

# تخمین تراوایی و شبیه‌سازی آن به منظور تعیین ویژگی‌های مخزنی سازند شور یجه در یکی از مخازن شمال شرق ایران

میلاذ مرادی<sup>۱</sup>، حسین رحیم پور بناب<sup>۱</sup> و علی کدخدائی<sup>۲\*</sup>

۱- دانشکده زمین‌شناسی، پردیس علوم، دانشگاه تهران، ایران

۲- گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز، ایران

تاریخ دریافت: ۱۴۰۰/۰۸/۲۹ تاریخ پذیرش: ۱۴۰۰/۱۱/۲۸

## چکیده

تراوایی یکی از مهم‌ترین پارامترها در مخازن هیدروکربنی است. درک صحیح از مقدار تراوایی و نحوه توزیع و گسترش آن در فرآیند مدیریت تولید از میدان سودمند است. فرآیند مغزه‌گیری به دلیل محدودیت‌های که وجود دارد بر روی تعداد کمی از چاه‌های میدان انجام می‌گیرد در حالی که بیشتر چاه‌ها تحت عملیات چاه‌نگاری قرار می‌گیرند. بنابراین یافتن راهی برای تخمین خصوصیات مخزن توسط نگاره‌های چاه‌پیمایی و مدل‌سازی آن در میدان تکنیک با ارزشی است. بنابراین در این پژوهش از روش شبکه عصبی مصنوعی پرسپترون چندلایه (پس انتشار خطا) برای تخمین تراوایی بخش‌های مختلف سازند شور یجه در حوضه رسوبی کپه داغ استفاده شده است. نمودارهای صوتی، نوترون و چگالی و نتایج حاصل از ارزیابی سازند شامل تخلخل و اشباع آب مفید به‌عنوان لایه ورودی و داده تراوایی حاصل از آنالیز مغزه دو چاه نیز به‌عنوان سلول‌های لایه خروجی برای آموزش شبکه مورد استفاده قرار گرفت. پس از آموزش شبکه با داده این دو چاه از داده آنالیز مغزه یک چاه دیگر برای آزمایش شبکه استفاده شد که در مرحله آزمایش شبکه ضریب همبستگی ۰.۹۸ برای تراوایی به‌دست آمد. با استفاده از این شبکه عصبی، تراوایی برای چاه‌های دیگر میدان که فاقد داده مغزه بودند تخمین‌زده شد. بعد از تخمین تراوایی به‌کمک شبکه عصبی نحوه توزیع و گسترش آن به‌کمک الگوریتم مدل‌سازی گوسی متوالی (SGS) در مقیاس میدان مشخص گردید. طبق مدل به‌دست آمده نواحی ماسه‌سنگی که عمدتاً در زون‌های B و D هستند به‌عنوان نواحی مخزنی تفکیک شده‌اند و همچنین نواحی مرکزی و شمال غربی میدان به‌دلیل میانگین تراوایی بالاتر نواحی مستعد برای حفاری‌های بعدی میدان می‌باشند.

**کلمات کلیدی:** سازند شور یجه، کپه داغ، نگاره چاه‌پیمایی، شبکه عصبی مصنوعی پرسپترون چند لایه، شبیه‌سازی گوسی متوالی (SGS)

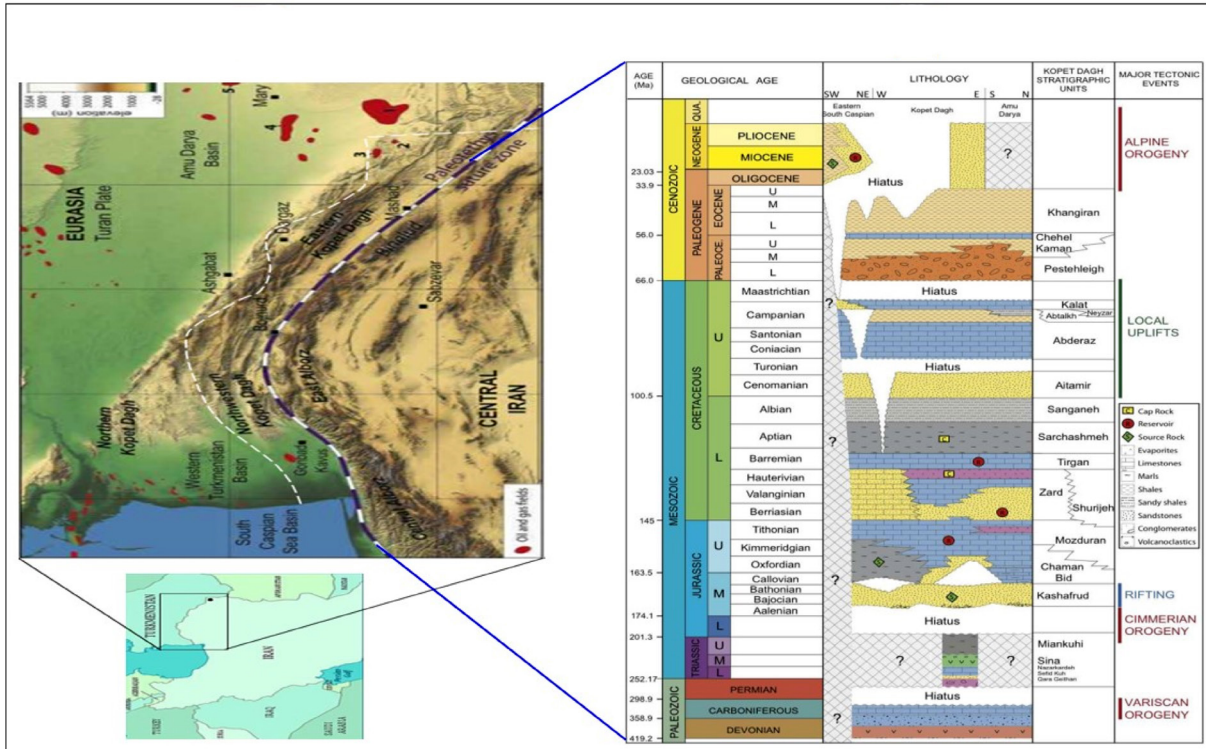
## مقدمه

تخلخل و تراوایی از پارامترهای مهم سنگ مخزن هستند، که تخمین آنها نقش کلیدی در اکتشاف میادین هیدروکربنی و پیش‌بینی حفاری‌های بعدی در میدان را دارد. بنابراین با ارزیابی این پارامترها می‌توان عملکرد تولید مخزن را افزایش داد [۱]. برای تخمین تراوایی از روش‌های مختلفی استفاده می‌شود اما تخمین آن با استفاده از مجموعه‌ای نگاره‌چاه‌پیمایی و به کمک شبکه عصبی مصنوعی به دلیل دقت بالا، هزینه کم (نسبت به فرآیند مغزه‌گیری) و سادگی در تخمین محبوبیت بیشتری دارد. در شبیه‌سازی تخمین دقیق تراوایی به دلیل فرآیند بازیافت ذخایر هیدروکربنی امری لازم و ضروری است [۲]. به‌طور معمول، پارامترهای مخزنی (مانند: تخلخل و تراوایی) را می‌توان از آنالیز مغزه به‌دست آورد. با توجه به دقت بالای که آنالیز مغزه‌گیری دارد اما به دلیل هزینه زیاد، محدودیت چاه‌های دارای داده مغزه و همچنین عدم پیوستگی در نرخ داده برداری نمی‌توان آن را به‌تنهایی در فرآیند شبیه‌سازی مورد استفاده قرار داد [۳]. اما داده‌های مربوط به نگاره‌چاه‌پیمایی به دلیل هزینه برداشت کمتر و پیوستگی در نرخ نمودارگیری و قابل دسترسی در اکثر یا تمام چاه‌های میدان در فرآیند تخمین تراوایی و شبیه‌سازی از اهمیت زیادی برخوردار است [۴ و ۵]. در سال‌های اخیر تخمین پارامترهای مخزنی و نگاره‌چاه‌پیمایی با استفاده از پاسخ مجموعه‌ای از نگاره‌های چاه‌پیمایی و با مدل شبکه عصبی مصنوعی توسط محققین در حال گسترش است [۶-۸]. شبکه عصبی مصنوعی و منطبق فازی از جمله روش‌های تخمینی مبتنی بر یادگیری هستند [۹]. این روش‌ها یک ابزار محاسباتی قدرتمند در حل مسائل مبهم و پیچیده‌ای هستند که با استفاده از روش‌های ریاضی مانند روابط دیفرانسیلی یا همبستگی‌های خطی قابل حل نیست [۱۰]. هدف اصلی این مطالعه، تخمین تراوایی به‌عنوان مهم‌ترین پارامتر مخزنی

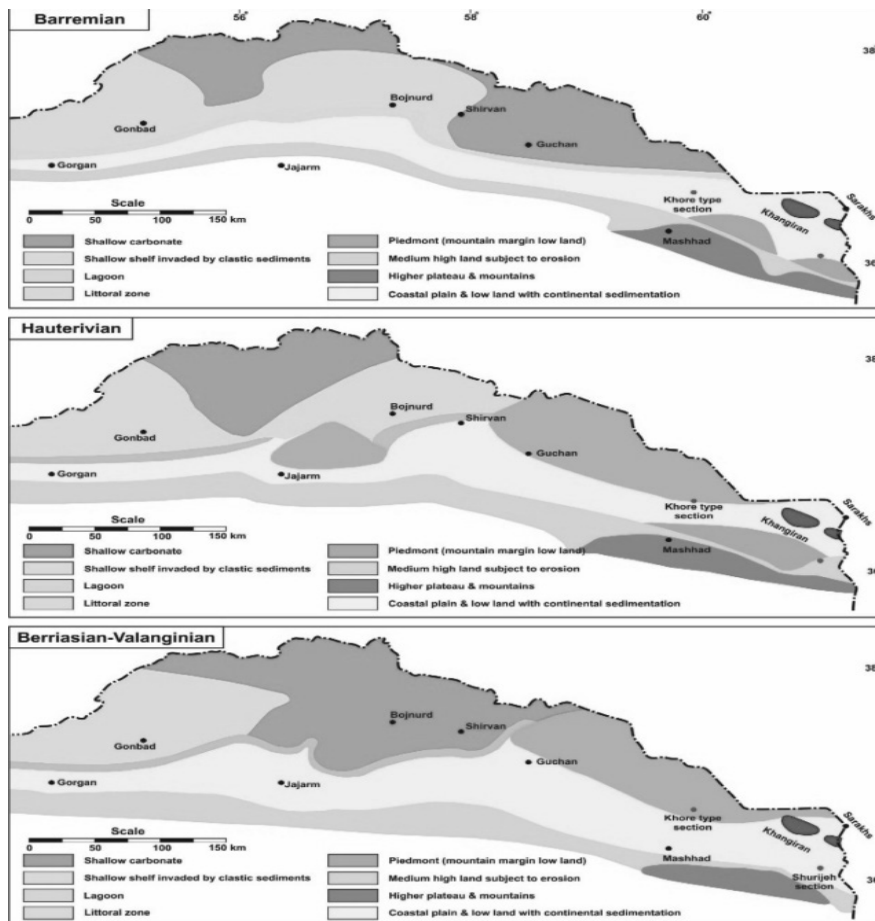
به کمک شبکه عصبی مصنوعی و مدل‌سازی آن برای مشخص کردن نحوه گسترش و پراکندگی نواحی مستعد مخزنی در میدان است تا براساس نتایج این مدل زون‌های مخزنی از غیر مخزنی برای حفاری‌های بعدی در میدان تفکیک شوند.

