصبی کانولوشن (CNN) و شبکه های حافظه کوتاه مدت طولانی (LSTM) با استفاده از داده های چاه برای تخمین تخلخل در مخازن کربناته توسعه داده شده است. از ترکیب این دو نوع شبکه عصبی در یک مدل یادگیری عمیق برای درک و تخمین روابط مکانی و زمانی پیچیده داده های مخزن کربناته استفاده شده است. داده های مورد استفاده شامل آنالیز مغزه و نمودارهای چاه پیمایی (نمودار گاما، نوترون، چگالی، صوتی و مقاومت و...) از یک مخزن کربناته در جنوب غربی ایران می باشد. همچنین نتایج این رویکرد پیشنهادی با یک مدل شبکه عصبی پرسپترون چند لایه (MLP) نیز مقایسه شده است.

## ۲ روش کار

زودهننگام و کاهش نرخ یادگیری برای جلوگیری از بیش‌برازش استفاده شده است.

#### ۴ ارزیابی مدل:

عملکرد مدل آموزش‌دیده با استفاده از مجموعه اعتبارسنجی (چاه دوم) ارزیابی شده است. معیارهای ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین ( $R^2$ ) برای اندازه‌گیری دقت پیش‌بینی تخلخل مدل استفاده شدند. این معیارها نشان‌دهنده کیفیت پیش‌بینی مدل و توانایی آن در تطابق با داده‌های واقعی هستند.

#### ۵ آزمایش مدل:

از مدل شبکه عصبی عمیق ترکیبی آموزش‌دیده برای تخمین تخلخل در چاه دوم که داده‌های تخلخل آن در دسترس نیست، استفاده شده است که برای این امر داده‌های چاه مربوطه به مدل آموزش‌دیده وارد شده و برای تخمین تخلخل به کار گرفته شدند. در این مرحله، عملکرد مدل در شرایط واقعی ارزیابی شده است تا اطمینان حاصل شود که مدل قادر به تعمیم دادن به داده‌های جدید و ناشناخته است.

### ۳ معماری ترکیب شبکه‌های عصبی عمیق

مدل شبکه عصبی عمیق ترکیبی بر اساس ترکیبی از لایه‌های کانولوشن و بازگشتی طراحی شده است. لایه‌های شبکه عصبی کانولوشن می‌توانند ویژگی‌های فضایی مربوطه را از داده‌های نمودارهای چاه پیمایی استخراج نمایند، در حالیکه لایه‌های شبکه عصبی بازگشتی می‌توانند وابستگی‌های زمانی را در توالی داده‌های چاه مدلسازی نمایند.

در شکل شماره ۱ معماری مدل یادگیری عمیق ترکیبی شامل لایه‌های ورودی، لایه‌های کانولوشن، لایه‌های بازگشتی (حافظه طولانی کوتاه مدت) و لایه رگرسیونی خروجی نمایش داده شده است.

مدل، بصورت لایه‌هایی از نورون‌ها ساخته شده است که هر لایه، به جز لایه ورودی، شامل چندین نورون است و همچنین هر نورون در لایه قبلی، به هر نورون در لایه فعلی برای انتقال اطلاعات و انجام محاسبات متصل می‌شود. علاوه بر این، هر نورون دارای وزن‌هایی است که در هنگام آموزش مدل بطور خودکار بهینه می‌شوند.

مراحل ساخت مدل شبکه عصبی عمیق ترکیبی عبارتند از:

#### ۱ جمع‌آوری داده‌ها و پیش‌پردازش داده‌ها:

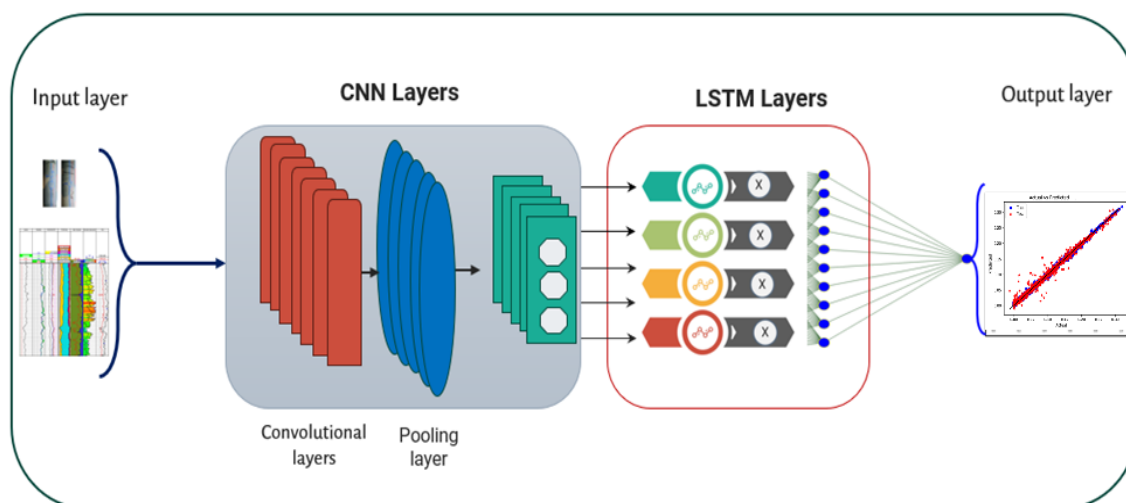
داده‌های جمع‌آوری شده از چاه شامل داده‌های حاصل از نمودارهای چاه‌پیمایی (نمودار گاما، نوترون، چگالی، صوتی و مقاومت) و داده‌های آنالیز مغزه است. پس از جمع‌آوری داده‌ها با حذف نقاط پرت و نرمال‌سازی برای متغیرهای ورودی، مورد پیش‌پردازش قرار گرفته‌اند.

#### ۲ طراحی معماری مدل شبکه عصبی عمیق:

طراحی معماری مدل شبکه عصبی عمیق ترکیبی، شامل ترکیب انواع مختلف لایه‌های شبکه عصبی مانند لایه‌های متراکم، لایه‌های کانولوشن، لایه‌های بازگشتی و لایه رگرسیونی برای مسئله تخمین تخلخل است. این مدل از لایه‌های کانولوشن (CNN) برای استخراج ویژگی‌های مکانی از داده‌های ورودی استفاده می‌کند و از لایه‌های بازگشتی (LSTM) برای مدل‌سازی روابط زمانی و دنباله‌ای در داده‌ها بهره می‌برد. ترکیب این دو نوع لایه به مدل اجازه می‌دهد تا روابط پیچیده مکانی و زمانی را به‌طور همزمان درک و تحلیل نماید.

#### ۳ آموزش مدل:

مجموعه داده به مجموعه‌های آموزشی، تست و اعتبارسنجی تقسیم شده‌اند. مدل شبکه عصبی عمیق ترکیبی با استفاده از مجموعه آموزشی (داده‌های چاه اول) آموزش داده شده‌اند تا وزن‌ها و بایاس‌های مدل از طریق فرآیند پس‌انتشار و الگوریتم بهینه‌سازی گرادیان نزولی تصادفی تنظیم گردند. در این مرحله، از تکنیک‌هایی مانند توقف



شکل ۱. شماتیک معماری مدل یادگیری عمیق ترکیبی در پژوهش.

- نرمال‌سازی داده‌ها: داده‌های ورودی باید نرمال‌سازی شوند تا مقیاس آنها به محدوده مشخصی (معمولاً بین ۰ و ۱) تغییر کند. این کار باعث شد که مدل بطور مؤثرتری آموزش ببیند و از مشکلات همگرایی جلوگیری شود.

- تغییر شکل داده‌ها: داده‌ها به فرمت مناسبی برای استفاده در لایه‌های کانولوشن (CNN) و حافظه کوتاه‌مدت طولانی (LSTM) تغییر شکل یافتند. برای این منظور، داده‌ها بصورت ماتریس‌های چندبعدی سازماندهی شدند تا بتوانند بطور صحیح در لایه‌های مختلف مدل مورد پردازش قرار گیرند.

#### ۵ طراحی معماری مدل شبکه عصبی عمیق

##### ۱-۵ طراحی معماری کانولوشن (CNN)

از لایه‌های کانولوشن برای استخراج ویژگی‌های فضایی از داده‌های ورودی استفاده شده است. این لایه‌ها شامل عملیات‌هایی مانند فیلترگذاری، نمونه‌برداری و جمع‌آوری هستند که به ترتیب، ویژگی‌های مهمی از داده‌ها را استخراج می‌نمایند.

- فیلترگذاری: در این مرحله، فیلترهای مختلفی بر روی داده‌های ورودی اعمال شدند تا ویژگی‌های مختلفی از جمله لبه‌ها، گوشه‌ها و الگوهای خاص شناسایی شوند.

در این مدل لایه‌های کانولوشنی برای استخراج ویژگی‌های مکانی و کشف رابطه پیچیده بین آنها استفاده شده از داده‌های ورودی استفاده شده است و به‌عنوان ورودی لایه حافظه کوتاه‌مدت طولانی بکار رفته است. مراحل پردازش داده‌ها در این مدل به شرح زیر می‌باشد:

#### ۴ جمع‌آوری داده‌ها و پیش‌پردازش داده‌ها

##### ۱-۴ جمع‌آوری داده‌ها

ابتدا، داده‌های چاه از منابع مختلفی مانند نمودارهای چاه‌پیمایی (نمودار گاما، نوترون، چگالی، صوتی و مقاومت) و داده‌های آنالیز مغزه جمع‌آوری شدند.

