

تعیین نگرهای موثر بر نفوذپذیری مخازن نفتی و گازی با روش تحلیل آماری مقادیر RSE

مرتضی بیکی^{۱*}، حسین رحیم پور بناب^۲، غلامرضا حسین یار^۲، آتنا پیرایه گر^۱

^۱ دانشکده مهندسی معدن، پردیس دانشکده های فنی، دانشگاه تهران، تهران، ایران

^۲ دانشکده زمین شناسی، پردیس علوم، دانشگاه تهران، تهران، ایران

*مسئول مکاتبات - آدرس الکترونیکی: Morteza.beiki@gmail.com

(دریافت: ۸۷/۵/۵؛ پذیرش: ۸۸/۸/۲۸)

چکیده

نفوذپذیری از خواص بسیار مهم مخازن نفت و گاز می باشد و معمولاً با روش هایی نظیر آنالیز مغزه و تست چاه که روش های هزینه بری هستند، به دست می آید. استفاده از نگرهای ژئوفیزیکی، یکی از ابزارهای مهم جهت شناخت خواص پتروفیزیکی مخزن، نظیر نفوذپذیری و تخلخل می باشد. عموماً اغلب پارامترهای پتروفیزیکی به طور مستقیم با نگر مخصوصی در ارتباط اند. اما تراوایی مخزن به راحتی با نگر خاصی انطباق داده نمی شود. مهم ترین نگرها برای تعیین نفوذپذیری، نمودار صوتی، چگالی، نوترون، مقاومت ویژه، شاخص فتوالکتریک و پرتو گاما می باشند. اما طبیعی است که همه این نگرها به یک اندازه در تعیین نفوذپذیری نمی توانند دخیل باشند و احتمالاً بررسی همه نگرها ضروری نیست. به همین منظور، می توان با استفاده از تکنیک شبکه های عصبی مصنوعی، مرتبه تاثیر هر یک از نگرها را در تعیین نفوذپذیری مخزن تعیین کرد. همچنین با استفاده از روابط موجود در شبکه عصبی فاکتوری به نام دوام نسبی آثار (RSE) قابل محاسبه است که تاثیر هر پارامتر ورودی بر خروجی را نشان می دهد. با مطالعه RSE، می توان نتیجه گرفت که هر نگر سهم خاصی در تعیین نفوذپذیری سنگ مخزن دارد و برخی از آن ها در اغلب اوقات نقش کم رنگی را ایفا می کنند و لذا بهتر است که ابتدا به نگرهای تاثیرگذارتر توجه شود. در این راستا پس از آموزش شبکه عصبی مصنوعی، با داده های به دست آمده از نگرهای ژئوفیزیکی به عنوان ورودی و نفوذپذیری افقی و قائم به عنوان خروجی های شبکه، وزن های مربوط به بهینه ترین شبکه عصبی، ذخیره شد و سپس با کمک روابط موجود، تاثیر نسبی هر کدام از این نگرها بر نفوذپذیری تعیین و مقادیر RSE پارامترها ثبت گردید. این فرایند به دفعات انجام شد و نتایج به دست آمده به صورت درصد فراوانی مقدار RSE در بازه $[-1, +1]$ و به فواصل 0.1 محاسبه و به صورت نمودار میله ای رسم شدند. با مطالعه این نمودارها، مشاهده شد که برخی نگرها همچون نگرهای DT، RHO، NPHI و LLS نقش بیشتری در تعیین نفوذپذیری سنگ مخزن دارند.

واژه های کلیدی: نفوذپذیری، شبکه عصبی پس انتشار خطا، شاخص دوام نسبی آثار (RSE).

مقدمه

انجام این آزمایش، چندان مقرون به صرفه نیست. یکی از اهداف مطالعات پتروفیزیکی تخمین دقیق و صحیح نفوذپذیری در چاههایی است که اندازه گیری نفوذپذیری در آنها به هر دلیلی (نبود مغزه، وجود شکستگی در نمونه ها و...) ممکن نمی باشد. رسیدن به این هدف مشکل است، زیرا هیچ نگاری که بتواند مستقیماً نفوذپذیری را در یک چاه اندازه بگیرد، توسعه پیدا نکرده است (Pereira 2004). بنابراین در این میان، تعیین نگرهایی که بیشترین نقش را در تعیین نفوذپذیری دارا هستند، می تواند دارای اهمیت خاصی باشد. این کار به کمک روشی موسوم به دوام نسبی آثار RSE (Relative Strength of Effect)، امکان پذیر است.