## زمین‌شناسی عمومی

از لحاظ سنگ‌شناسی، سازند شوربجه در بخش شرق مشهد و شمال غرب و غرب مشهد تغییرات قابل توجهی دارد (شکل ۱). بر طبق نقشه‌های رخساره‌ای شکل ۲، رخساره‌های کنگلومرایی و ماسه‌ای با میان لایه‌های شیل سرخ عمدتاً در بخش غربی ظهور می‌یابند در حالی که در بخش شمال غرب و غرب مشهد رخساره‌های شیلی، ژپسی، ماسه سنگی با میان لایه‌های کربناتی افزایش ضخامت می‌یابند [۱۱]. بازسازی محیط رسوبی این سازند براساس رخساره‌های رسوبی نشان می‌دهد که این سازند نتیجه رسوب‌گذاری در نواحی خشکی طی یک فاز پسروی دریایی در کرتاسه پیشین (نئوکومین) است (شکل ۲). رسوبات این فاز عمدتاً از سنگ‌های آواری ژوراسیک جنوب مشهد تأمین شده است [۱۲]. رسوب‌گذاری سازند آواری شوربجه در حوضه کپه داغ در زمان رخداد خشکی‌زایی سیمین پسین هم‌زمان با پسروی گسترده آب دریا در اواخر ژوراسیک- اوایل کرتاسه در اثر برخورد حوضه‌های ایران مرکزی و هلمند با حوضه‌های کپه داغ و آمودریا آغاز گردیده است [۱۳-۱۵]. به‌نظر می‌رسد توالی سازند شوربجه در نواحی شرقی و جنوبی حوضه رسوبی کپه داغ در بخش زیرین مربوط به محیط رودخانه‌ای و در بخش بالایی عمدتاً در یک محیط دلتایی تا دریایی کم‌عمق رسوب‌گذاری کرده است [۱۶-۱۸]. همچنین، محیط رسوبی قسمت زیرین سازند شوربجه در شرقی‌ترین بخش حوضه کپه داغ عمدتاً از نوع رودخانه بریده بریده و گاهی اوقات مئاندری است.



شکل ۱ الف) محل میدان‌های گازی (منطقه فرمز)؛ میدان عظیم گاز: ۱: دولت‌آباد، ۲: گنبدلی، ۳: خانگیران، ۴: شالتیک، ۵: بایرام‌علی، خط تیره سفید: مرز کشور؛ و ب) ستون چینه‌شناسی حوضه رسوبی کپه داغ [۲۰].



شکل ۲ نقشه جغرافیای دیرینه کپه داغ در کرتاسه پیشین [۲۱]

گوسی متوالی و کریجینگ<sup>۶</sup> استفاده شده است [۲۲] و [۲۳].

### نتایج

#### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، یک شبکه به هم پیوسته‌ای از پردازنده اطلاعات است که مشابه سیستم عصبی مغز انسان عمل می‌کند. یک شبکه عصبی از واحدهای پردازنده به نام نرون و اتصالات بین واحدهای که همان ضرایب یا فاکتورهای وزنی تشکیل شده است. نرون‌ها عناصر ضروری شبکه عصبی هستند و شبیه نرون بیولوژیکی، به صورت هماهنگ با هم در ارتباط هستند. در یک نگاه کلی، مدل یک شبکه عصبی شامل مجموعه‌ای از ورودی‌ها است که در نقش سنابس عمل می‌کنند و یک تابع فعال‌سازی تصمیم می‌گیرد که چگونه نرون فعال شود یا نه و مقدار خروجی براساس آن مشخص می‌شود. یکی از ساده‌ترین و پرکاربردترین شبکه‌های عصبی، مدل پرسپترون چندلایه است و شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است [۲۴]. خروجی شبکه عصبی (در لایه آخر) را می‌توان براساس رابطه ۱ محاسبه کرد:

$$O = f(\text{net}), \text{net} = b + \omega_1 x_1 + \dots + \omega_n x_n = b + \sum \omega x_i \quad (1)$$

در این رابطه،  $\omega$  و  $b$  وزن و بایاس شبکه عصبی مصنوعی بوده و  $f$  نشان‌دهنده تابع فعال‌سازی است که شامل یک فرمول ریاضی برای برورسانی وزن‌ها در شبکه است.

#### آموزش شبکه عصبی

الگوریتم‌های زیادی برای آموزش شبکه عصبی وجود دارد.

که به سمت قسمت بالایی این سازند تبدیل به رخساره‌های ساحلی و در نهایت رخساره‌های پهنه جزر و مدی می‌گردد. این قسمت به سمت غرب حوضه به‌طور جانبی به بخش‌های زیرین سازند تیرگان تبدیل می‌شود [۱۲]. بر طبق مطالعات پیشین، این سازند به پنج واحد مخزنی تقسیم شده است که زون‌های ماسه‌ای B و D اصلی‌ترین زون‌های مخزنی بوده و زون‌های A، C، E عموماً دارای خواص مخزنی مناسبی نمی‌باشند [۱۹].

#### داده‌ها و روش مطالعه

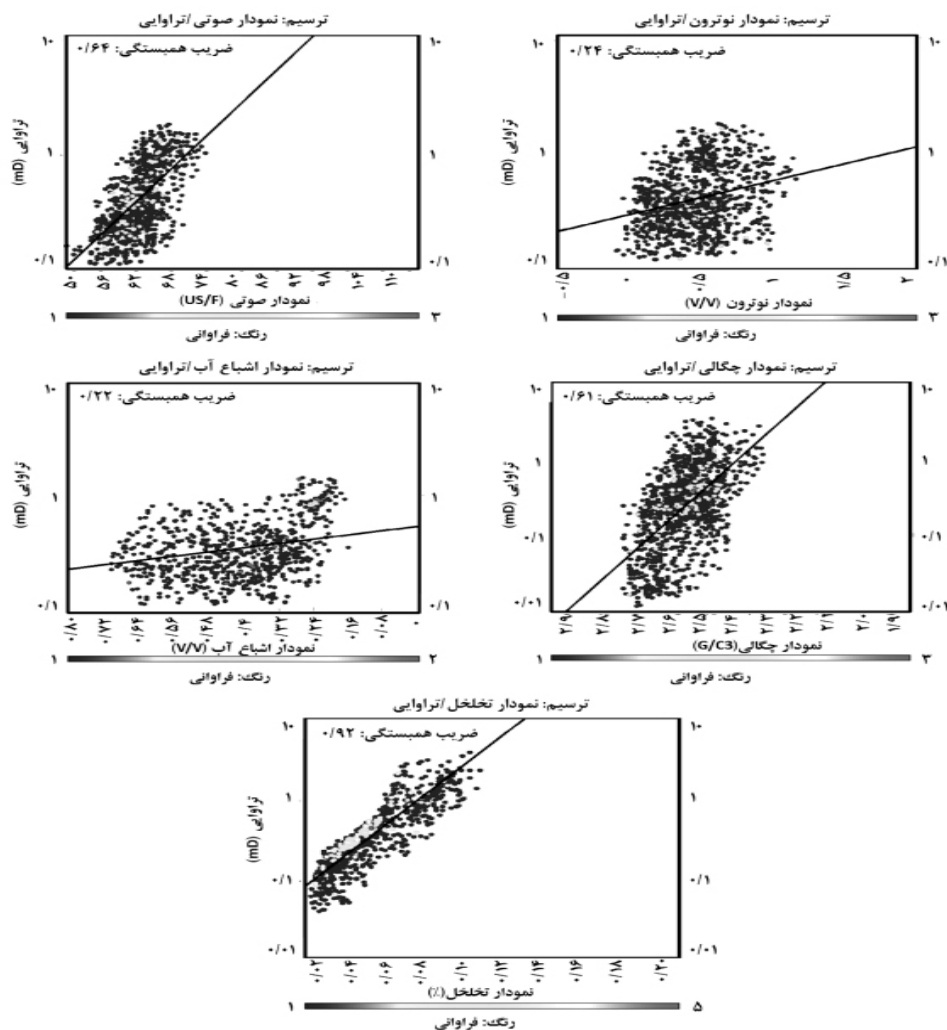
در این مطالعه برای تخمین و مدل‌سازی تراوایی در میدان مورد مطالعه، داده هفت حلقه چاه مورد بررسی قرار گرفت. تمام چاه‌های مطالعه‌ای دارای داده نگاره چاه‌پیمایی هستند ولی تنها از سه حلقه چاه داده آنالیز مغزه در دسترس است. در این پژوهش در ابتدا برای تخمین تراوایی، ارتباط هر کدام از نگاره‌های چاه‌پیمایی با تراوایی و براساس ضریب همبستگی مورد بررسی قرار گرفت. در نهایت، نگاره‌های نوترون، چگالی و صوتی و تخلخل مفید و اشباع آب حاصل از ارزیابی سازند با داشتن بهترین ضریب همبستگی و ارتباط بالا با تراوایی برای ساخت مدل شبکه عصبی پرسپترون چند لایه انتخاب گردید. بعد از اطمینان از عملکرد و مقدار دقت شبکه عصبی در چاه آزمایش، برای چاه‌های فاقد داده مغزه تراوایی تخمین زده شد. در ادامه برای شبیه‌سازی تراوایی و مشخص کردن گسترش و پراکندگی زون‌های مخزنی از غیرمخزنی و نواحی مستعد برای حفاری‌های بعد در میدان مراحل زیر در نرم‌افزار پترل انجام شد: ۱- بارگذاری پارامترهای ورودی (مانند: ورود اطلاعات سربرگ<sup>۱</sup> و موقعیت چاه‌ها، سرسازندها<sup>۲</sup>، اطلاعات نقشه‌های افق هم تراز دیجیتال<sup>۳</sup>، نمودارهای چاه‌پیمایی<sup>۴</sup>) و کنترل کیفیت آن، ۲- مدل‌سازی ساختمانی<sup>۵</sup>، ۳- مدل‌سازی خواص پتروفیزیکی (تراوایی). برای مدل‌سازی پارامتر مخزنی (تراوایی) از دو الگوریتم

1. Well Head
2. Well Top
3. Underground Contour Map
4. Well Log
5. Structural Modeling
6. Kriging

این گام از کار نقش مهمی را در ساخت مدل ایفا می‌کند. به‌طور کلی، ارتباط قوی بین داده‌های ورودی و خروجی، می‌تواند پیش‌گویی دقیق‌تری را نسبت به داده‌های با تطابق ضعیف‌تر ایجاد کند. در این مطالعه با کراس پلات‌های مختلف نگاره‌های چاه‌پیمایی در مقابل تراوایی انجام شده و نگاره‌های نوترون (NPHI)، صوتی (DT) و چگالی (RHOB) دارای بیشترین ارتباط با خروجی (تراوایی) حاصل از آنالیز مغزه) بود، و برای بهبود تخمین تراوایی، تداخل مؤثر (PHIE) و اشباع آب مؤثر (SWE) حاصل از ارزیابی احتمالی سازند هم به‌عنوان ورودی شبکه انتخاب شد (شکل ۳).