##### ۲-۴ پیش‌پردازش داده‌ها

داده‌های جمع‌آوری شده ابتدا برای استفاده در مدل‌های یادگیری ماشین و یادگیری عمیق آماده‌سازی شدند. این فرآیند شامل مراحل زیر است:

- حذف نقاط پرت: نقاط پرت می‌توانند تأثیر منفی بر دقت مدل داشته باشند. این نقاط با استفاده از روش‌های آماری و الگوریتم‌های خاص شناسایی و حذف شدند (خداقلی و همکاران، ۲۰۲۰؛ باقری و ریاحی، ۲۰۱۶).

مدل شبکه عصبی عمیق ترکیبی با استفاده از مجموعه آموزشی (چاه اول) آموزش داده شدند. این فرآیند شامل مراحل زیر است:

- پس‌انتشار: پس‌انتشار یک الگوریتم بهینه‌سازی است که وزن‌ها و بایاس‌های مدل را با استفاده از گرادینان خطا تنظیم می‌نماید. این کار با انتشار خطا از خروجی مدل به ورودی آن انجام می‌شود.

- نزول گرادینان: الگوریتم نزول گرادینان تصادفی (SGD) برای بهینه‌سازی مدل، مورد استفاده قرار گرفته است و این الگوریتم وزن‌ها و بایاس‌ها را به گونه‌ای تنظیم می‌نماید که خطا کاهش یابد.

### ۳-۶ تکنیک‌های بهینه‌سازی

برای جلوگیری از بیش‌برازش و بهبود عملکرد مدل، از تکنیک‌های متفاوتی استفاده شده است:

- توقف زودهنگام: آموزش مدل زمانی که عملکرد آن بر روی مجموعه اعتبارسنجی بهبود نمی‌یابد، متوقف می‌شود تا از بیش‌برازش جلوگیری شود.

- کاهش نرخ یادگیری: نرخ یادگیری به تدریج کاهش می‌یابد تا مدل بتواند بطور مؤثرتری به بهینه‌سازی قابل قبول برسد.

### ۷ ارزیابی مدل

#### ۱-۷ ارزیابی عملکرد

مدل آموزش‌دیده با استفاده از مجموعه اعتبارسنجی ارزیابی شده است تا دقت و عملکرد آن سنجیده شود. معیارهای مختلفی برای ارزیابی مدل مورد استفاده قرار گرفته است:

- ریشه میانگین مربعات خطا یا RMSE: ریشه میانگین مربعات خطا یک معیار متداول برای ارزیابی مدل‌های پیش‌بینی است که ریشه میانگین مربعات، تفاوت بین مقادیر پیش‌بینی‌شده و مقادیر واقعی را اندازه‌گیری می‌نماید.

- نمونه‌برداری: نمونه‌برداری معمولاً به کاهش ابعاد داده‌ها و افزایش کارایی مدل کمک می‌کند. این عمل با استفاده از تکنیک‌هایی مانند نمونه‌برداری ماکسیمم انجام شده است.

- جمع‌آوری: ویژگی‌های استخراج‌شده در لایه‌های کانولوشن جمع‌آوری و به لایه‌های بعدی منتقل شدند.

### ۲.۲ طراحی معماری حافظه کوتاه‌مدت طولانی (LSTM)

در ادامه خروجی لایه‌های کانولوشنی به لایه‌های LSTM وارد شدند تا روابط زمانی و دنباله‌ای بین داده‌ها پردازش شوند. لایه‌های LSTM قادر به مدل‌سازی داده‌های ترتیبی و دنباله‌ای هستند و می‌توانند اطلاعات گذشته را برای پیش‌بینی‌های بهتر در آینده حفظ نمایند.

- واحدهای حافظه LSTM: شامل واحدهای حافظه‌ای هستند که اطلاعات را برای دوره‌های طولانی حفظ می‌کنند و می‌توانند بر اساس ورودی‌های جدید بروزرسانی شوند.

- دروازه‌های ورودی، خروجی و فراموشی: این دروازه‌ها اطلاعاتی را که به حافظه افزوده یا از آن حذف شود و چگونگی استفاده از اطلاعات موجود در حافظه را کنترل می‌نمایند.

### ۶ آموزش مدل

#### ۱-۶ تقسیم مجموعه داده

مجموعه داده به دو چاه که داده‌های چاه اول به سه بخش آموزشی، ارزیابی و اعتبارسنجی با درصدهای به ترتیب ۷۰، ۱۵ و ۱۵ تقسیم شده است و این مجموعه داده به منظور آموزش مدل و تنظیم وزن‌ها و بایاس‌های آن مورد استفاده قرار گرفته است؛ در حالی که از داده‌های چاه دوم به منظور ارزیابی عملکرد مدل به کار رفته است.

### ۲-۶ آموزش مدل

## ۹ بهینه‌سازی نهایی و مستندسازی

### ۱-۹ بهینه‌سازی نهایی مدل

بر اساس نتایج ارزیابی، مدل ممکن است نیاز به بهینه‌سازی نهایی داشته باشد. این کار شامل تنظیم نهایی وزن‌ها و بایاس‌ها و اعمال تغییرات جزئی در معماری مدل است تا عملکرد آن به حداکثر برسد.

### ۲-۹ مستندسازی فرآیند

تمام مراحل جمع‌آوری، پیش‌پردازش، طراحی، آموزش، ارزیابی و آزمایش مدل مستند شده‌اند. این مستندسازی شامل شرح دقیق روش‌ها، الگوریتم‌ها و ابزارهای استفاده‌شده و همچنین نتایج حاصل از هر مرحله است.

با تکمیل این مراحل، مدل شبکه عصبی عمیق ترکیبی آماده شد تا به عنوان یک ابزار دقیق و کارآمد برای تخمین تخلخل در مخازن کربناته مورد استفاده قرار گیرد. این مدل می‌تواند به مهندسين نفت و زمین‌شناسان در بهبود فرآیندهای تصمیم‌گیری و بهره‌برداری از مخازن هیدروکربنی کمک نماید.

### ساختار مدل یادگیری عمیق

شبکه عصبی کانولوشن با استفاده از هسته کانولوشن، عملیات کانولوشن را بر روی داده های ورودی انجام می‌دهد و سپس استخراج ویژگی‌ها و پردازش آنها لایه به لایه از طریق تابع فعال سازی و لایه ادغام انجام می‌گردد. دنباله کانولوشن های یک بُعدی عملیات اصلی در شبکه های عصبی کانولوشن را می‌توان بصورت زیر توصیف نمود:

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} \text{Conv1D}(w_{ik}^{l-1}, s_i^{l-1})$$

که در آن  $x_k^l$  ورودی،  $b_k^l$  بایاس،  $s_i^{l-1}$  خروجی و  $w_{ik}^{l-1}$  کرنل نوروں لایه ها می باشد (کریستوفر و همکاران، ۲۰۲۳).

ضریب تعیین یا  $R^2$ : این ضریب نشان‌دهنده میزان ارتباط خطی بین دو متغیر مستقل و وابسته است. این نسبت تغییرات متغیر وابسته را که می‌توان به متغیر مستقل نسبت داد اندازه گیری می‌نماید. ضریب تعیین نشان می‌دهد که چند درصد تغییرات متغیرهای وابسته در یک مدل رگرسیونی با متغیر مستقل تبیین می‌شود. به عبارت دیگر، ضریب تشخیص نشان می‌دهد که چه میزان یا مقدار از تغییرات متغیر وابسته مساله تحت تاثیر متغیر مستقل مساله بوده است و همچنین تا چه حدی مابقی تغییرات متغیر وابسته مساله مربوط به سایر عوامل موجود در مساله است.

### ۲-۷ ارزیابی تعمیم‌پذیری

مدل همچنین باید توانایی تعمیم دادن به داده‌های جدید و ناشناخته را داشته باشد. این کار با استفاده از داده‌های اعتبارسنجی و آزمون انجام شدند تا اطمینان حاصل شود که مدل بر روی داده‌های جدید نیز عملکرد خوبی دارد.

## ۸ آزمایش مدل

### ۱-۸ تخمین تخلخل در ناحیه جدید

از مدل شبکه عصبی عمیق ترکیبی آموزش‌دیده برای تخمین تخلخل در چاه دوم به عنوان ناحیه جدید و ناشناخته که داده‌های تخلخل آن در دسترس نیست، استفاده شده است. بدین منظور داده‌های چاه مربوط به چاه دوم به مدل وارد شده است و برای تخمین تخلخل به کار گرفته شده‌اند.

### ۲-۸ ارزیابی عملکرد مدل در شرایط واقعی

در ادامه عملکرد مدل در شرایط واقعی مورد ارزیابی قرار گرفته است تا اطمینان حاصل شود که مدل قابلیت تعمیم یافتن به داده‌های جدید و ناشناخته را دارد. این ارزیابی شامل مقایسه نتایج پیش‌بینی‌شده با داده‌های واقعی در دسترس و تحلیل دقت و کارایی مدل در شرایط مختلف می‌باشد.