استفاده از شبکه های عصبی، که نوعی شبیه سازی ساختار بیولوژیکی مغز انسان در قالب یک سیستم مصنوعی هستند، تکنیک

تعیین پارامتر نفوذپذیری در فرایندهایی چون تخمین ذخیره و توسعه مخازن نفتی از جایگاه ویژه ای برخوردار است. در حقیقت درک مقادیر صحیح نفوذپذیری به منزله ابزاری موثر، کارآمد و مهم برای مهندسی نفت در امر فرآیند تولید و مدیریت یک میدان می باشد. معمولاً صنعت نفت برای تعیین مقادیر صحیح نفوذپذیری از دو روش مستقیم (آنالیز مغزه و تست چاه) و یا غیرمستقیم (ارزیابی نگرهای ژئوفیزیکی) استفاده می کند. از آنجایی که برخی از محیط های زمین شناسی دارای پیچیدگی های خاص خود می باشند، برای تعیین هرچه دقیق تر نفوذپذیری باید از اکثر چاه ها مغزه تهیه کرد که چنین کاری مستلزم صرف هزینه و زمان فراوانی خواهد بود. همچنین تعیین این پارامتر به روش تست چاه، به علت صرف هزینه های گزاف و توقف تولید در حین

در این زمینه می‌باشد

۱- مبانی شبکه‌های عصبی مصنوعی

شبکه‌های عصبی به طور کلی سیستم‌های ریاضی غیرخطی هستند. طرز کار این شبکه‌ها از روش کار مغز انسان الگوبرداری شده است. یک شبکه عصبی برخلاف کامپیوترهای رقومی که نیازمند دستورات کاملاً صریح و مشخص است، به مدل‌های ریاضی محض نیازی ندارد، بلکه مانند مغز انسان قابلیت یادگیری به وسیله تعدادی مثال مشخص را دارد. در واقع شبکه‌های عصبی را می‌توان در حل مسائلی که روابط دقیق ریاضی بین ورودی‌ها و خروجی‌های آن برقرار نیست، به کار برد. این شبکه‌ها از عناصر ساده‌ای تشکیل شده‌اند که به طور موازی عمل می‌کنند و با الهام از شبکه‌های بیولوژیک، هر یک از این عناصر را نرون می‌نامند. آموزش شبکه‌های عصبی در واقع چیزی جز تنظیم وزن‌های ارتباطی این نرون‌ها به ازای دریافت مثال‌های مختلف نیست تا خروجی شبکه به سمت خروجی مطلوب همگرا شود.

۱-۱ شبکه عصبی پس انتشار خطا (Back Propagation Neural Network)

شبکه عصبی پس انتشار خطا در اصل یک شبکه عصبی پرسپترون چندلایه، (MLP)، است که از الگوریتم آموزش انتشار برگشتی یا انتشار معکوس خطا، (BPNN)، به عنوان ابزاری قدرتمند برای آموزش استفاده می‌کند. یک شبکه انتشار برگشتی، شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشد. شبکه به عنوان یک ابزار تغذیه رو به جلو در نظر گرفته می‌شود، زیرا بین خروجی یک جزء پردازش و ورودی یک گره در لایه‌های پیشین، هیچ‌گونه اتصال داخلی وجود ندارد (Rolon 2004).

آموزش این شبکه‌ها با نظارت بوده و در سه مرحله انجام می‌شود:

ارائه زوج‌های آموزشی به شبکه عصبی در نرون‌های ورودی-خروجی شبکه.

محاسبه خطای شبکه و انتشار رو به عقب خطا در شبکه.

اصلاح وزن‌ها در جهت کاهش خطا.