اما در این مطالعه به‌دلیل کاربرد و محبوبیت بیشتر الگوریتم پسانتشار خطا<sup>۱</sup> از آن برای آموزش استفاده شده است. این روش جزو روش‌های با نظارت<sup>۲</sup> است که داده‌های ورودی مشخص شده‌اند و خروجی مورد انتظار هر یک از آن‌ها از پیش مشخص است. بنابراین تخمین خروجی شبکه (تراوایی تخمینی) با تخمین ایده‌ال (تراوایی مغزه) مقایسه شده و خطای شبکه با استفاده از الگوریتم‌های مختلف محاسبه می‌شود. در هر مرحله، خروجی شبکه اندازه‌گیری می‌شود و برحسب میزان خطا بین پارامتر تخمینی و پارامتر هدف، وزن‌ها تصحیح می‌گردند تا در نهایت این خطا به حداقل برسد [۲۵].

### انتخاب ورودی‌های مدل شبکه عصبی



شکل ۳ ترسیم پارامترهای ورودی و هدف برای ساخت شبکه عصبی

1. Error Back Propagation  
2. Supervised

## طراحی ساختار شبکه عصبی مصنوعی

که در آن  $n$  تعداد داده‌ها و  $e$  اختلاف بین مقدار واقعی و مقدار برآورد شده توسط شبکه است. پس از انجام مراحل بهینه‌سازی مشخص گردید که شبکه‌ای با مشخصات زیر می‌تواند بهترین نتایج را در پیش‌بینی مسئله مورد نظر به‌همراه داشته باشد:

۱- شبکه سه لایه با دو لایه مخفی

۲- تابع  $tansig$  به‌عنوان تابع انتقال لایه مخفی

۳- تابع  $pureline$  به‌عنوان تابع انتقال لایه خروجی

۴- ۱۰ نرون در لایه مخفی اول و ۹ نرون در لایه مخفی دوم


۵- تابع  $trainlm$  به‌عنوان تابع آموزش شبکه

**شکل ۴** ساختار کلی شبکه بهینه ایجاد شده را نمایش می‌دهد. در نهایت، شبکه‌ای با مشخصات فوق ساخته شد و توسط آن تراوایی مخزن تخمین‌زده شد. عملیات تخمین ۲۱ مرتبه تکرار گردید. یکی از معیارهای مهم در آموزش شبکه، تعداد دوره‌ها یا تکرارهایی است که شبکه در حین آموزش انجام می‌دهد. تعیین صحیح این تکرارها در آموزش شبکه بسیار مهم است. به‌طور کلی هر چه تعداد تکرارها در آموزش شبکه بیشتر باشد خطای پیش‌بینی در شبکه کمتر می‌شود. اما هنگامی که تعداد تکرارها از یک مقدار تجاوز کند، خطای دسته آزمایشی نیز افزایش می‌یابد.

کارایی شبکه‌های آموزش دیده تا حدی با استفاده از خطای مجموعه‌های آموزشی، اعتبارسنجی و آزمایش قابل اندازه‌گیری است، اما اغلب بهتر است تا جزئیات عکس‌العمل شبکه با دقت بیشتری بررسی گردد. آنالیز همبستگی برای انجام این تحلیل‌ها طراحی شده است، برای انجام این آنالیز خروجی شبکه و بردار هدف- برای داده‌های آموزش، اعتبارسنجی و آزمایش- وارد نرم‌افزار اکسل شده و آنالیز همبستگی آن برای مشخص کردن  $m$  و  $b$  (شیب و عرض از مبدأ) انجام گرفت. اگر تناسب کاملی بین خروجی و هدف وجود داشته باشد (یعنی خروجی شبکه کاملاً با هدف برابر باشد)، شیب برابر یک و عرض از مبدأ برابر صفر خواهد بود. پارامتر دیگر آنالیز همبستگی، ضریب همبستگی بین خروجی‌ها و هدف است. که اگر این عدد برابر یک باشد، در آن صورت مشخص می‌شود که ارتباط کاملی بین خروجی و هدف وجود دارد. برای ارزیابی شبکه بهینه از جذر میانگین مربعات خطا (RMSE) و میانگین مربعات خطا (MSE) نیز استفاده گردید (رابطه ۲ و ۳):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n ei^2}{n}} \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (ei)^2 \quad (3)$$



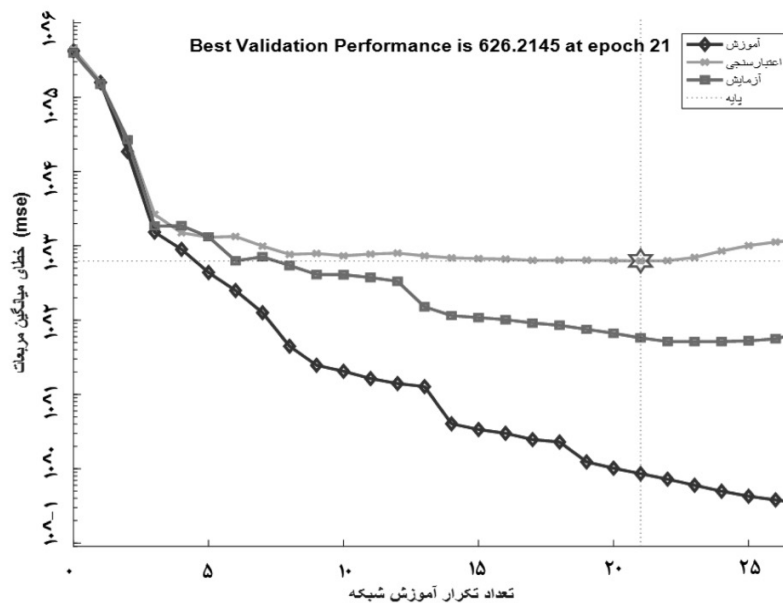
شکل ۴ الف) ساختار شبکه عصبی پرسپترون سه لایه؛ ب) ساختار کلی شبکه عصبی استفاده شده در این مطالعه [۲۵]

همان‌طوری که در شکل ۵ دیده می‌شود از تکرار ۲۱ به بعد که خطای آزمایش افزایش پیدا می‌کند و آموزش شبکه متوقف و وزن‌های شبکه ثابت می‌گردد تا بیش از حد آموزش نبیند و الگوها را حفظ کند. در جدول ۱ میانگین پارامترهای حاصل از آنالیز همبستگی، تعداد داده هر دسته و خطای مربعات حاصل از ۲۱ تکرار برای هر سه نوع داده آموزش، اعتبارسنجی و آزمایش به مقایسه تراوایی حاصل از مغزه و تخمینی در مقابل هر سه نوع دسته آموزش، اعتبارسنجی و آزمایش در شکل‌های ۶ تا ۸ و مقایسه نتایج تخمینی با داده واقعی تراوایی در مقابل عمق در شکل‌های ۹ و ۱۰ ترسیم شده است.

**مدل‌سازی زمین آماری**

زمین آمار علمی است که به بحث در مورد رابطه

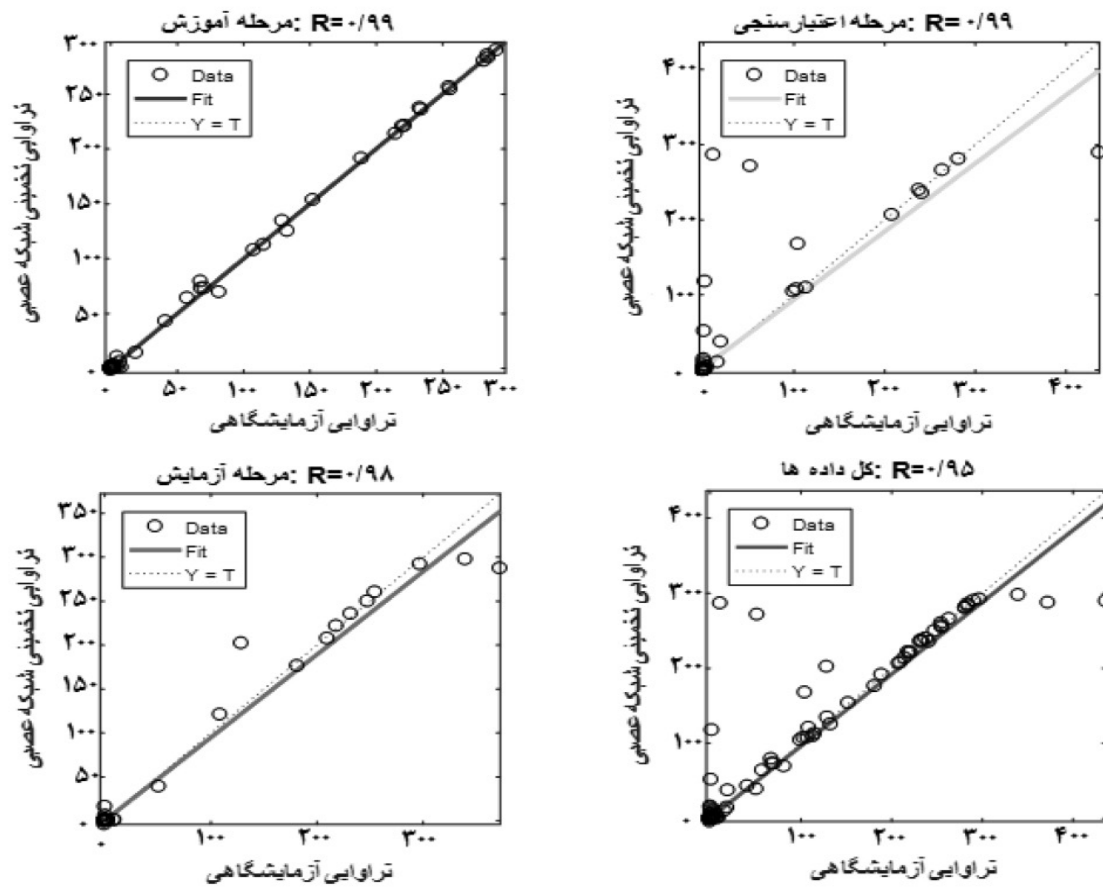
فضایی بین متغیرها می‌پردازد. در طبیعت مشخص شده است که مقدار و میزان یک پارامتر در فواصل نزدیک مشابه به هم و با افزایش فاصله مقدار شباهت بین آنها کاهش پیدا می‌کند. بنابراین، زمین‌آمار با بررسی پارامترهای مؤثر بین اندازه‌گیری‌ها به توزیع فضایی یک متغیر می‌پردازد [۲۶]. در زمین آمار از الگوریتم‌های مختلفی برای شبیه‌سازی استفاده می‌شود. در مدل‌سازی پتروفیزیکی، رخساره‌ای و ساخت افق‌های زمین‌شناسی باید نوع الگوریتمی که استفاده می‌شود مشخص و هم راستا با نوع ورودی داده‌ها باشد. دو نوع روش زمین آماری وجود دارد، یک دسته تحت عنوان روش‌های قطعی (مانند: کریجینگ و میانگین جریان<sup>۱</sup>) و دسته دوم، روش‌های تصادفی (شاخص پی‌درپی و گوسی متوالی) شناخته می‌شوند.