شبکه‌های حافظه کوتاه‌مدت طولانی (LSTM) به عنوان یکی از پیشرفته‌ترین انواع شبکه‌های عصبی بازگشتی (RNN) مورد استفاده قرار می‌گیرند و بطور خاص برای حفظ و استفاده از اطلاعات طولانی‌مدت در دنباله‌های داده طراحی شده‌اند. همچنین LSTM این قابلیت را از طریق استفاده از سه نوع دروازه خاص بدست می‌آورد: دروازه ورودی، دروازه خروجی و دروازه فراموشی. این دروازه‌ها به LSTM ها امکان می‌دهند تا مشکلات گرادیان‌های موجود در شبکه‌های عصبی بازگشتی معمولی را حل کنند و اطلاعات را در طول دنباله‌های طولانی بطور مؤثری پردازش کنند.

### ۱ دروازه ورودی (Input Gate)

دروازه ورودی کنترل کننده مقدار اطلاعات جدید وارد شده به واحد حافظه LSTM است. این دروازه بطور دینامیکی تصمیم می‌گیرد که چه بخش‌هایی از ورودی جاری و حافظه قبلی باید به حافظه جدید اضافه شوند. دروازه ورودی از طریق یک لایه سیگموئید عمل می‌نماید که مقدار آن بین ۰ و ۱ تغییر می‌کند، بطوری که ۰ نشان‌دهنده عدم ورود اطلاعات و ۱ نشان‌دهنده ورود کامل اطلاعات است.

### ۲ دروازه فراموشی (Forget Gate)

دروازه فراموشی تصمیم می‌گیرد که چه بخش‌هایی از اطلاعات حافظه قبلی باید حذف شوند. این دروازه نیز از یک لایه سیگموئید استفاده می‌نماید که مقدار آن بین ۰ و ۱ تغییر می‌کند. مقدار ۰ به این معناست که هیچ اطلاعاتی از حافظه قبلی حذف نمی‌شود، در حالی که مقدار ۱ به معنای حذف کامل اطلاعات حافظه قبلی است. این دروازه به LSTM ها کمک می‌کند تا اطلاعات نامربوط یا کمتر مهم را از حافظه حذف کنند و حافظه را بطور مؤثری مدیریت کنند.

### ۳ دروازه خروجی (Output Gate)

دروازه خروجی کنترل می‌کند که چه مقدار از اطلاعات حافظه جاری به خروجی LSTM منتقل شود. این دروازه نیز از یک لایه سیگموئید استفاده می‌کند و مقدار آن بین ۰ و ۱ تغییر می‌کند. مقدار ۰ به این معناست که هیچ اطلاعاتی به خروجی منتقل نمی‌شود، در حالی که مقدار ۱ به معنای انتقال کامل اطلاعات به خروجی است. دروازه خروجی به LSTM ها امکان می‌دهد تا تنها اطلاعات مهم و مرتبط را به مراحل بعدی پردازش منتقل کنند.

### عملکرد ترکیبی دروازه‌ها

عملکرد ترکیبی این دروازه‌ها این امکان را برای LSTM ها فراهم می‌نماید تا اطلاعات را در دنباله‌های طولانی بطور مؤثری مدیریت و پردازش کنند. هر یک از این دروازه‌ها بطور مستقل عمل کرده و به LSTM ها این امکان را می‌دهند که اطلاعات را بطور دقیق و مؤثر بروزرسانی یا حذف نموده و یا انتقال دهند. این امر به LSTM ها کمک می‌نماید تا مشکلات گرادیان‌های ناپایدار (vanishing gradients) و انفجار گرادیان‌ها (exploding gradients) را که در شبکه‌های عصبی بازگشتی معمولی وجود دارد، برطرف نمایند.

### مثال عملی:

فرض کنید که می‌خواهیم تخلص یک مخزن کربناته را با استفاده از داده‌های چاه‌پیمایی پیش‌بینی کنیم. در هر مرحله زمانی، ورودی شبکه شامل ویژگی‌های مختلفی از نمودارهای چاه‌پیمایی است. LSTM با استفاده از دروازه‌های خود، تصمیم می‌گیرد که کدام اطلاعات جدید وارد حافظه شود، کدام اطلاعات قدیمی حذف شود و کدام اطلاعات به خروجی منتقل شود.

- دروازه ورودی: ممکن است تصمیم بگیرد که اطلاعات جدید از نمودار گاما باید به حافظه اضافه شود.

بطور کلی مدل عصبی حافظه کوتاه مدت طولانی طی سه مرحله عمل می‌نماید:

در مرحله اول، کار شبکه با دروازه فراموشی آغاز می‌شود تا بررسی نماید چه نوع اطلاعاتی می‌بایست نادیده گرفته شود یا برای حالت سلول ذخیره گردد. محاسبه با در نظر گرفتن ورودی در مرحله زمانی فعلی ( $x_t$ ) و مقدار قبلی حالت پنهان ( $h_{t-1}$ ) با استفاده از تابع سیگموئید ( $S$ ) شروع می‌شود. فرمول محاسبه در دروازه فراموشی عبارت است از:

$$f_t = S(wf \cdot [h_{t-1}, x_t] + b_f)$$

در اینجا  $b$  بایاس و  $f_t$  تابع دروازه فراموشی است. در مرحله دوم، محاسبه شبکه با تبدیل حالت سلول قدیمی ( $C_{t-1}$ ) به یک حالت سلول جدید ( $C_t$ ) ادامه می‌یابد. این فرآیند انتخاب می‌نماید که کدام اطلاعات جدید باید در حافظه بلند مدت (حالت سلول) گنجانده شود. برای بدست آوردن مقدار حالت سلول جدید، فرآیند محاسبه باید مقدار مرجع از دروازه فراموشی، گیت ورودی و مقدار دروازه بروز رسانی سلول را در نظر بگیرد. این مراحل بصورت زیر فرمول بندی می‌شود:

$$C_t = (C_{t-1} \cdot f_t) + (i_t \cdot C'_t)$$

$$C'_t = T(wc \cdot [h_{t-1}, x_t] + b_c)$$

$$i_t = S(wi \cdot [h_{t-1}, x_t] + b_i)$$

هنگامیکه بروز رسانی حالت سلول کامل شد، مرحله نهایی تعیین مقدار حالت پنهان ( $h_t$ ) است. هدف از این فرآیند این است که حالت پنهان به عنوان حافظه شبکه عمل کند که حاوی اطلاعاتی در مورد داده های قبلی است و برای پیش بینی مورد استفاده قرار می‌گیرد. برای تعیین مقدار حالت پنهان، محاسبه باید دارای مقدار مرجع حالت سلول جدید و گیت خروجی ( $o_t$ ) باشد. این فرآیند بصورت زیر است:

$$o_t = S(wo \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \cdot T(C_t)$$

که در آن  $w$  وزن،  $o_t$  گیت خروجی و  $h_t$  متغیر حالت

پنهان می‌باشد.

• دروازه فراموشی: ممکن است تصمیم بگیرد که اطلاعات قدیمی مربوط به نمودار نوترون که دیگر مهم نیستند، حذف شوند.

• دروازه خروجی: ممکن است تصمیم بگیرد که اطلاعات ترکیبی از نمودارهای چگالی و مقاومت به خروجی منتقل شوند و برای پیش‌بینی تخلخل استفاده شوند.

به این ترتیب، LSTM با استفاده از دروازه‌های خود می‌تواند اطلاعات مربوطه را در طول زمان حفظ نموده و دقت پیش‌بینی خود را افزایش دهد. این ویژگی بویژه در مسائل پیچیده‌ای مانند تخمین تخلخل مخازن کربناته که شامل داده‌های متنوع و پیچیده‌ای است، بسیار مفید است.

### مزایای استفاده از LSTM

• حفظ اطلاعات طولانی مدت: LSTM ها قادر به حفظ اطلاعات مربوط به دنباله‌های طولانی هستند و می‌توانند روابط پیچیده زمانی بین داده‌ها را به خوبی مدل‌سازی نمایند.

• مقاومت در برابر مشکلات گرادیان: استفاده از دروازه‌های مختلف به LSTM ها کمک می‌نماید تا مشکلات گرادیان‌های ناپایدار و انفجار گرادیان‌ها را که معمولاً در RNN ها رخ می‌دهد، حل نمایند.

• دقت بالا در پیش‌بینی: LSTM ها با استفاده از مکانیزم دروازه‌ها می‌توانند اطلاعات مهم را از داده‌های ورودی استخراج و به خروجی منتقل نمایند که این امر دقت پیش‌بینی مدل را بطور قابل توجهی افزایش می‌دهد.

در نتیجه، استفاده از LSTM ها در مدل شبکه عصبی عمیق ترکیبی برای تخمین تخلخل در مخازن کربناته، بطور قابل توجهی می‌تواند دقت و کارایی مدل را افزایش دهد و به مهندسين نفت و زمین‌شناسان در تصمیم‌گیری‌های بهتر و بهینه‌تر کمک نماید.