قانون پس‌انتشار خطا اساساً از دو مسیر اصلی تشکیل می‌شود. مسیر اول، موسوم به مسیر رفت می‌باشد که در این مسیر، بردار ورودی به شبکه اعمال می‌شود و تأثیراتش از طریق لایه‌های میانی به لایه خروجی انتشار می‌یابد و بردار نهایی در لایه خروجی حاصل می‌گردد (شکل ۱). در این مسیر پارامترهای شبکه ثابت و بدون تغییر در نظر گرفته می‌شوند. مسیر دوم، موسوم به مسیر برگشت می‌باشد. در این مسیر، برعکس مسیر رفت، پارامترهای شبکه تغییر یافته و تنظیم می‌گردند. بردار خطا برابر اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می‌باشد. مقدار خطا پس از محاسبه در مسیر برگشت از لایه خروجی و از طریق لایه‌های شبکه در کل شبکه توزیع می‌گردد و چون

نسبتاً جدیدی در صنعت نفت است که می‌تواند برای مسائل بهینه‌سازی، شناسایی الگوهای ذخیره‌سازی و بازیابی داده‌ها، فیلتر کردن ناهمگونی داده‌ها و موارد مشابه زیادی مورد استفاده قرار گیرد. این شبکه‌ها می‌توانند مسائل پایه‌ای مهندسی نفت را که محاسبات قدیمی قادر به حل آنها نیستند، حل نماید.

مطالعات زیادی در زمینه کاربرد شبکه‌های عصبی در صنعت نفت و گاز انجام شده است که در بین آنها می‌توان به موارد زیر اشاره نمود. پیش بینی نفوذپذیری به وسیله شبکه‌های عصبی مصنوعی (Chen & Lin 2005)، پیش بینی نگاره تخلخل با استفاده از داده‌های لرزه‌ای و شبکه‌های عصبی مصنوعی (Hampson et al 2000)، استفاده از شبکه عصبی برای کاهش هزینه موثر آنالیز نگارها در یک مقیاس ناحیه‌ای (Mohaghegh et al 1999)، استفاده از ویژگی‌های لرزه‌ای، نگارهای صوتی و دانسیته برای آموزش یک شبکه عصبی مصنوعی برای پیش بینی نگار اشعه گاما در ماسه‌های نفتی آتاباسکا در غرب کانادا به خاطر بدست آوردن خواص مخزن و همچنین برای انتخاب بهترین محل چاههای تزریقی و تولیدی برای یک برنامه تزریق (Tonn, 2002)، استفاده از روش شبکه عصبی و منطق فازی برای تعیین خواص مخزن از روی داده‌های چاه نگاری در یکی از سواحل کره جنوبی (Lim, 2005).


در این مطالعه، ابتدا، به کمک شبکه‌های عصبی، نفوذپذیری تخمین زده شد. به همین منظور شبکه پرسپترون چند لایه (MLP) با الگوریتم آموزشی انتشار برگشتی خطا، و یا به اختصار، شبکه پس انتشار خطا، تهیه و با داده‌های موجود مورد آموزش قرار گرفت و بهترین شبکه ذخیره گردید. وزن‌ها و بایاس‌های این شبکه برای محاسبه RSE مورد استفاده قرار گرفت. از آنجائی که در این بررسی از داده‌های منطقه پارس جنوبی استفاده می‌شود، ابتدا بحث مختصری در مورد زمین‌شناسی منطقه صورت می‌گیرد.

منطقه مورد مطالعه

مطالعه حاضر در میدان گازی پارس جنوبی صورت گرفته است که در این میدان بخش فوقانی سازند دالان و سازند کنگان با سن پرمین پسین-تریاس پیشین به عنوان سنگ مخزن این میدان محسوب می‌شوند. این سازندها از توالی‌های کربناته و تبخیری تشکیل شده است. طی سال‌های اخیر با تلاش شرکت ملی نفت ایران و شرکت نفت و گاز پارس مطالعات گسترده‌ای در زمینه اکتشاف و توسعه چاهها در این میدان صورت گرفته است. قرار گرفتن این میدان به عنوان بخشی از بزرگترین میدان گازی جهان اهمیت این مطالعات را به خوبی نشان می‌دهد. به طوری که بهره برداری بهینه و روز افزون از ذخیره این میدان مستلزم مطالعات بیشتر و استفاده از متدها و تکنولوژی پیشرفته

منجر به دستیابی به وزن‌های بهینه برای ورودی هر سلول شبکه عصبی می‌گردد که می‌توان توسط الگوریتم‌های مختلف آموزش آن را انجام داد. شبکه معمولاً بعد از چندین تکرار، الگوها را یاد می‌گیرد. هنگام آموزش شبکه، خطا در مجموعه آموزش بعد از هر تکراری کم می‌شود و در تکرارهای زیاد این مقدار خطا به کمترین مقدار ممکن می‌رسد. ممکن است که شبکه برای داده‌های جدید، خطای زیادی را تولید کند، که این مسئله ناشی از حفظ کردن الگوهای آموزشی توسط شبکه است که می‌تواند منجر به کاهش قابلیت تعمیم آن شود. از این مشکل به عنوان بیش‌برازش یاد می‌شود. برای حل این مشکل دو روش توقف سریع و روش منظم‌سازی وجود دارد.