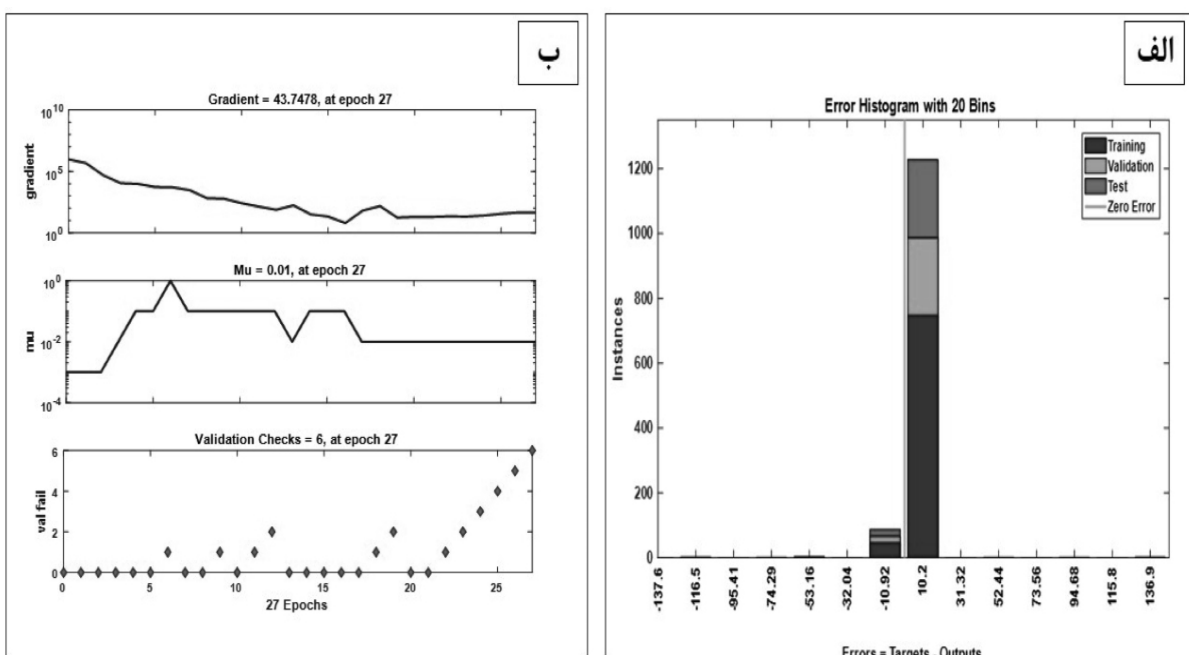
شکل ۵ منحنی خطا در مقابل تعداد تکرار الگوریتم برای داده‌های آموزش، اعتبارسنجی و آزمایش

جدول ۱ میانگین پارامترهای حاصل از آنالیز همبستگی و مقدار خطا برای انواع مختلف داده‌ها

MSE	RMSE	ضریب همبستگی	عرض از مبدأ	شیب نمودار همبستگی	تعداد داده	نوع داده
۰/۰۱	۰/۹۲	۰/۹۹	۰/۰۰۷	۰/۹۹	۷۹۴	آموزش
۲/۳	۲۵/۰	۰/۸۵	۳/۱	۰/۹۷	۲۶۴	اعتبارسنجی
۰/۲۲	۷/۵	۰/۹۸	۰/۳۴	۰/۸۶	۲۶۴	آزمایش




شکل ۶ مقایسه تراوایی آزمایشگاهی (Real) و مقادیر تخمین زده شده (Predicted) برای داده‌های آموزش، اعتبارسنجی و آزمایش.

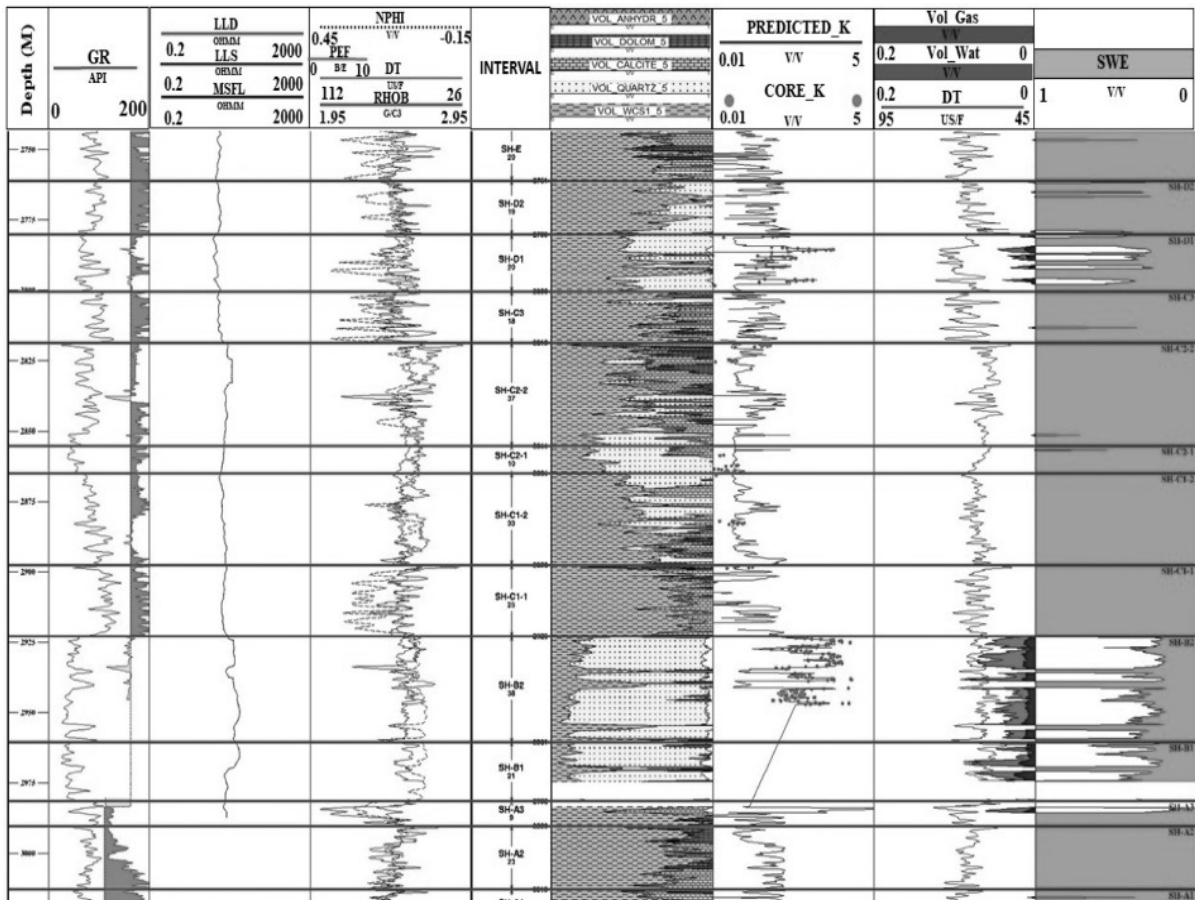


شکل ۷ الف) هیستوگرام خطا برای داده‌های آموزش، اعتبارسنجی و آزمایش، ب) تعداد تکرار آموزش شبکه.






شکل ۸ مقایسه تراوایی مغزه اندازه‌گیری (Real) و مقادیر تخمین‌زده شده (Predicted) در چاه آزمایش (KG-001)



شکل ۹ نمایش ورودی‌های ساخت شبکه عصبی و مقایسه تراوایی مغزه اندازه‌گیری (Real) و مقادیر تخمین‌زده شده (Pre-) (dicted) در مقابل عمق چاه آزمایش (KG-001)



شکل ۱۰ نمایش ورودی‌های ساخت شبکه عصبی با مقادیر تخمین‌زده شده (ANN) برای هر هفت چاه مورد مطالعه

نسبت به دیگر روش‌های احتمالی محبوبیت بیشتری دارند. اگر داده‌ها به صورت گسسته و اعداد صحیح (مانند کد رخساره‌ای یا گونه‌های سنگی و...) باشند از مدل شبیه‌سازی احتمالی شاخص پی‌درپی استفاده می‌شود و اگر داده‌ها به صورت پیوسته و اعشاری (مانند پارامترهای پتروفیزیکی) باشد از مدل شبیه‌سازی احتمالی گوسی متوالی استفاده می‌شود. مدل کریجینگ: یکی از مشهورترین الگوریتم‌ها برای شبیه‌سازی پارامترهای، ایستای مخزن هستند و براساس رابطه درون‌یابی خطی بنا شده است. در این روش با استفاده از یک رابطه خطی رابطه ۴ نقاط مجهول براساس نقاط معلوم تخمین‌زده می‌شود [۲۷ و ۲۸].

در روش قطعی، براساس نقاط داده مشخص، مقادیر جدیدی برای نقاط دیگر در همان محدوده محاسبه می‌کند. در این روش برحسب مقدار فاصله نقاط مجهول از نقطه معلوم وزن دهی داده می‌شود. در روش تصادفی با هر بار اجرا بر روی یک سری داده ثابت، جواب‌های مختلفی به دست می‌آید که البته احتمال وقوع آنها با هم برابر است. در روش تصادفی جواب‌های تصادفی تولید می‌شود و در ادامه می‌توان چندین مدل احتمالی رو با هم مقایسه کرد و محتمل‌ترین مدل که با تعداد بیشتری تولید شده است را به عنوان بهترین مدل در نظر گرفت [۲۷]. بسته به نوع داده‌ای که برای مدل‌سازی انتخاب می‌شود دو نوع مدل احتمالی، شاخص پی‌درپی و گوسی متوالی

شوند. هر چقدر این سلول‌ها کوچک مقیاس‌تر انتخاب شود دقت مدل‌سازی بالاتر، اما مدت زمان ساخت مدل بیشتر می‌شود. بنابراین باید انتخاب این سلول‌ها بدرستی انجام شود تا تخمین درستی از میدان به‌دست آید. از این‌رو، تعریف شبکه‌بندی مناسب برای شبیه‌سازی و تخمین صحیح هر پارامتر مخزنی ضروری است [۳۱]. در این مطالعه با توجه به اهمیت مخزنی هر کدام از زون‌های سازند شوریجه، اقدام به شبکه‌بندی مخزن شد. بنابراین بعد از تعریف مدل ساختمانی در راستای X و Y و ۱۰۰ × ۱۰۰ مترمربع و در راستای Z در زون مخزنی (D2 و B، C2، D1) ۱ متر و غیرمخزنی (A، C1، C3 و E) ۵ m<sup>2</sup> شبکه‌بندی انجام شد (شکل ۱۱).