تفسیر، تنها از دو چاه (که دارای داده‌های لاگ چاه و تحلیل مغزه هستند) استفاده شده است. داده‌های لاگ چاه شامل عمق (DEPTH)، اشعه گاما (GR)، تخلخل نوترونی (NPHI)، چگالی حجمی (RHOB)، زمان عبور صوت فشاری یا لاگ صوتی (DT)، قطر چاه (BS)، کالیپر یا اندازه‌گیری تغییرات قطر چاه (CALI)، چگالی حجمی تصحیح شده (DRHO)، مقاومت ویژه واقعی سازند (RT) و مقاومت ویژه عمیق (LLD) است که برخی از آنها در شکل ۲ نمایش داده شده‌اند. داده‌های مورد استفاده برای توسعه مدل‌ها و محدودده تخلخل در هر دو لاگ و مغزه در جدول ۱ خلاصه شده‌اند. تمام پارامترهای و سایر پارامترهای مجموعه داده‌ها که در جدول ۱ آمده است در توسعه مدل‌ها برای پیش‌بینی تخلخل استفاده شده‌اند. برخی از داده‌های آموزشی در مدل بارگذاری شده و لاگ‌های نمایش داده شده در نمودار بصورت شکل ۲ نشان داده شده‌اند. این شکل داده‌های لاگ چاه را پس از پیش‌پردازش نشان می‌دهد. داده‌های بدست آمده نشان‌دهنده افزایش یکپارچگی و کیفیت است که آنها را برای ورودی دقیق مدل مناسب می‌سازد. شکل ۲ داده‌های لاگ چاه را پس از مراحل پیش‌پردازش نشان می‌دهد و بر وضوح و یکنواختی بهبود یافته تأکید دارد که برای پیش‌بینی دقیق تخلخل در مخازن کربناته حیاتی است و همچنین پروفایل عمقی داده‌های مغزه هم نشان داده شده است.

در ادامه هیت می‌بی برای نشان دادن روابط رگرسیونی و ارتباط بین ورودی و خروجی رسم شده است و به شرح زیر در شکل ۳ به نمایش در آمده است.

روش ترکیب یک شبکه عصبی کانولوشن و یک شبکه حافظه کوتاه مدت شامل استفاده از خروجی شبکه عصبی کانولوشن به عنوان ورودی شبکه حافظه کوتاه مدت می‌باشد. این روش به شبکه حافظه کوتاه مدت اجازه می‌دهد تا ویژگی‌های استخراج شده از داده‌های ورودی توسط شبکه عصبی کانولوشن را فرا گیرد.


برای اندازه‌گیری مدل یادگیری عمیق از معیار ارزیابی ریشه میانگین مربعات خطا (RMSE) استفاده شده است که بصورت زیر تعریف می‌شود:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2}$$

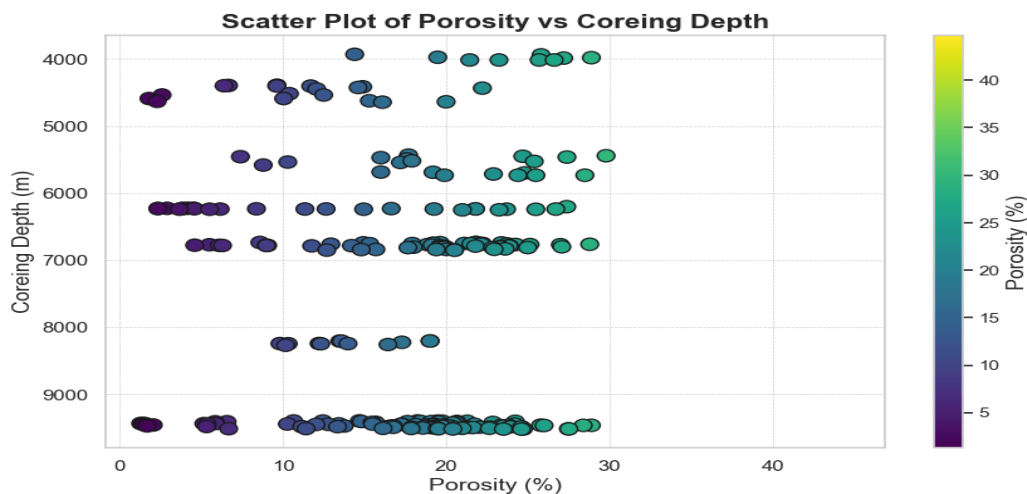
این معیار تفاوت بین مقادیر پیش‌بینی شده و واقعی را با گرفتن جذر میانگین اختلاف مجذور محاسبه می‌نماید. به عبارت دیگر، میزان فاصله مقادیر پیش‌بینی شده از مقادیر واقعی را اندازه می‌گیرد. مقدار پایین‌تر این معیار نشان‌دهنده عملکرد بهتر مدل است. مدل یادگیری عمیق ترکیبی با استفاده از کتابخانه TensorFlow در پایتون برنامه نویسی و پیاده‌سازی شده است.

### داده‌های مورد استفاده

داده‌های ورودی خام از یک مخزن کربناته در جنوب ایران بدست آمده‌اند. این میدان در سال ۱۹۷۱ کشف و شامل دو سازند اصلی نفتی کربناته است. سازند مخزنی این میدان بسیار پیچیده است و ترکیبات سنگی آن شامل دولومیت، سنگ آهک، شیل، انیدریت، نمک و ماسه می‌باشد. شش چاه در این میدان حفر شده است و همه چاه‌ها مورد ارزیابی قرار گرفته‌اند، اما به دلیل کمبود نتایج ارزیابی یا ضعف در



الف)




ب)

شکل ۲. پروفایل عمقی داده های لاگ (الف) و مغزه (ب).

جدول ۱. محدوده های آماری و پارامترهای داده های لاگ و مغزه به کار گرفته شده برای مدل های در حال توسعه.

شماره	پارامتر (واحد)	تعداد	میانگین	انحراف معیار	کمترین	۲۵٪	۵۰٪	۷۵٪	بیشترین
۱	DEPTH	۱۰۸۷۲	۲۸۰۹/۴	۴۷۸/۳۲	۱۹۸۱	۲۳۹۵/۲	۲۸۰۹/۴	۳۲۲۳/۶	۳۶۳۷/۷
۲	GR (API units)	۱۰۸۷۲	۲۳/۳۹۶	۱۲/۳۸۱	۲/۲۸۱۲	۱۳/۸۲۱	۲۲/۶۷۳	۳۱/۰۵۶	۱۰۱/۹۶
۳	NPHI (%)	۱۰۸۷۲	۰/۱۲۴۷	۰/۱۳۹۱	-۰/۰۵۷	-۰/۰۳۱	۰/۱۴۶۶	۰/۲۵۸	۰/۴۴۹
۴	RHOB (g/cm <sup>3</sup> )	۱۰۸۷۲	۲/۵۳۰۵	۰/۲۸۵۹	۱/۶۰۳	۲/۳۰۴۳	۲/۴۹۳۸	۲/۸۰۸۴	۳/۱۵۸
۵	DT (μs/ft)	۱۰۸۷۲	۷۵/۷۶۱	۱۷/۱۸۸	۳۹/۷۱۷	۶۳/۹۵	۷۲/۸۵۵	۸۶/۵۹۵	۱۴۵/۴۵
۶	BS	۱۰۸۷۲	۹/۱۳۱	۲/۸۴۶۹	۶	۶/۱۲۵	۸/۳۷۵	۱۲	۱۲

۷	CALI	۱۰۸۷۲	۱۱/۱۶۹	۵/۲۲۷	۵/۴۸۰۲	۶/۴۶۳۳	۸/۵۴۵۸	۱۵/۴۱۸	۲۰/۴۵۱
۸	DRHO	۱۰۸۷۲	۰/۱۲۸۲	۰/۰۹۹۸	-۰/۴۶۱	۰/۰۸۶۳	۰/۱۲۶۴	۰/۱۵۹۹	۰/۹۵۷۷
۹	RT	۱۰۸۷۲	۹۲/۰۳	۴۹۶/۷۲	۰/۲	۱/۰۱۶	۲/۲۴۵	۳۳/۷۹۸	۱۲۱۸۰
۱۰	LLD ( $\Omega \cdot m$ )	۱۰۸۷۲	۹۱/۸۹	۴۹۷/۰۰۳	۰/۰۰۹	۱/۰۲۱	۲/۲۴۷	۳۳/۸۲	۲۰۰۰
۱۱	PHIE	۱۰۸۷۲	۰/۰۸۶۹	۰/۰۸۰۶	۰	۰	۰/۰۶۹۷	۰/۱۵۲۲	۰/۳۷۱۳
۱۲	Porosity %	۲۳۶	۱۵/۸۶۲	۷/۸۳۲۴	۱/۲۹	۱۰/۲۲۵	۱۶/۵	۲۱/۶۸۵	۴۴/۶۹



شکل ۳. هیت مپ روابط رگرسیونی بین ورودی‌ها و خروجی مدل برای پیش‌بینی تخلخل در مخازن کربناته. این شکل بطور دقیق ارتباط بین متغیرهای ورودی شامل GR، NPHI، RHOB، DT، و LLD با تخلخل (PHIE) را نشان می‌دهد. رنگ‌بندی هیت مپ شدت روابط رگرسیونی را بر اساس مقدار همبستگی بین متغیرها نمایش می‌دهد، بطوری که مقادیر بالاتر نشان‌دهنده همبستگی قوی‌تر است. این روابط مبنای تحلیل انتخاب ورودی‌ها به مدل شبکه عصبی عمیق قرار گرفتند.