در روش توقف سریع که در این مطالعه به کار گرفته شده است، شبکه توسط مجموعه داده‌های آموزشی، آموزش داده شده و خطای شبکه برای داده‌های آموزشی و ارزیابی به طور هم‌زمان مورد بررسی قرار می‌گیرد و با توجه به خطای داده‌های ارزیابی آموزش شبکه متوقف می‌گردد (شکل ۲). به عبارت دیگر، زمانی که خطا برای داده‌های ارزیابی افزایش می‌یابد (با وجود این که خطا برای داده‌های آموزشی کاهش می‌یابد)، در واقع شبکه شروع به از بر نمودن داده‌های آموزشی کرده است. این همان حالت بیش‌برازش است که در این زمان باید آموزش متوقف گردد و وزن‌ها و بایاس‌ها به مینیمم خطای اعتبارسنجی برگردانده شوند. در شکل ۲، خطای شبکه برای داده‌های آموزشی، ارزیابی و تست رسم شده است. همان‌طور که دیده می‌شود از تکرار ۲۹ به بعد علیرغم کاهش مقدار خطا در دسته داده‌های آموزشی، خطا در دسته ارزیابی ثابت است و آموزش شبکه متوقف می‌شود.

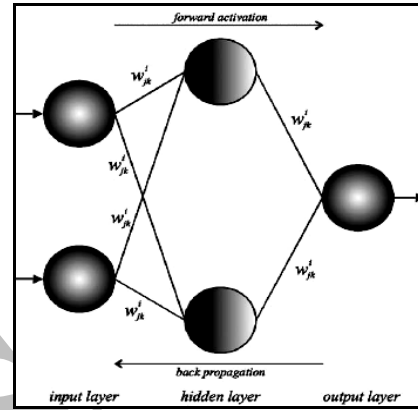


شکل ۲: منحنی مجموع مربعات خطا در مقابل تعداد تکرار الگوریتم برای داده‌های آموزش، اعتبارسنجی و تست.

۲. آماده سازی داده‌ها برای آموزش و تست شبکه

داده‌هایی که برای طراحی شبکه عصبی مورد استفاده قرار گرفت شامل نگاره‌های چاه (ورودی‌ها) و نفوذپذیری مغزه (خروجی) هستند. نگاره‌های ثبت شده در اکثر چاه‌های منطقه شامل، نگار صوتی (DT)،

این توزیع اخیر در خلاف مسیر ارتباطات وزنی سیناپس‌ها صورت می‌پذیرد، کلمه پس انتشار جهت توضیح رفتار شبکه به کار رفته است. به طور کلی می‌توان گفت که پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی شبکه، هر چه بیش‌تر به سمت پاسخ مطلوب، نزدیک شود.



شکل ۱: شبکه انتشار برگشتی ساده (Sonmez et al. 2005).

در حالت کلی در صورتی که p امین الگوی آموزشی برای لایه ورودی آماده می‌شود، ورودی شبکه که به z امین گره لایه مخفی وارد می‌شود به صورت زیر است:

$$net_{pi}^h = \sum_{i=1} w_{ji}^h x_i - \theta_{pj}^h \quad (1)$$

و خروجی‌های این گره و گره k در لایه خروجی به ترتیب عبارتند از:

$$\hat{o}_{pj}^h = f_j^h(net_{pj}^h) \quad (2)$$

$$net_{pk}^o = \sum_{j=1}^M w_{kj}^o \hat{o}_{pj}^h - \theta_{pk}^o \quad (3)$$

که در روابط بالا f_j^h و f_k^o توابع محرک z امین گره لایه مخفی و k امین گره لایه خروجی هستند. خطای بین خروجی حقیقی و خروجی شبکه و خروجی مطلوب به صورت زیر محاسبه می‌شود.

$$\delta_{pk} = t_{pk} - o_{pk} \quad (4)$$

و مقدار تصحیح وزن متصل به لایه خروجی که به شبکه اعمال می‌شود به صورت زیر محاسبه می‌گردد.


$$\Delta w(t) = -\alpha \frac{\partial E}{\partial w(t)} + \beta \Delta w(t-1) \quad (5)$$

که α نرخ آموزش و β فاکتور مومنتوم نامیده می‌شود (منهاج (۱۳۸) و (Demuth & Beale, 2002)).