#### درشت‌نمایی<sup>۳</sup>

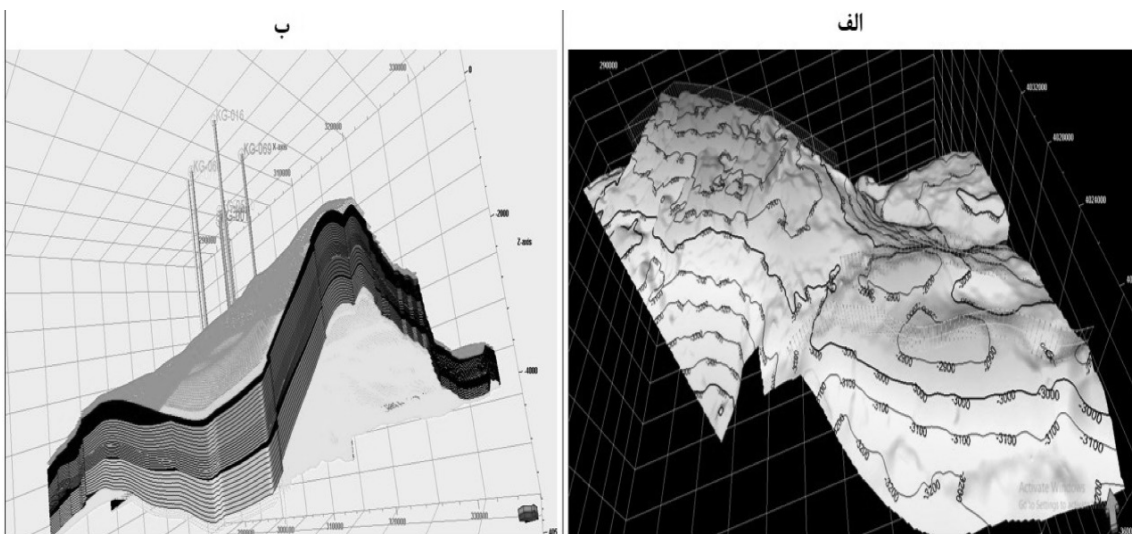
با توجه به اینکه داده هر پارامتر مخزنی و نگاره‌چاه‌پیمایی در مسیر چاه حفاری شده است باید قبل از شبیه‌سازی این پارامترها در تمام ابعاد سلول ساختمانی تعریف شود که این مرحله درشت‌نمایی نامیده می‌شود. برای درشت‌نمایی از روش‌های مختلف میانگین‌گیری استفاده می‌شود [۳۲].

$$(\lambda_i Z(x_i))Z(x_0) = E_i^N = 1 \quad (4)$$

در این رابطه،  $Z(x_0)$  پارامتر مجهول در نقطه  $X_0$ ،  $\lambda_i$  وزن هر نقطه و  $Z(x_i)$  مقدار پارامتر معلوم در نقطه  $X_i$  است. مدل گوسی متوالی: در این روش برای تخمین یک نقطه مجهول از تکرار فرآیندهای آماری استفاده می‌شود و توزیع داده‌ها از یک نمودار گوسی پیروی می‌کند. در الگوریتم به‌کار رفته در این روش ابتدا کاملاً به‌صورت تصادفی یک نقطه انتخاب می‌شود و سپس کل سلول‌های شبکه به‌ترتیب و به شکل متوالی شبیه‌سازی می‌شود [۲۹]. در ساخت یک مدل زمین‌آماری مراحل زیر به‌ترتیب انجام می‌شود:

#### ساخت مدل ساختمانی<sup>۱</sup> و شبکه‌بندی<sup>۲</sup> مخزن

چهارچوب هندسی شبکه سه بعدی، مدل ساختمانی مخزن است. به‌طور کلی، مدل ساختمانی نقطه شروع یک مدل مخزن است [۳۰]. در این مطالعه با توجه به افق‌های مربوط به سازندها و گسل‌های مربوطه مدل ساختمانی تعریف گردید (شکل ۱۱). بعد از تعریف مدل ساختمانی باید این مدل یکپارچه مخزن به سلول‌های کوچکتری که در برگیرندی میانگین هر پارامتر هستند تقسیم



شکل ۱۱ الف) افق مربوط به سرسازند و اثر گسل، ب) شبکه‌بندی سازند شوریهجه

1. Structural Modeling
2. Pillar Gridding
3. Upscaling

به شکل تخمین خوبی را برای کل سلول‌های ساختمانی نشان می‌دهد.

### آنالیز داده

بعد از درشت‌نمایی در محاسبات زمین‌آماری اول باید داده دارای توزیع نرمال باشد و در ادامه، اثر روند در آنها حذف شود. در زمین‌آمار موقعیت فضایی داده‌ها و مقدار کمیت آن هم‌زمان بررسی می‌شود. پس باید بین مقادیر یک کمیت در جامعه نمونه، فاصله و جهت قرارگیری داده‌ها نسبت به هم ارتباط برقرار شود. این ارتباط توسط ساختار فضایی برقرار می‌شود [۳۱]، که این ساختار همان واریوگرام<sup>۲</sup> در فرآیند شبیه‌سازی است، که در سه جهت عمود، اصلی و فرعی تعریف می‌گردد. انتخاب صحیح واریوگرام در فرآیند مدل‌سازی سه بعدی پارامترهای پتروفیزیکی (تراوایی) اهمیت زیادی دارد [۲۲، ۳۳، ۲۶]. مقدار واریوگرام از رابطه ۶ محاسبه می‌گردد:

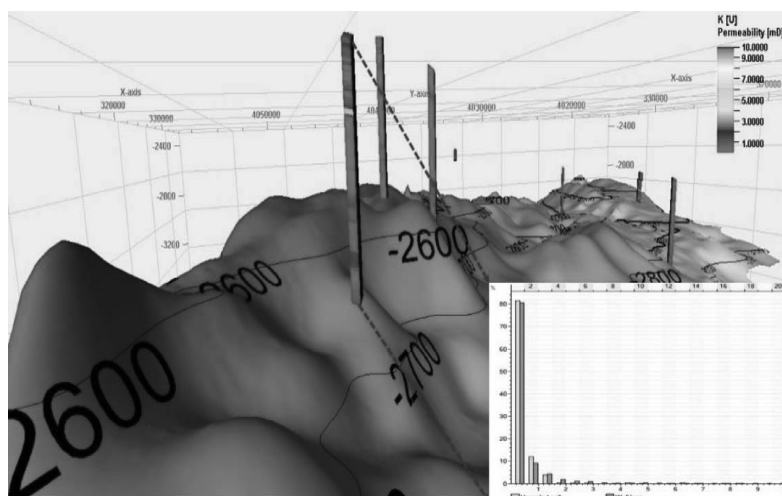
$$Y(h) = \frac{1}{2N_h} \sum_{i=1}^{N_h} (Z_{x+h} - Z_x)^2 \quad (6)$$

که در این رابطه،  $N_h$  تعداد جفت نمونه‌های به‌کار رفته شده به‌ازای یک فاصله مشخص مانند  $Z_x$ ،  $h$  متغیر مشاهده شده در نقطه  $x$  و  $Z_{x+h}$  مقدار متغیرهای مشاهده شده در نقطه‌ای به فاصله  $h$  از نقطه  $x$  است (شکل ۱۳).

معمولاً سه روش میانگین‌گیری شامل میانگین‌گیری حسابی، هندسی و همساز<sup>۱</sup> وجود دارد. روش حسابی به‌دلیل اینکه داده‌ها با تصاعد حسابی در ارتباط هستند، هر داده با نقطه وسط داده‌ها (میان) برابر است یا به عبارت دیگر میانگین حسابی، نقطه‌ای است که میانگین فاصله نقاط از آن صفر است. در روش هندسی، تصاعد هندسی یا جزر آن با نقطه وسط داده یا همان میانگین برابر خواهد بود. روش سوم میانگین‌گیری روش میانگین همساز است که دقیقاً برعکس میانگین‌گیری حسابی تعریف می‌شود و معکوس داده‌ها در نظر گرفته می‌شود. بنابراین با توجه به اینکه پارامترهای مخزنی مانند تراوایی، تخلخل و غیره، اعداد پیوسته و به‌صورت اعشاری می‌باشند استفاده از روش میانگین‌گیری حسابی نتایج بهتری حاصل می‌شود. میانگین‌گیری حسابی با استفاده از رابطه ۵ قابل محاسبه است:

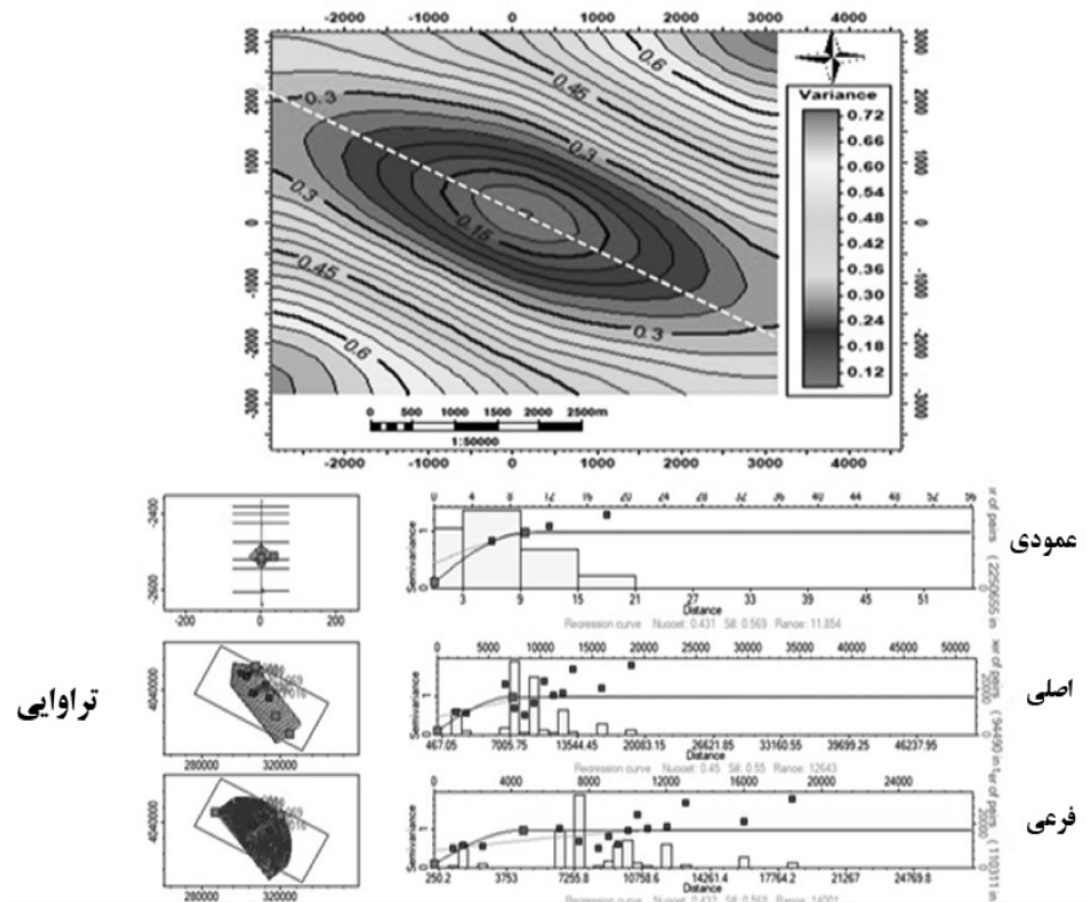
$$X_A = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (X_1 + \dots + X_n) \quad (5)$$