تخلخل مغزه به عنوان ورودی‌های مدل شبکه عصبی در نظر گرفته شده‌اند. این پارامترها بر اساس مطالعات پیشین و اهمیت آنها در فرآیند پیش‌بینی تخلخل مخازن کربناته انتخاب شده‌اند.

#### دلایل استفاده از پارامترها

در این مطالعه، تمامی پارامترهای ورودی نمایش داده شده در هیت مپ شامل عمق (DEPTH)، اشعه گاما (GR)، تخلخل نوترونی (NPHI)، چگالی حجمی (RHOB)، زمان عبور صوت فشاری یا لاگ صوتی (DT)، قطر چاه (BS)، کالیپر یا اندازه‌گیری تغییرات قطر چاه (CALI)، چگالی حجمی تصحیح شده (DRHO)، مقاومت ویژه واقعی سازند (RT) و مقاومت ویژه عمیق (LLD)، به همراه مقادیر

مخزن کمک می‌نماید و به عنوان یک پارامتر کلیدی در شبکه در نظر گرفته شده است. تخلخل با میزان فضای خالی در سنگ‌ها مرتبط است و مقاومت ویژه واقعی که به هدایت الکتریکی سنگ‌ها بستگی دارد، می‌تواند به طور غیرمستقیم به تغییرات در تخلخل مرتبط باشد، زیرا فضاهای متخلخل بیشتر معمولاً حاوی سیالاتی هستند که هدایت الکتریکی را تحت تأثیر قرار می‌دهند.

• LLD (مقاومت ویژه عمیق): لاگ مقاومت ویژه عمیق، برای اندازه‌گیری مقاومت ویژه سنگ‌های مخزن در فاصله دورتری از دیواره چاه استفاده می‌شود و می‌تواند به شناسایی مناطق دارای تخلخل و سیالات هیدروکربنی کمک کند، بنابراین در مدل گنجانده شده است.

همه این پارامترها در تحلیل‌های رگرسیونی و بر اساس همبستگی آنها با تخلخل مؤثر انتخاب شده‌اند و در نهایت، تمامی این پارامترها به دلیل نقش مهمی که در دقت پیش‌بینی داشتند، به عنوان ورودی مدل شبکه عصبی استفاده شدند. هیچ کدام از پارامترها حذف نشده‌اند، چرا که هر یک به نوعی در بهبود عملکرد و دقت مدل نقش داشتند.

همچنین نمودار جفتی بصورت تصویری پراکندگی داده‌ها بین هر دو متغیر را نمایش می‌دهد که در شکل ۴ نمایش داده شده است. تعداد کل نقاط داده از تعداد داده‌های اصلی مغزه (۲۳۶) بیشتر است زیرا شامل نقاط داده میان‌یابی شده نیز می‌باشد که برای تقویت مجموعه داده‌های مختلف مورد نیاز مدل و بهبود دقت پیش‌بینی مورد استفاده قرار گرفته‌اند.

شکل ۴ شامل نمودار جفتی (Pair Plot) از داده‌های ورودی و خروجی مدل شبکه عصبی عمیق ترکیبی است. این نمودار پراکندگی داده‌ها را بین هر دو متغیر بصورت تصویری نشان می‌دهد و به تحلیل روابط بین ورودی‌ها و خروجی کمک می‌نماید. در این شکل، تمامی داده‌های

• DEPTH (عمق): پارامتر عمق یکی از مهم‌ترین مواردی است که بطور غیرمستقیم نشان‌دهنده تغییرات ژئوفیزیکی و زمین‌شناسی لایه‌های مخزن است. این پارامتر به دلیل تأثیر مستقیم بر سایر لاگ‌ها به عنوان ورودی مدل استفاده شده است.

• GR (اشعه گاما): لاگ گاما، نشان‌دهنده سطح تابش گامای طبیعی سنگ‌ها است که برای تشخیص نوع سنگ و طبقه‌بندی آن‌ها از نظر تخلخل و تراوایی اهمیت دارد. این پارامتر به طور مستقیم به پیش‌بینی تخلخل کمک می‌کند.

• NPHI (تخلخل نوترونی): لاگ تخلخل نوترونی برای تخمین مستقیم تخلخل مخزن به کار می‌رود و یکی از اصلی‌ترین ورودی‌های مدل است.

• RHOB (چگالی حجمی): چگالی نیز برای تخمین تخلخل از اهمیت ویژه‌ای برخوردار است، زیرا این پارامتر با تخلخل و نوع سنگ‌های مخزن ارتباط نزدیکی دارد.

• DT (لاگ صوتی): لاگ زمان عبور صوتی، سرعت امواج صوتی را در سنگ‌ها اندازه‌گیری می‌کند و بطور غیرمستقیم به تخمین تخلخل و تراکم سنگ‌های مخزن کمک می‌کند، به همین دلیل به عنوان ورودی مدل استفاده شده است.

• BS (قطر چاه): این پارامتر نشان‌دهنده مشخصات فیزیکی حفاری است و می‌تواند بر دقت اندازه‌گیری لاگ‌ها تأثیر بگذارد؛ بنابراین در مدل گنجانده شده است.

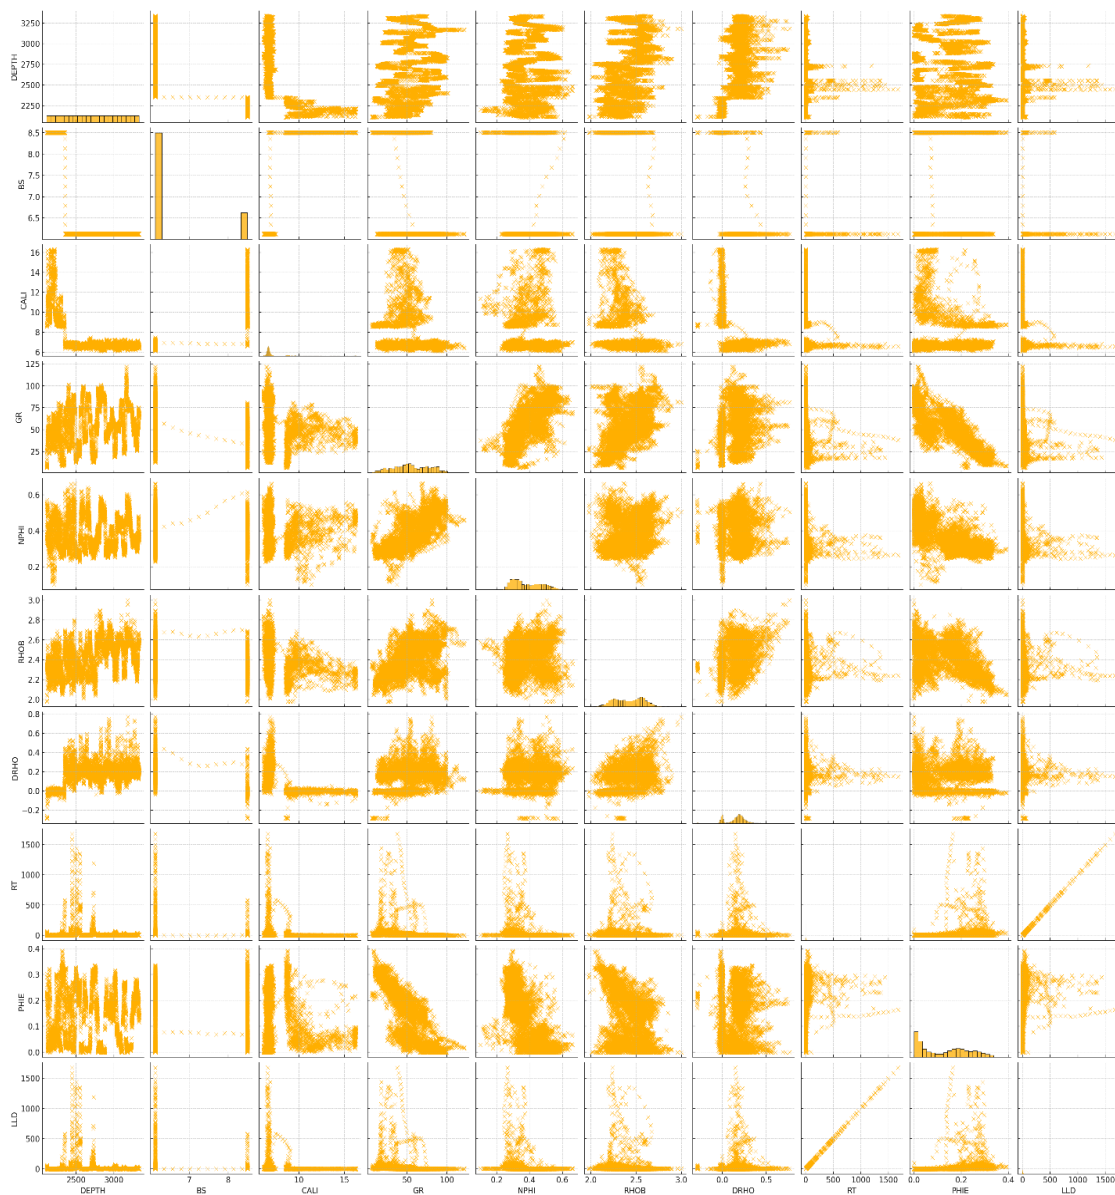
• CALI (کالیپر): اندازه‌گیری تغییرات قطر چاه به شناسایی مناطق شسته شده یا غیرنرمال در طول حفاری کمک می‌نماید. این پارامتر بطور غیرمستقیم بر تخلخل تأثیرگذار است و در مدل لحاظ شده است.