۲-۱ آموزش شبکه‌های عصبی پس‌انتشار خطا

آموزش، فرآیندی است که با توجه به الگوهای ورودی و خروجی معلوم،

پنهان اول و تعداد ۴ نرون در لایه پنهان دوم و تابع محرک تانژانت سیگموئید در هر دو لایه، به عنوان بهترین شبکه انتخاب شد. برای نفوذپذیری قائم نیز شبکه‌ای با ۱۳ نرون در لایه پنهان اول و ۵ نرون در لایه پنهان دوم و تابع محرک تانژانت سیگموئید در هر دو لایه پنهان به عنوان شبکه بهینه در نظر گرفته شد. در شکل ۳، نمایی ساده از شبکه مورد استفاده جهت تخمین نفوذپذیری قائم نشان داده شده است.



شکل ۳: نمایی ساده از ساختار شبکه عصبی برای تخمین نفوذپذیری قائم.

ضریب همبستگی بین نفوذپذیری افقی و قائم پیش بینی شده و نفوذپذیری مغزه برای دو مجموعه داده آموزشی و تست محاسبه و در شکل‌های ۴ و ۵ نشان داده شده است. همان‌طور که در این شکل‌ها دیده می‌شود، هر کدام از این نمودارها دارای خط برازش شده‌ای بین پاسخ شبکه و داده‌های مغزه هستند. این خط دارای یک شیب و ضریب همبستگی است که پراکندگی داده‌ها را حول خط برازش شده نشان می‌دهند، هر چه مقدار ضریب همبستگی و شیب خط به عدد ۱ نزدیک باشند ($A=T$)، پراکندگی داده‌ها حول خط برازش کمتر و نشان از پیش بینی خوب می‌باشد. همبستگی بین داده‌های پیش بینی و داده‌های مغزه برای سه سری داده آموزش، اعتبار سنجی و تست و برای نفوذپذیری افقی به ترتیب برابر با ۰/۹۵۵ و ۰/۹۰۴ و برای نفوذپذیری قائم به ترتیب برابر با ۰/۹۶۴ و ۰/۹۲۸ است.

۴. تعیین میزان تاثیر نگارهای پتروفیزیکی بر نفوذپذیری با

روش RSE

در صورتی که پارامترهای ورودی به شبکه عصبی آموزش دیده، داده شود، شبکه قادر به محاسبه خروجی است. می‌توان با استفاده از روابط موجود در شبکه عصبی فاکتوری به نام دوام نسبی آثار (Relative Strength of Effect) را معرفی نمود که تاثیر نسبی پارامتر i در ورودی را بر پارامتر k در خروجی نشان دهد.

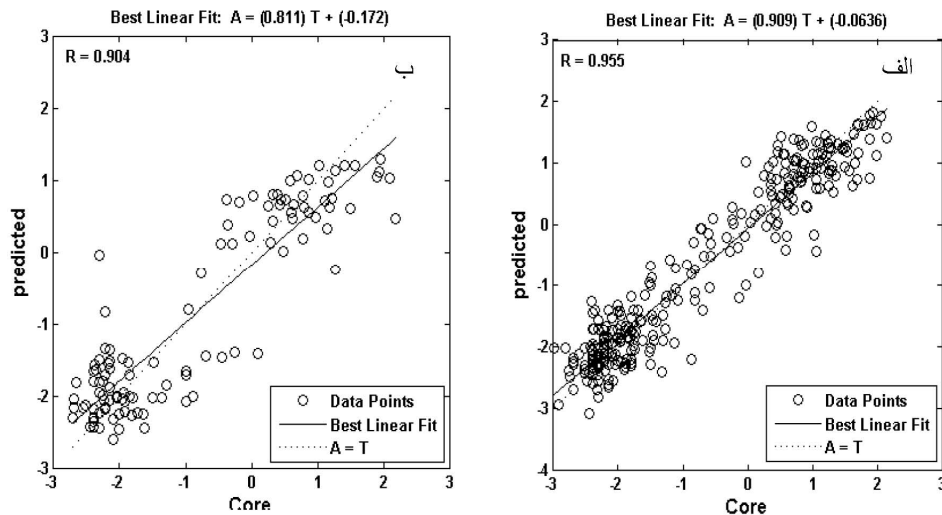
باید توجه داشت که مقدار RSE با توجه به خروجی شبکه تعیین