که در این رابطه،  $X_A$  میانگین پارامترهای پتروفیزیکی  $X_i$ ، مقادیر پارامتر  $X$  در موقعیت  $i$  و  $h$  تعداد نمونه‌ها است. درشت‌نمایی برای پارامترهای پتروفیزیکی (تراوایی) برای زون‌های مورد مطالعه در شکل ۱۲ نمایش داده شده است که با توجه



شکل ۱۲ درشت‌نمایی داده تراوایی

1. Harmonic Mean  
2. Variogram



شکل ۱۳ مدل واریوگرام در سه جهت عمودی، اصلی و فرعی زون D1 سازند شورپیجه

### تفسیر نتایج

تخمین صحیح تراوایی و مشخص کردن نحوی توزیع و گسترش این پارامتر به دلیل هزینه زیاد مغزه‌گیری و عدم پیوستگی آن در چاه‌های حفاری یکی از اهداف اصلی در هر پروژه نفتی است. شبکه عصبی پرسپترون چند لایه (MLP) به دلیل دقت بالایی که در فرآیند تخمین دارد مورد استفاده قرار گرفت. بعد از ترسیم انواع نگاره‌های چاه‌پیمایی با تراوایی، براساس ضریب رگرسیون، نگاره‌های که بیشترین ضریب همبستگی را با تراوایی داشتند انتخاب گردید. نگاره‌های چاه‌پیمایی نوترون، صوتی و چگالی و نتایج حاصل از ارزیابی سازند شامل تخلخل مفید و اشباع آب مؤثر به‌عنوان ورودی‌های شبکه عصبی مصنوعی انتخاب شده‌اند. بعد از مقایسه الگوریتم‌های مختلفی که برای آموزش شبکه وجود دارد الگوریتم  $trainlm$  با کمترین میانگین مربعات خطا (MSE) برای هر

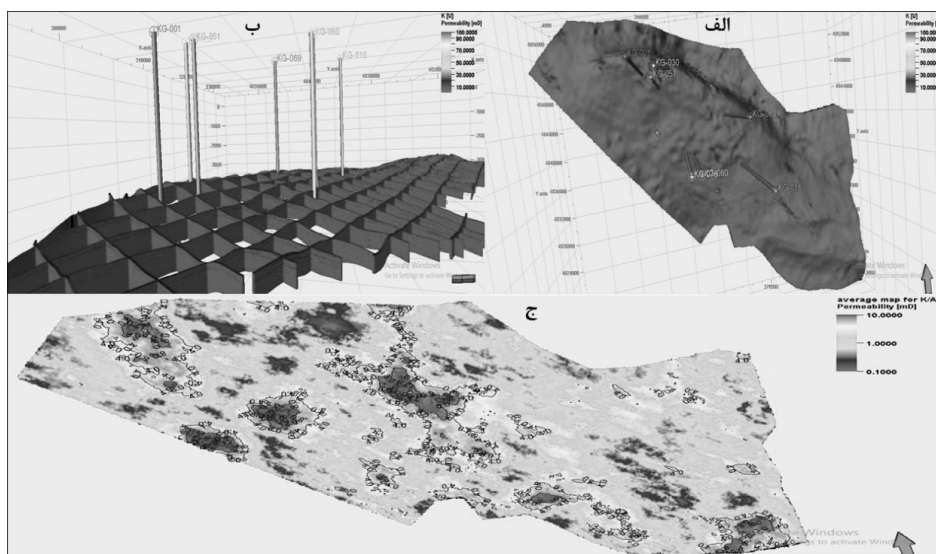
سه دسته آموزش، اعتبارسنجی و آزمایش به‌عنوان روش بهینه انتخاب گردید. برای انتقال لایه مخفی از تابع  $tansig$  و برای لایه خروجی از تابع  $pureline$  استفاده شد. همان‌طوری که در شکل‌های ۸ و ۹ که تراوایی واقعی با تخمین شبکه عصبی را نمایش می‌دهد برای چاه تست تا ۹۸٪ دقت در تخمین را نشان می‌دهد. با توجه به اینکه در مخزن شورپیجه عامل اصلی کنترل‌کننده کیفیت مخزنی بافت رسوبی اولیه است و فرآیند های دیاژنزی توالی مورد نظر را کمتر تحت تأثیر قرار داده است بنابراین رابطی منطقی بین پارامترهای ورودی ما که شامل لاگ‌های نوترون، چگالی، صوتی، اشباع آب و تخلخل هستند با پارامتر هدف (تراوایی) وجود دارد و این ارتباط مشخص بین نمودارهای ورودی و خروجی باعث افزایش تخمین (۰/۹۸) در مخزن شورپیجه شده است.

توزیع و گسترش تراوایی در کل میدان مشخص شد. براساس نتایج **جدول ۲**، شبیه‌سازی با استفاده از الگوریتم شبیه‌سازی گوسی متوالی با توجه به تخمین بهتر تراوایی در مرحله مدل و همچنین انحراف معیار و واریانس نزدیک به لاگ ورودی و درشت‌نمایی شده از دقت بهتری برخوردار است. مقدار تراوایی بالا با زون‌های عمدتاً ماسه سنگی B، D2 و D1 مربوط به محیط‌های پرانرژی (مانند رودخانه بریده بریده، بخش پر انرژی لاگون تا سدهای جزرومدی) در ارتباط است و تراوایی پایین در ارتباط محیط‌های کم انرژی (دشت سیلابی)، روخانه مائندری و پری تایدال (بالای جزرومد) است. نحوی توزیع و گسترش تراوایی در **شکل ۱۴** نشان دهنده این است که شمال غربی و بخش مرکزی میدان به دلیل تراوایی بالاتری نسبت به بخش جنوبی و شمال شرقی از کیفیت مخزنی بهتری برخوردار است.

با توجه به دقت بالای که در تخمین تراوایی واقعی و تخمینی وجود دارد با قطعیت عملکرد صحیح شبکه مورد اثبات قرار گرفت. در نهایت به کمک شبکه عصبی با ساختار گفته شده برای چاه‌های دیگر که فاقد داده آنالیز مغزه بودند تراوایی تخمین‌زده شد تا در مرحله بعد به عنوان ورودی وارد ساخت فرآیند شبیه‌سازی گردد. در هر مطالعه برای مشخص کردن توزیع و گسترش هر پارامتر مخزنی و پیش‌بینی محل حفاری‌های بعدی که در میدان صورت می‌گیرد شبیه‌سازی امری لازم و ضروری است. بنابراین در این مطالعه هم بعد از تخمین صحیح تراوایی در کل چاه‌های در دسترس به ساخته مدل سه بعدی پرداختیم. در ابتدا بر پایه زمین‌آمار ساخت مدل ساختمانی و شبکه‌بندی مخزن صورت گرفت و بعد از فرآیند درشت‌نمایی و آنالیز داده‌ها به کمک الگوریتم‌های شبیه‌سازی گوسی متوالی (SGS) و کریجینگ (Kriging) نحوه

**جدول ۲** مقایسه دو الگوریتم شبیه‌سازی گوسی متوالی (SGS) و کریجینگ (Kriging) برای سازند شورجه

واریانس	انحراف معیار	میانگین	حداکثر	حداقل	الگوریتم	
۶۰۷/۸۱	۲۴/۶۵	۳/۴۷	۴۱۷/۸۶	۰/۰۱۰۰	لاگ درشت‌نمایی مدل	شبیه‌سازی گوسی متوالی (SGS)
۶۲۳/۸۱	۲۴/۹۶	۴/۸۴	۲۹۷/۱۹	۰/۰۱۰۰		
۶۴۷/۸۵	۲۵/۴۵	۴/۷۳	۴۱۷/۷۰	۰/۰۰۷		
۶۰۷/۸۱	۲۴/۶۵	۳/۴۷	۴۱۷/۸۶	۰/۰۱۰۰	لاگ درشت‌نمایی مدل	شبیه‌سازی کریجینگ (Kriging)
۶۲۳/۱۲	۲۴/۹۶	۴/۸۴	۲۹۷/۱۹	۰/۰۱۰۰		
۸/۴۳۰	۲/۹۰	۰/۳۸	۲۹۷/۱۹	۰/۰۱۰۰		



**شکل ۱۴** نتایج مدل‌سازی تراوایی: الف) مدل‌سازی گوسی متوالی (SGS)، ب) فیلتر مدل‌سازی گوسی متوالی (SGS)، ج) نقشه میانگین تراوایی در کل توالی سازند شورجه.

## نتیجه‌گیری

نظر با استفاده از روش معمول مدل‌سازی شامل روش گوسی متوالی (SGS) و کریجینگ (Kriging) به تخمین تراوایی و نحوی توزیع و گسترش آن پرداخته شد. با توجه با مقایسه این دو الگوریتم مدل‌سازی روش تخمینی تصادفی گوسی متوالی (SGS) به دلیل تخمین دقیق‌تر میانگین تراوایی در کل میدان و همچنین انحراف معیار و واریانس نزدیک به تراوایی چاه می‌تواند با دقت بسیار خوبی به شبیه‌سازی پارامترهای مخزنی (تراوایی) و همچنین فهم توزیع و گسترش سه‌بعدی این پارامتر در فواصل بین چاه‌ها سازند شورپیجه بپردازد. تراوایی‌های بالا بیشتر با نواحی ماسه‌سنگی سازند شورپیجه که اغلب در زون‌های مخزنی B، D2 و D1 تمرکز دارد در ارتباط هستند. زون‌های که شیل غلبه پیدا می‌کند یا مخلوطی از شیل، ماسه و کربناته هستند با تراوایی پایین مشخص می‌شود. همچنین نحوی توزیع و پراکندگی تراوایی در میدان حاکی از آن است که نواحی شمال غربی و مرکزی میدان نواحی مستعد برای حفاری‌های بعدی در میدان می‌باشند و نواحی جنوبی و شرقی به دلیل میانگین تراوایی کمتر نسبت به نواحی شمالی و غربی از پتانسیل تولیدی کمتری برخوردار هستند.