• DRHO (چگالی حجمی تصحیح شده): تفاوت چگالی می‌تواند نشانه‌ای از تغییرات در سیال‌های موجود در مخزن باشد و به همین دلیل در مدل لحاظ شده است.

• RT (مقاومت ویژه واقعی): مقاومت ویژه واقعی به شناسایی سیالات موجود در مخزن و ارزیابی قابلیت تولید

و Core Porosity بکار رفته و به شناسایی ارتباطات غیرخطی احتمالی بین آنها کمک می‌کند. علاوه بر این، نمودارهای جفتی برای تشخیص ناهنجاری‌ها و الگوهای پراکندگی مفید هستند و می‌تواند اطلاعات مهمی در مورد رفتار مخزن ارائه دهند.

اصلی و داده‌های میان‌یابی شده که به عنوان ورودی‌های مدل استفاده شده‌اند، به نمایش درآمده‌اند. این نمودار بخصوص برای نمایش همبستگی‌های بالقوه بین متغیرهای ورودی مانند GR، DEPTH، NPHI، PHIE، LLD، RT، DRHO، CALI، BS، DT، RHOB



شکل ۴. نمودار جفتی داده‌های مورد استفاده در مدل شبکه عصبی عمیق ترکیبی.

تصویری نشان می‌دهد و به تحلیل روابط بین ورودی‌ها و خروجی کمک می‌نماید. در این شکل، تمامی داده‌های

شکل ۴ شامل نمودار جفتی (Pair Plot) از داده‌های ورودی و خروجی مدل شبکه عصبی عمیق ترکیبی است. این نمودار پراکندگی داده‌ها را بین هر دو متغیر بصورت

- بررسی موارد پرت: موارد پرت شناسایی شده تحت یک ارزیابی جامع قرار گرفتند. در مواردی که موارد پرت به خطاهای ورودی داده یا ناهنجاری های آشکار نسبت داده می شدند، با دقت از مجموعه داده حذف شدند.
- بازبینی یکپارچگی داده ها: موارد پرت احتمالی به دقت بررسی شدند و بویژه به مواردی که ممکن است نشان دهنده تغییرات واقعی داده باشند، توجه ویژه ای شد. این مرحله برای اطمینان از حفظ مشاهدات اصیل که ممکن است سناریوهای نادر اما معتبر را نشان دهند، حیاتی بود.
- ارزیابی زمینه ای: با کارشناسان موضوعی با دانش مرتبط، برای انجام ارزیابی زمینه ای هر مورد پرت مشورت شد. این مرحله برای اطمینان از این که هیچ نقطه داده مهمی به اشتباه از فرآیند تحلیل حذف نشود، ضروری بود و تمامیت و جامعیت مجموعه داده را حفظ نمود.

### نتایج و بحث

در این بخش نتایج بدست آمده برای مدل یادگیری عمیق ترکیبی شبکه های عصبی کانولوشن و شبکه های حافظه کوتاه مدت طولانی در مقایسه با شبکه عصبی پرسپترون چند لایه ارائه شده است. لازم به ذکر است برای هر دو مدل از داده های ورودی یکسان استفاده شده است.

ابتدا نتایج بدست آمده برای پیش بینی تخلخل توسط مدل شبکه عصبی پرسپترون چند لایه با داده های ورودی یکسان بررسی شد. تابع ضرر فرآیند آموزش و اعتبارسنجی برای مدل شبکه عصبی پرسپترون چند لایه در شکل شماره ۵ نشان داده شده است.


اصلی و داده های میان یابی شده که به عنوان ورودی های مدل استفاده شده اند، به نمایش درآمده اند.

این نمودار بخصوص برای نمایش همبستگی های بالقوه بین متغیرهای ورودی مانند DEPTH، GR، NPFI، PHIE، LLD، RT، DRHO، CALI، BS، DT، RHOB و Core Porosity بکار رفته و به شناسایی ارتباطات غیرخطی احتمالی بین آنها کمک می کند. علاوه بر این، نمودارهای جفتی برای تشخیص ناهنجاری ها و الگوهای پراکندگی مفید هستند و می تواند اطلاعات مهمی در مورد رفتار مخزن ارائه دهند.

از آنجایی که این داده ها شامل نقاط داده میان یابی شده چاه نیز هستند، تعداد کل نقاط بیشتر از داده های اصلی است و این موضوع به بهبود دقت پیش بینی مدل کمک نموده است.

داده های طی یک فرآیند دقیق برای شناسایی و رفع موارد پرت بررسی شدند که شامل مراحل زیر بود:

- شناسایی موارد پرت: تکنیک تجزیه و تحلیل آماری سختگیرانه ای برای شناسایی موارد پرت احتمالی در مجموعه داده به کار گرفته شد. روش دامنه بین چارکی (IQR) که به دلیل استحکام و رویکرد محافظه کارانه اش در حفظ داده ها شناخته شده است، بکار رفت. برای هر ویژگی کمی، IQR محاسبه شد. مشاهداتی که کمتر از چارک اول منهای ۱/۵ برابر IQR یا بیشتر از چارک سوم به علاوه ۱/۵ برابر IQR بودند، به عنوان موارد پرت احتمالی علامت گذاری شدند.





شکل ۵. نمودار تابع ضرر برای مدل شبکه عصبی پرسپترون چند لایه.

را نشان می‌دهد بدست آمده است. برای مدل ساخته شده و آموزش دیده شده بر اساس داده های موجود، نمودار رگرسیون برای مدل شبکه عصبی پرسپترون چند لایه در شکل ۶ نمایش داده شده است و به دو صورت الف و ب برای چاه اول و دوم است که چاه اول برای ساخت مدل استفاده شده است و داده های چاه دوم برای ارزیابی کارایی مدل به عنوان چاه دیده نشده استفاده شده است.

برای این مدل در نمودار تابع ضرر، مشاهده می‌شود که در ابتدا تابع ضرر کاهش می‌یابد ولی سپس به تقاطعی می‌رسد و دیگر بطور قابل توجهی کاهش نمی‌یابد. این امر نشان دهنده این است که مدل شبکه عصبی پرسپترون چند لایه بهبود کمتری در دقت پیش بینی حاصل می‌نماید و ممکن است به یک حالت اشباع برسد. برای بررسی خروجی مدل، منحنی رگرسیون که رابطه بین متغیرهای ورودی و متغیر هدف پیش بینی شده (تخلخل)

الف


ب



شکل ۶. نمودار رگرسیون برای مدل شبکه عصبی پرسپترون چند لایه.

مدل شبکه عصبی پرسپترون چند لایه آموزش دیده شده، برای تخمین تخلخل استفاده شده است. در شکل شماره ۷ نتایج تخمین تخلخل توسط این مدل نشان داده شده است که به دو صورت الف و ب برای چاه اول و دوم است که چاه اول برای ساخت مدل استفاده شده است و داده های چاه ۲ برای ارزیابی کارایی مدل به عنوان چاه دیده نشده استفاده شده است.


در نمودار رگرسیون، ضریب تعیین برای مدل شبکه عصبی پرسپترون چند لایه با مقدار ۰/۹۲ نشان دهنده تطابق متوسط بین پیش بینی های مدل و داده های واقعی است. این نمودار نشان می دهد که مدل شبکه عصبی پرسپترون چند لایه دارای دقت نسبتاً قابل قبولی در پیش بینی تخلخل است، اما نسبت به مدل یادگیری عمیق ترکیبی، دقت کمتری دارد که در ادامه ارائه شده است.



شکل ۷. پیش بینی تخلخل برای مدل شبکه عصبی پرسپترون چند لایه.

برای فرآیند آموزش و اعتبارسنجی مدل یادگیری عمیق ترکیبی در شکل شماره ۸ نشان داده شده است.


در ادامه نتایج بدست آمده برای مدل یادگیری عمیق شبکه های عصبی کانولوشن و شبکه های حافظه کوتاه مدت طولانی برای داده های یکسان ارائه شده است. تابع ضرر،




شکل ۸. نمودار تابع ضرر مدل یادگیری عمیق ترکیبی CNN-LSTM.

کارایی مدل به عنوان چاه دیده نشده استفاده شده است. نمودار تحلیل رگرسیون مقادیر تخلخل پیش‌بینی شده از مدل را با مقادیر تخلخل واقعی مقایسه می‌کند. همانطور که مشاهده می‌شود نقاط داده در امتداد یک خط مورب هم‌تراز هستند که بیانگر اینست که این مدل به خوبی برازش یک همبستگی مثبت قوی بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد.

الف



ب



شکل ۹. نمودار رگرسیون مدل یادگیری عمیق ترکیبی CNN-LSTM.

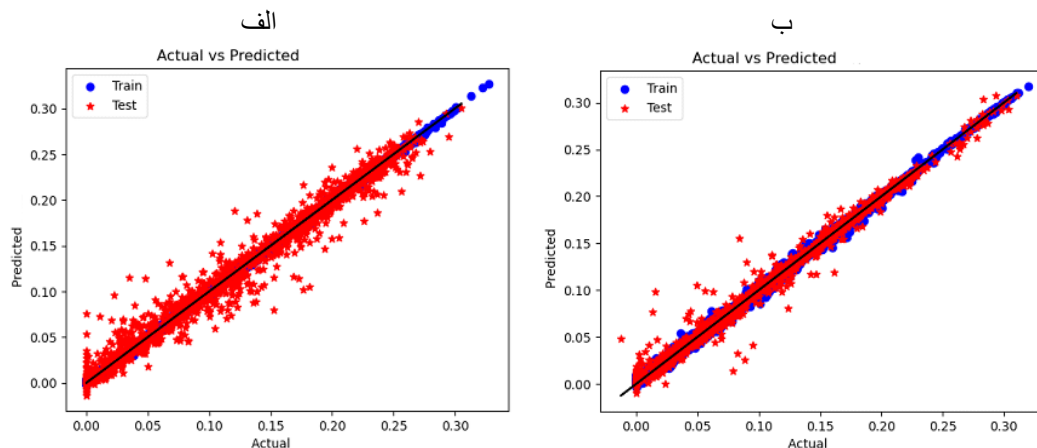
عصبی پرسپترون چند لایه، دقت و کارایی بیشتری دارد. ضریب تعیین نشان می‌دهد که چه میزان از تغییرات داده‌ها می‌تواند توسط مدل پیش‌بینی شود. به عبارت بهتر، ضریب تعیین نشان می‌دهد که مدل برای پیش‌بینی داده‌ها چقدر مناسب است. یک ضریب تعیین نزدیک به یک نشان دهنده دقت و کارایی بالای مدل است. با توجه به این که ضریب تعیین برای مدل یادگیری عمیق ترکیبی بالاتر از ضریب تعیین مدل شبکه عصبی پرسپترون چند لایه است، می‌توان نتیجه گرفت که مدل یادگیری عمیق ترکیبی برای پیش‌بینی داده‌های ورودی مناسب‌تر است.

در نمودار تابع ضرر برای فرآیند آموزش و اعتبارسنجی مدل، تابع ضرر بطور مداوم کاهش می‌یابد و نشان می‌دهد که مدل بهبود پیدا می‌کند و به دقت بالاتری دست می‌یابد. در شکل ۹ نمودار رگرسیون برای مدل یادگیری عمیق شبکه‌های عصبی کانولوشن و شبکه‌های حافظه‌ی کوتاه‌مدت طولانی ارائه شده است که به دو صورت الف و ب برای چاه اول و دوم است که چاه اول برای ساخت مدل استفاده شده است و داده‌های چاه ۲ برای ارزیابی

در نمودار رگرسیون، برای مدل یادگیری عمیق ترکیبی، ضریب تعیین با مقدار  $0/98$  نشان دهنده تطابق بسیار خوب بین پیش‌بینی‌های مدل و داده‌های واقعی است. این نمودار نشان می‌دهد که مدل یادگیری عمیق ترکیبی قادر به تخمین دقیق تخلخل است و دارای دقت بسیار بالایی در پیش‌بینی تخلخل است.

در نمودار رگرسیون، ضریب تعیین برای مدل شبکه عصبی پرسپترون چند لایه  $0/92$  و ضریب تعیین برای مدل یادگیری عمیق ترکیبی  $0/98$  شده است. با توجه به ضریب تعیین قابل مشاهده در نمودار رگرسیون، می‌توان نتیجه گرفت که مدل یادگیری عمیق ترکیبی نسبت به مدل شبکه

در شکل شماره ۱۰ تخمین تخلخل با استفاده از مدل یادگیری عمیق ترکیبی شبکه های عصبی کانولوشن و حافظه کوتاه مدت طولانی نشان داده شده است.



شکل ۱۰. پیش بینی تخلخل برای مدل یادگیری عمیق ترکیبی CNN-LSTM.

از آنها، مانند ترکیب بسیار مرسوم مدل های U-Net و Autoencoder، عملکرد بهتری نسبت به هر مدل شبکه عصبی ساده تری با هر عمقی و هر روش بهینه سازی داشته باشند.

۱. مدل CNN (Convolutional Neural Network) (Transformer) ها به دلیل قابلیت های پیشرفته در استخراج ویژگی های فضایی و زمانی از داده های پیچیده، می توانند در تخمین تخلخل مخازن کربناته بسیار مؤثر باشند. این مدل ها ترکیبی از قابلیت های CNN و Transformer ها هستند که بطور هم زمان ویژگی های محلی و زمانی داده ها را استخراج می نمایند.

۲. مدل U-Net که بطور گسترده در پردازش تصاویر پزشکی استفاده می شود، قابلیت های بسیار مناسبی برای مدل سازی داده های زمین شناسی و چاه پیمایی دارد. ساختار U-Net به گونه ای است که می تواند جزئیات مهم داده ها را حفظ نموده و دقت پیش بینی را افزایش دهد.

۳. مدل Res-Net (Residual Network)

در شکل شماره ۱۰ منحنی رگرسیون مقادیر برازش شده را با مقادیر تخلخل واقعی مشاهده شده نشان می دهد که دقت بسیار بهتری نسبت به مدل شبکه عصبی پرسپترون چند لایه دارد.

در مطالعه ما، برای پیش بینی تخلخل مخازن کربناته از دو مدل شبکه عصبی استفاده شد. مدل اول، شبکه عصبی پرسپترون چند لایه (MLP) و مدل دوم، مدل شبکه عصبی عمیق ترکیبی شامل شبکه های عصبی کانولوشنی (CNN) و شبکه های حافظه کوتاه مدت طولانی (LSTM) بود. نتایج حاصل از مقایسه عملکرد این دو مدل نشان داد که مدل یادگیری عمیق ترکیبی با ضریب تعیین ( $R^2$ ) برابر ۰/۹۸، نسبت به مدل شبکه عصبی پرسپترون چند لایه با ضریب تعیین ۰/۹۲ دقت بیشتری دارد. این نتایج نشان دهنده برتری واضح مدل یادگیری عمیق ترکیبی در پیش بینی تخلخل مخازن کربناته است.

با توجه به توانایی های مدل های یادگیری عمیق، انتظار می رود که مدل های پیچیده تر و پیشرفته تری مانند CNN، U-Net، Res-Net، LSTM و Autoencoder یا هر ترکیبی

کارایی، مدل‌های دیگر یادگیری عمیق نیز مورد بررسی و مقایسه قرار گیرند.

### نتیجه‌گیری

پیش‌بینی تخلخل با استفاده از مدل یادگیری عمیق ترکیبی به دلیل داشتن تعداد لایه‌های بیشتر و قابلیت استخراج ویژگی‌های پیچیده‌تر، بهتر است و نتایج دقیق‌تری از این مدل بدست آمده است. همچنین، یادگیری عمیق قابلیت انجام پیش‌پردازش‌های داده‌ها را دارد، بطوری که می‌تواند ویژگی‌های مهم را از داده‌های ورودی خود استخراج نماید و تاثیر داده‌های ناهنجار و پرت که در مدل‌های سنتی ممکن است مشکل‌ساز باشند، را از بین ببرد. در این کار از یک مدل یادگیری عمیق ترکیبی شبکه‌های عصبی کانولوشن و شبکه حافظه کوتاه‌مدت طولانی با معماری چندلایه‌ای عمیق برای انجام رگرسیون و پیش‌بینی تخلخل استفاده گردید. بر اساس نتایج بدست آمده، مدل شبکه عصبی یادگیری عمیق ترکیبی (با ضریب تعیین ۰/۹۸) عملکرد بهتری را برای پیش‌بینی تخلخل در مقایسه با مدل پرسپترون چندلایه (با ضریب تعیین ۰/۹۲) داشته است. بنابراین، استفاده از مدل یادگیری عمیق ترکیبی برای پیش‌بینی تخلخل، می‌تواند به صحت و دقت بیشتری در پیش‌بینی تخلخل منجر شود. مدل یادگیری عمیق ترکیبی قادر است تا ۹۸٪ واریانس تخلخل را در داده‌های ورودی تشخیص دهد. علاوه بر این، تخلخل پیش‌بینی شده توسط مدل یادگیری عمیق ترکیبی به داده‌های واقعی با دقت بیشتری نزدیک است و از مقادیر واقعی تخلخل کمتر انحراف دارد. بطور کلی نتایج نشان می‌دهد که مدل یادگیری عمیق ترکیبی در پیش‌بینی تخلخل از داده‌های بدست آمده از روش‌های مرسوم، دقت بالاتری دارد و بنابراین می‌تواند در تحقیقات آینده بطور گسترده‌تری مورد استفاده قرار گیرد.

مدل‌های Res-Net با استفاده از لایه‌های باقیمانده، مشکل گرادیان‌های ناپایدار در شبکه‌های عمیق را حل می‌نمایند. این مدل‌ها می‌توانند با دقت و کارایی بالاتری، ویژگی‌های پیچیده تخلخل مخازن را پیش‌بینی نمایند.