هدف اصلی از این پژوهش تخمین صحیح تراوایی به کمک شبکه عصبی مصنوعی در سازند شورپیجه و شبیه‌سازی این پارامتر در یکی از میداین گازی حوضه رسوبی کپه داغ است. در این مطالعه برای یافتن ارتباط بین پارامترهای ورودی شبکه با پارامتر هدف، با توجه به کراس پلات‌های مختلف لاگ‌ها و نتایج حاصل از ارزیابی پتروفیزیکی با تراوایی نمودارهای چاه‌پیمایی صوتی (DT)، نوترون (NPHI) و چگالی (RHOB) و نتایج حاصل از ارزیابی سازند شامل تخلخل مفید (PHIE) و اشباع آب موثر (SWE) به عنوان ورودی شبکه و پارامتر تراوایی هم به عنوان خروجی شبکه نتایج مطلوبی به دست می‌دهد. نتایج این پژوهش نشان می‌دهد که استفاده از شبکه عصبی پرسپترون چند لایه (شبکه پس انتشار خطا) در مرحله آزمایش شبکه می‌تواند تراوایی را در چاه‌های که از داده آن در آموزش شبکه استفاده نشده است را با دقت بسیار بالا (۹۸٪) تخمین بزند. این مقدار دقت بیان‌کننده توان بالای شبکه برای فهم ارتباط بین داده‌های ورودی و خروجی و همچنین اثبات دقت این شبکه برای محاسبه تراوایی در چاه‌های فاقد داده مغزه در میدان است. پس از تخمین تراوایی در چاه‌های مد

## مراجع

- [1]. Aminian K, Ameri S (2005) Application of artificial neural networks for reservoir characterization with limited data, *Journal of Petroleum Science and Engineering*, 49, 3-4: 212-222.
- [2]. No H A (2011) Estimation of spatial distribution of porosity by using neural networks method in one of oil fields in South of Iran, *Australian Journal of Basic and Applied Sciences*, 5, 8: 182-189.
- [3]. Luthi S (2001) *Geological well logs: Their use in reservoir modeling*, Springer Science and Business Media.
- [4]. Helle H B, Bhatt A, Ursin B (2001) Porosity and permeability prediction from wireline logs using artificial neural networks: a North Sea case study, *Geophysical Prospecting*, 49, 4: 431-444.
- [5]. Lim J S (2005): Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea, *Journal of Petroleum Science and Engineering*, 49, 3-4: 182-192.
- [6]. Kadkhodaie-Ilkhchi A, Rezaee M R, Rahimpour-Bonab H, Chehrazi A (2009) Petrophysical data prediction from seismic attributes using committee fuzzy inference system, *Computers and Geosciences*, 35, 12: 2314-2330.
- [7]. Kadkhodaie-Ilkhchi A, Amini A ((2009)) A fuzzy logic approach to estimating hydraulic flow units from well log data: A case study from the Ahwaz oilfield, South Iran, *Journal of Petroleum Geology*, 32, 1: 67-78.
- [8]. Kadkhodaie Ilkhchi A, Rezaee M, Moallemi S A (2006) A fuzzy logic approach for estimation of permeability and rock type from conventional well log data: an example from the Kangan reservoir in the Iran Offshore Gas Field, *Journal of Geophysics and Engineering*, 3, 4: 356-369.
- [9]. Mehraki M, Ashuri H, Shekiba sefat N, Ahremi Y (2010) Use of artificial neural network technique to estimate porosity and permeability in Asmari Formation The first national meeting and conference to review the

- achievements of earth scientists, Azad University, North Tehran Branch, Iran.
- [10]. Del Frate F, Salvatori L (2004) Oil spill detection by means of neural networks algorithms: a sensitivity analysis, In IGARSS IEEE International Geoscience and Remote Sensing Symposium, 2, 1370-1373.
- [11]. Afshar Harb A (1979) The stratigraphy, tectonics and petroleum geology of the Kopet Dag region, Northern Iran.
- [12]. Moussavi-Harami R (1990) Lithostratigraphy and depositional history of the Upper Jurassic (Oxfordian-Kimmeridgian) rocks in Col-e-Malkabad area in southwest of Ag-Darband (abs.)(in Persian): Geological Survey of Iran, In Eighth Geological Symposium of Iran, 6-8.
- [13]. Thomas J C, Cobbold P R, Shein V S, Le Douaran S (1999) Sedimentary record of late paleozoic to recent tectonism in central Asia—analysis of subsurface data from the Turan and south Kazak domains, Tectonophysics, 313, 3: 243-263.
- [14]. Golonka J (2004) Plate tectonic evolution of the southern margin of Eurasia in the Mesozoic and Cenozoic, Tectonophysics, 381, 1-4: 235-273.
- [15]. Golonka J (2004) Plate tectonic evolution of the southern margin of Eurasia in the Mesozoic and Cenozoic, Tectonophysics, 381, 1-4: 235-273.
- [16]. Moussavi Harami R, Brenner R L (1992) Geohistory analysis and petroleum reservoir characteristics of Lower Cretaceous (Neocomian) sandstones, eastern Kopet-Dagh Basin, northeastern Iran, AAPG Bulletin, 76, 8: 1200-1208.
- [17]. Moussavi Harami R, Brenner R L (1993) Diagenesis of non-marine petroleum reservoirs: The Neocomian (Lower Cretaceous) Shurijeh Formation, Kopet-Dagh Basin, NE Iran, Journal of Petroleum Geology, 16, 1: 55-72.
- [18]. Moussavi Harami R, Mahboubi A, Nadjafi M, Brenner R L, Mortazavi M (2009) Mechanism of calcrete formation in the Lower Cretaceous (Neocomian) fluvial deposits, northeastern Iran based on petrographic, geochemical data, Cretaceous Research, 30, 5: 1146-1156.
- [19]. Moradi M, Rahimpour Bonab H, Kadkhodaie A, Chehrazi A (2022) Analysis and distribution of Hydraulic flow unit and Electrofacies in the framework of sedimentary sequences in one of the gas fields in northeastern Iran, Journal of Petroleum Research, 32, 123: 3-18.
- [20]. Robert A M, Letouzey J, Kavooosi M A, Sherkati S, Müller C, Vergés J (2014) Structural evolution of the Kopet Dag fold-and-thrust belt (North-East Iran) and interactions with the South Caspian Sea Basin and Amu Darya Basin, In EGU General Assembly Conference Abstracts 6699.
- [21]. Afshar Harb A (1979) The stratigraphy, tectonics and petroleum geology of Kopet-Dagh region, Northern Iran. Unpublished PhD Thesis, Petroleum Geology Section, Imperial College, London, 316.
- [22]. Caers J (2000) Adding local accuracy to direct sequential simulation, Mathematical Geology, 32, 7: 815-850.
- [23]. Kiaei H, Sharghi Y, Ilkhchi A K, Naderi M (2015) 3D modeling of reservoir electrofacies using integration clustering and geostatistic method in central field of Persian Gulf, Journal of Petroleum Science and Engineering, 135: 152-160.
- [24]. Meulenkamp F, Alvarez Grima M (1999) Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness, International Journal of Rock Mechanics and Mining Sciences, 36, 1: 29-39.
- [25]. Nikraves M, Aminzadeh F (2001) Mining and fusion of petroleum data with fuzzy logic and neural network agents, Journal of Petroleum Science and Engineering, 29, 3-4: 221-238.
- [26]. Deutsch C V, Srinivasan S, Mo Y (1996) Geostatistical reservoir modeling accounting for precision and scale of seismic data, SPE Annual Technical Conference and Exhibition, OnePetro.
- [27]. Carr L A, Benteau R I, Corrigan M P, Van Doorne G G (1989) A complex reservoir characterized by three-dimensional seismic, geostatistical reservoir description, and sponge-core analysis, SPE Formation Evaluation, 4, 03: 335-342.
- [28]. Doyen P M (1988) Porosity from seismic data: A geostatistical approach, Geophysics, 53, 10: 1263-1275.
- [29]. Kelkar M, Perez G (2002) Applied geostatistics for reservoir characterization, Society of Petroleum Engineers.
- [30]. Diggle P J, Tawn J A, Moyeed R A (1998) Model-based geostatistics, Journal of the Royal Statistical Society: Series C, (Applied Statistics), 47, 3: 299-350.
- [31]. Bahar A, Kelkar M (2000) Journey from well logs/cores to integrated geological and petrophysical properties simulation: a methodology and application, SPE Reservoir Evaluation and Engineering, 3, 05: 444-456.
- [32]. Ortiz J, Deutsch C V (2002) Calculation of uncertainty in the variogram, Mathematical Geology, 34, 2: 169-183.
- [33]. Tammadge A (1972) Mathematics, A Human Endeavor, By Harold R. Jacobs. Pp. xvii, 529. £ 3· 50. 1970. (WH Freeman.), The Mathematical Gazette, 56, 396: 156-156.





# Permeability Estimation and its Simulation to Determine the Reservoir Characteristics of Shurijeh Formation in One of the Reservoirs of Northeast Iran

Milad Moradi<sup>1</sup>, Hossain Rahimpour-bonab<sup>1</sup> and Ali Kadkhodaie<sup>2\*</sup>

1. School of Geology, College of Science, University of Tehran, Iran

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

kadkhodaie\_ali@tabrizu.ac.ir

DOI:10.22078/PR.2022.4660.3094

Received: November/29/2021

Accepted: February/17/2022

## Introduction

Porosity and permeability are important parameters of the reservoir rock, the estimation of which plays a key role in the exploration of hydrocarbon fields and the prediction of subsequent drilling in the field. Therefore, the production performance of the reservoir can be increased through evaluating these parameters [1]. Various methods are used to estimate the amount of permeability, but the method using wireline well-logging charts and artificial neural networks is more popular due to its high accuracy, low cost (compared to the coring process) and simplicity. In simulation, accurate permeability estimation is necessary due to the process of recycling hydrocarbon reserves [2]. The data obtained from wireline well-logging charts is of great importance in the process of permeability estimation and simulation due to lower costs and consistency in charting rate and accessibility in most or all field wells [3-4]. The main purpose of this study is to estimate the permeability as the most important reservoir parameter with the help of artificial neural network and its modeling to determine the expansion and dispersion of the reservoir potential in the field. Based on the results of this model, reservoir zones are created from non-reservoir and apt zones for further excavations in the field.

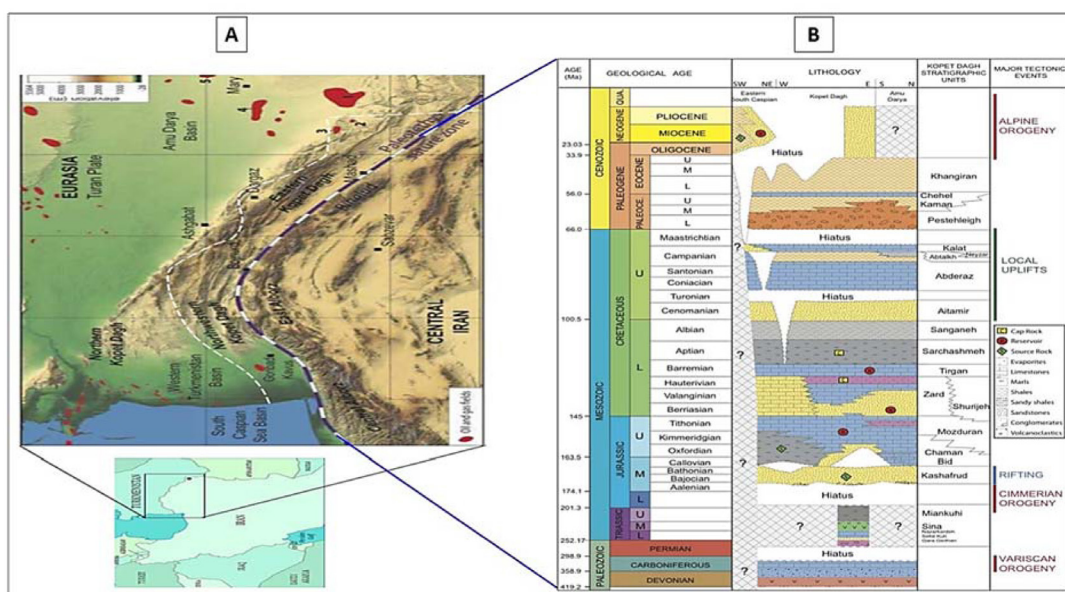
## Geological Setting

During the Late Jurassic-Early Cretaceous, a widespread regional regression took place in the Kopet-Dagh and red bed siliciclastics of the Shurijeh

Formations were deposited in nonmarine to delta and shallow marine environments [5-8]. The siliciclastic sandstone, siltstone and claystone grade into mixed siliciclastic sediments to the east. Lower Cretaceous siliciclastic rocks change gradually into conglomeratic lithofacies toward the south and southeast of the basin. From a stratigraphic view, it is composed of pebbly sandstone, sandstone, siltstone, claystone and shale with thin anhydrite interbeds in the Khangiran and Gonbadli fields, which pass southwards and southeastwards into conglomeratesandstone facies, as seen in Figure 1. The siliciclastic Shurijeh Formation was deposited in proximal braided rivers with gravely bed load in the lower part and sandstoneshale deposits in fluvial to shoreline and shallow marine environments in the upper part in the outcrop belt [9-11]. According to previous studies, this formation is divided into five reservoir zones, of which sand zones B and D are the main reservoir zones, and zones A, C, and E generally do not have suitable reservoir properties [12].

## Materials and Methods

In this study, to estimate and simulate permeability in the field, the data obtained from seven wells were examined. All the wells of interest have their wireline well-logging charts created, but the core analysis data of only three wells are available. In this study, to estimate the permeability, the relationship between each of the wireline well-logging charts and the permeability, based on the regression coefficient, was investigated.



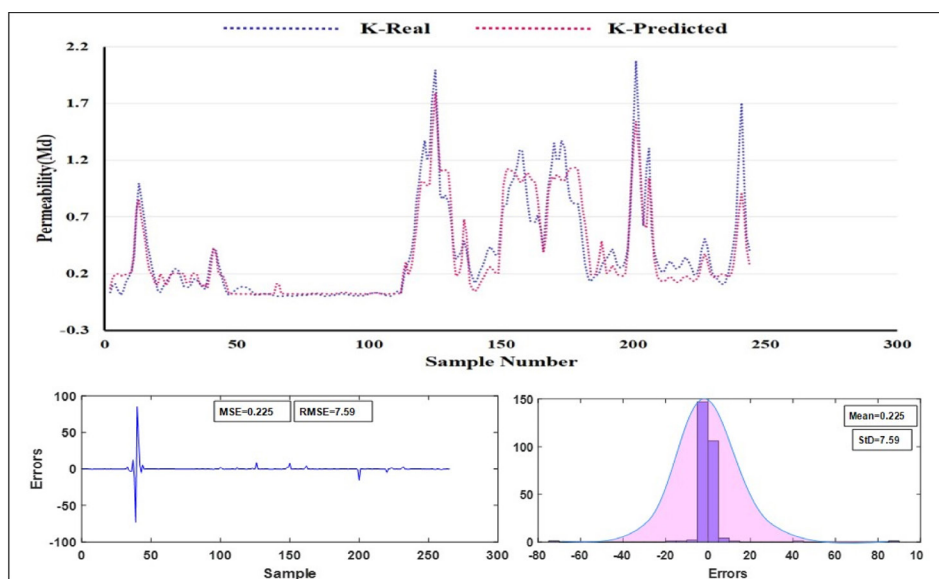
**Fig 1.** A: Location of the gas fields (red area). Major gas fields: 1: Daultabadi; 2: Gonbadly; 3: Khangiran; 4: Shalytk; 5: Bayram-Ali, White dash line: country boundary, B: Stratigraphic chart of Kopet-Dagh Basin [13].

Finally, neutron, density and sonic logs, useful porosity and water saturation obtained from the evaluation of the formation with the best regression coefficient and high correlation with permeability were selected to construct a multilayer perceptron neural network model. After ensuring the performance and accuracy of the neural network in the test well, permeability was estimated for wells without data. Then, in order to simulate permeability and determine the expansion and dispersion of reservoir zones from non-reservoir and areas prone to later drilling in the field, modeling was performed in Petrol software.


### Results and Discussion

After creating wireline well-logging charts bases on

permeability, the charts that had the highest correlation coefficient with permeability were selected based on the regression coefficient. Neutron, sonic and density wireline charts and the results of the formation evaluation including useful porosity and effective water saturation have been selected as inputs of the artificial neural network. After comparing the different algorithms available for network training, with least Mean squared errors (MSE), the “trainlm” algorithm was selected as the optimal method for all three categories of training, validation and testing. As shown in Figures 2 and 3, which show the actual permeability with neural network estimation, the test wells have up to 98% accuracy in the estimation.



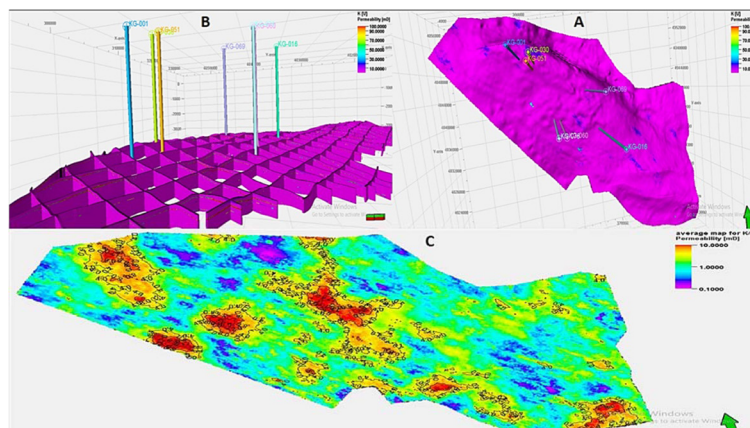
**Fig. 2** Comparison of measured core permeability and predicted values in test well (KG-001).



**Fig. 3** Plotting neural network construction inputs and comparing measured core permeability and predicted values against the depth of the test well (KG-001).

Due to the high accuracy of real and estimated permeability estimation, the correct operation of the network was proved with certainty. Finally, with the help of a neural network with the mentioned structure for other wells that did not have core analysis data, permeability was estimated to enter the construction of the simulation process as an input in the next step. In each study, simulation is necessary to determine the distribution and expansion of each reservoir parameter and to predict the location of subsequent drilling in the field. Therefore, in this study, after correctly estimating the permeability in all available wells, we constructed a three-dimensional model. Initially, construction

model and reservoir networking were done based on land statistics and after the process of magnification and data analysis with the help of Sequential Gaussian Simulation algorithm, the distribution and diffusion permeability in the whole field was determined. Based on this, high permeability is associated with predominantly high-energy sandstone zones B, D2, and D1, and low permeability is associated with low-energy environments. The distribution and expansion of permeability in Figure 4 show that the northwest and central part of the field have better reservoir quality due to higher permeability than the southern and northeastern part.



**Fig. 4** Permeability modeling results: A: Sequential Gaussian Simulation (SGS) for the whole Shurijeh Formation, B: Filtered Sequential Gaussian Simulation (SGS), C: Map of average permeability in the whole sequence of Shurijeh Formation.

## Conclusions

The main purpose of this study is to estimate the permeability with the help of artificial neural network in Shurijeh Formation and to simulate this parameter in one of the gas fields of Kopet Dagh sedimentary basin.

1- The results of this study show that the use of neural network in the network testing phase can estimate the permeability in wells whose data has not been used in network training with very high accuracy (98%). This accuracy expresses the network's ability to understand the relationship between input and output data, as well as proving the network's accuracy in calculating permeability in wells without core data.

2- Sequential Gaussian Simulation method as a random estimation method can simulate reservoir parameters (permeability) with great accuracy as well as understanding the distribution and three-dimensional expansion of this parameter in the distances between wells of Shurijeh Formation. The high amounts of permeability are mostly associated with the sandstone areas of the Shurijeh Formation, which are often concentrated in reservoir zones B, D2, and D1. Zones in which the ground bed is a mixture of shale, sand and carbonate are characterized by low permeability. Also, the distribution and dispersion of permeability in the field, indicates that the northwestern and central areas of the field are areas prone to further excavations in the field and the southern and eastern regions have less production potential due to lower average permeability than the northern and western regions.

## References

- Aminian K, Ameri S (2005) Application of artificial neural networks for reservoir characterization with limited data *Journal of Petroleum Science and Engineering*, 49, 3-4: 212-222.
- No HA (2011) Estimation of spatial distribution of porosity by using neural networks method in one of oil fields in South of Iran, *Australian Journal of Basic and Applied Sciences*, 5, 8: 182-189.
- Helle H. B, Bhatt A, Ursin B (2001) Porosity and permeability prediction from wireline logs using artificial neural networks: a North Sea case study, *Geophysical Prospecting*, 49, 4: 431-444.
- Lim J S (2005) Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea, *Journal of Petroleum Science and Engineering*, 49, 3-4: 182-192.
- Afshar Harb A (1979) The stratigraphy, tectonics and petroleum geology of the Kopet Dagh region, Northern Iran.
- Thomas J C, Cobbold P R, Shein V S, Le Douaran S (1999) Sedimentary record of late Paleozoic to Recent tectonism in central Asia—analysis of subsurface data from the Turan and south Kazak domains, *Tectonophysics*, 313, 3: 243-263.
- Golonka J (2004) Plate tectonic evolution of the southern margin of Eurasia in the Mesozoic and Cenozoic, *Tectonophysics*, 381, 1-4: 235-273.
- Brunet M F, Sobel E R, McCann T (2017) Geological evolution of Central Asian basins and the western Tien Shan range, *Geological Society, London, Special Publications*, 427, 1: 1-17.
- Moussavi Harami R, Brenner R L (1992) Geohistory analysis and petroleum reservoir characteristics of Lower Cretaceous (Neocomian) sandstones, eastern Kopet-Dagh Basin, northeastern Iran, *AAPG bulletin*, 76, 8: 1200-1208.
- Moussavi Haram, R, Brenner R L (1993) Diagenesis of non-marine petroleum reservoirs: The Neocomian (Lower Cretaceous) Shurijeh Formation, Kopet-Dagh Basin, NE Iran, *Journal of Petroleum Geology*, 16, 1: 55-72.
- Moussavi Harami R, Mahboubi A, Nadjafi M, Brenner R L, Mortazavi M (2009) Mechanism of calcrete formation in the Lower Cretaceous (Neocomian) fluvial deposits, northeastern Iran based on petrographic, geochemical data, *Cretaceous Research*, 30, 5: 1146-1156.
- Moradi M, Rahimpour Bonab H, Kadkhodaie A, Chehrazi A (2022) Analysis and distribution of hydraulic flow unit and electrofacies in the framework of sedimentary sequences in one of the gas fields in northeastern Iran, *Journal of Petroleum Research*, 32, 123: 3-18.
- Robert A M, Letouzey J, Kavooosi M A, Sherkati S, Müller C, Vergés J (2014) Structural evolution of the Kopet Dagh fold-and-thrust belt (North-East Iran) and interactions with the South Caspian Sea Basin and Amu Darya Basin, In *EGU general assembly conference abstracts*, 6699.