### ۴. مدل LSTM (Long Short-Term Memory)

مدل‌های LSTM به‌خوبی قادر به مدل‌سازی توالی‌های زمانی داده‌های چاه‌پیمایی هستند. این مدل‌ها می‌توانند روابط طولانی‌مدت بین داده‌ها را حفظ نموده و دقت پیش‌بینی را افزایش دهند.

### ۵. مدل Autoencoder

مدل‌های Autoencoder برای کاهش ابعاد داده‌ها و استخراج ویژگی‌های اصلی از داده‌های پیچیده بسیار مؤثر هستند. این مدل‌ها می‌توانند داده‌های چاه‌پیمایی را بطور مؤثری فشرده نموده و سپس با دقت بالایی ویژگی‌های تخلخل را استخراج نمایند.

با توجه به دقت و عملکرد بهتر مدل یادگیری عمیق ترکیبی در پیش‌بینی تخلخل، استفاده از این مدل به عنوان پایه برای تخمین تخلخل پیشنهاد می‌گردد. با این حال، به منظور افزایش دقت و کارایی مدل، پیشنهاد می‌شود که از مدل‌های پیشرفته‌تر یادگیری عمیق مانند CNN, U-Net, Res-Net, LSTM و Autoencoder نیز استفاده و نتایج حاصل با مدل فعلی مقایسه گردد.

در این مطالعه، مدل یادگیری عمیق ترکیبی شامل شبکه‌های عصبی کانولوشنی و حافظه کوتاه‌مدت طولانی برای پیش‌بینی تخلخل مخازن کربناته با دقت بالا مورد استفاده قرار گرفت. نتایج نشان داد که مدل یادگیری عمیق ترکیبی با ضریب تعیین ۰/۹۸ عملکرد بهتری نسبت به مدل شبکه عصبی پرسپترون چندلایه با ضریب تعیین ۰/۹۲ دارد. با توجه به این نتایج، استفاده از مدل یادگیری عمیق ترکیبی برای پیش‌بینی تخلخل مخازن کربناته توصیه می‌شود. همچنین، پیشنهاد می‌شود که به منظور بهبود دقت و

## منابع

- Aaron Courville, I.G., Yoshua Bengio, Deep Learning. Illustrated ed. Adaptive Computation and Machine Learning series. 2016: The MIT Press, 800.
- Ahmadi, M.A. and Z .Chen, Comparison of machine learning methods for estimating permeability and porosity of oil reservoirs via petro-physical logs. *Petroleum*, 2019. 5(3), 271-284.
- Allen, D., et al., Pore geometry and its geological evolution in carbonate rocks. *Petrophysics-The SPWLA Journal of Formation Evaluation and Reservoir Description*, 2002. 43(05).
- Bagheri, M., and Riahi, M. A., Seismic data random noise attenuation using DBM filtering. *Bollettino di Geofisica Teorica ed Applicata*, 2016, v. 57, n. 1, p. 1.
- Bagheri, M., Asadi S., and Talkhablou, M. Seismic multi-attribute analysis for fault and fracture modeling of an oil field in the south of Iran. *Journal of Seismic Exploration*. 2020. 29(4), 343-62.
- Bagheri, M., Riahi, M. A. Support Vector Machine Based Facies Classification Using Seismic Attributes in an Oil Field of Iran. *Iranian Journal of Oil and Gas Science and Technology*. 2013. 2(3), 1-10.
- Burchette, T.P., Carbonate rocks and petroleum reservoirs: a geological perspective from the industry. Geological Society, London, Special Publications, 2012. 370(1), 17-37.
- Bust, V.K., J.U. Oletu, and P.F. Worthington, The Challenges for Carbonate Petrophysics in Petroleum Resource Estimation. *SPE Reservoir Evaluation & Engineering*, 2011. 14(01), 25-34.
- Christopher M. Bishop , H.B., Deep Learning: Foundations and Concepts. 2023: Springer.
- Khodagholi, M. A. Bagheri, M., Seismic data random noise attenuation using LLSP smoothing. *Bollettino di Geofisica Teorica ed Applicata*, 2020, Vol 61, Issue 2, p131.
- Lai, J., et al., Prediction of reservoir quality in carbonates via porosity spectrum from image logs. *Journal of Petroleum Science and Engineering*, 2019. 173, 197-208.
- Mazzullo, S., Overview of porosity evolution in carbonate reservoirs. *Kansas Geological Society Bulletin*, 2004. 79(1-2), 1-19.
- Mehrabi, A., Bagheri, M., Bidhendi, M.N. et al. Improved porosity estimation in complex carbonate reservoirs using hybrid CRNN deep learning model. 2024, *Earth Sci Inform* 17, 4773–4790.
- Moosavi, N., Bagheri, M., Prediction of Water Saturation by FSVM using Well Logs in a Gas Field. *Journal of the Earth & Space Physics*. 2023, v. 48, n. 4, p. 77.
- Moosavi, N., et al., Hydrocarbon reservoir parameter estimation using a fuzzy Gaussian based SVR method. *Bulletin of Geophysics & Oceanography (BGO)*, 2024, v. 65, n. 4, p. 70.
- Moosavi, N., et al., Porosity prediction using Fuzzy SVR and FCM SVR from well logs of an oil field in south of Iran. *Acta Geophysica*, 2023. 71(2), 769-782.
- Okon, E.I. and D. Appah. Application of Machine Learning Techniques in Reservoir Characterization. in *SPE Nigeria Annual International Conference and Exh*. 2021.
- Stadtmüller, M. and J.A. Jarzyna, Estimation of Petrophysical Parameters of Carbonates Based on Well Logs and Laboratory Measurements, a Review. *Energies*, 2023. 16(10), 4215.
- Tiab, D. and E.C. Donaldson, *Petrophysics: theory and practice of measuring reservoir rock and fluid transport properties*, 2019.
- Tian, X., et al., A Carbonate Reservoir Prediction Method Based on Deep Learning and Multiparameter Joint Inversion. *Energies*, 2022. 15(7), 2506.
- Wang, J., J. CAO, and X. ZHOU, Reservoir porosity prediction based on deep bidirectional recurrent neural network. *Progress in Geophysics*, 2022. 37(1), 267-274.
- Wang, Y., et al., Gaussian mixture model deep neural network and its application in porosity prediction of deep carbonate reservoir. *Geophysics*, 2022. 87(2), M59-M72.
- Xu, C., et al., Machine learning in petrophysics: Advantages and limitations. *Artificial Intelligence in Geosciences*, 2022. 3, 157-161.
- Zare, A., M. Bagheri, and M. Ebadi, Reservoir facies and porosity modeling using seismic data and well logs by geostatistical simulation in an oil field. *Carbonates and Evaporites*, 2020. 35(3): 65.

Zhang, S., et al., Graph convolutional networks: a comprehensive review. *Computational Social Networks*, 2019. 6(1), 1-23.

Zou, C., et al., A comparison of machine learning methods to predict porosity in carbonate reservoirs from seismic-derived elastic properties. *GEOPHYSICS*, 2023. 88(2), B101-B120.

## Porosity estimation of carbonate reservoirs using a hybrid deep neural network model based on well data

Amirreza Mehrabi<sup>1</sup>, Majid Bagheri <sup>\*2</sup>, Majid Nabi Bidhendi<sup>3</sup>, Ebrahim Biniiaz Delijani<sup>4</sup> and Mohammad Behnoud<sup>4</sup>

<sup>1</sup> Ph.D. Student, Department of Petroleum Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

<sup>2</sup> Associate Professor, Institute of Geophysics, University of Tehran, Tehran, Iran

<sup>3</sup> Professor, Institute of Geophysics, University of Tehran, Tehran, Iran

<sup>4</sup> Assistant Professor, Department of Petroleum Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

(Received: 02 June 2024, Accepted: 26 August 2024)

### Summary

Estimating porosity in carbonate reservoirs is challenging and complex due to the intricate pore systems and heterogeneity. Porosity represents the fluid storage capacity of the reservoir and is crucial for estimating reserves and production capacity; therefore, accurate and precise estimation of reservoir rock porosity is essential. Traditional methods for measuring porosity, such as core analysis and well logging, are often expensive and time-consuming. Deep learning methods and algorithms, by extracting complex patterns from large datasets and analyzing well data, can provide more accurate porosity estimations. In this study, a novel approach using a hybrid deep neural network model is presented for porosity estimation based on well data. The data were collected from a carbonate reservoir in southwestern Iran and include data from core analysis and well logs (gamma, neutron, density, sonic, and resistivity logs). The dataset comprises 2,000 data points, with 236 cores and two wells, divided into training, validation, and testing sets in the proportions of 70%, 15%, and 15%, respectively, for the first well, while the second well was used to evaluate the model's performance. The approach of this study includes data collection and preparation, the design of the hybrid neural network architecture, training, optimization, and model evaluation. Core data were used to validate the constructed hybrid deep neural network model. The coefficient of determination ( $R^2$ ) for the hybrid deep neural network model was 0.98, indicating that this model has a very high accuracy in predicting porosity.

A comparison of porosity predictions made by the hybrid deep learning model shows that its performance is more accurate than that of the multilayer perceptron model.

**Keywords:** Porosity, carbonate reservoirs, deep learning, hybrid model, well data

---

\*Corresponding author:

majidbagheri@ut.ac.ir