نگار گاما (GR)، نگار نوترون اصلاح شده (NPFI)، نگار چگالی (RHOB)، نگار مقاومت ویژه کروی میکرو (MSFL)، نگار مقاومت ویژه القایی عمیق (LLD)، نگار مقاومت ویژه القایی کم عمق (LLS)، نگار شاخص فتوالکتریک (PEF) و عمق (Depth) هستند. داده مغزه مد نظر در اینجا نفوذپذیری افقی (KH) و نفوذپذیری قائم (KV) است که برای شبکه از لگاریتم آن دو (LKH و LKV) استفاده می‌گردد.

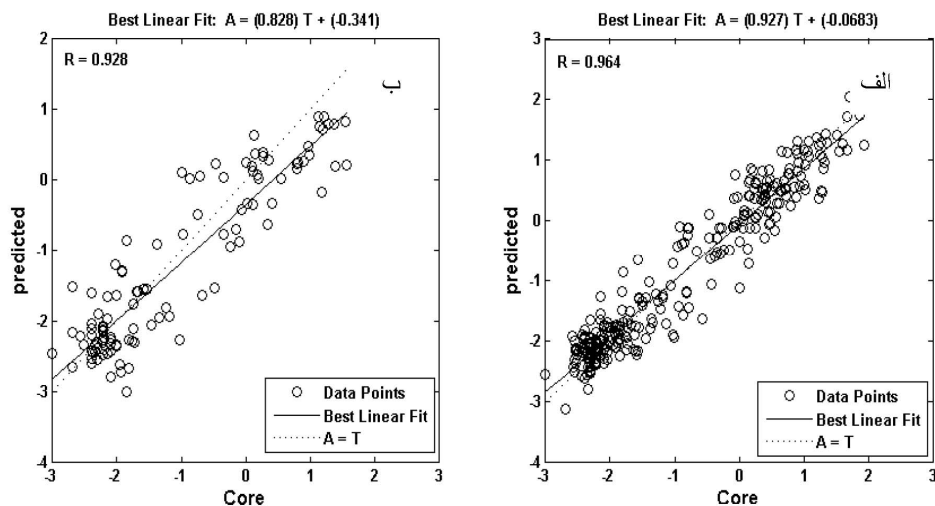
برای آموزش شبکه ابتدا داده‌ها را به دسته‌های آموزشی و ارزیابی و تست تقسیم نمود. معمولاً برای تقسیم‌بندی داده‌های کل دو روش وجود دارد. در روش اول به عنوان مثال داده‌های چند چاه به عنوان داده آموزش به کار می‌برند و داده‌های چاه دیگری به عنوان داده‌های تست شبکه استفاده می‌شود. در روش دوم کلیه داده‌ها با یکدیگر با هم ترکیب می‌شوند به طوری که شانس انتخاب هر داده یکسان باشد. در این مطالعه برای فایلهایی داده‌ها از روش دوم استفاده شده است. این امر سبب می‌شود تا تاثیر پارامترهای جغرافیایی و موقعیت چاه‌ها از روی داده‌ها حذف نشود و شبکه در هنگام آموزش با کلیه شرایط موجود در مخزن روبرو شده و آموزش ببیند تا قدرت تعمیم خود را حفظ کند. به همین منظور از مجموع داده‌های موجود برای کل چاههای مورد مطالعه، حدود ۵۰۰ داده که در آن هم نمودارهای پتروفیزیکی و هم آنالیز مغزه موجود بودند، به صورت جداگانه ذخیره شدند. از این مقدار داده، حدود ۶۰ درصد به صورت تصادفی به عنوان داده‌های آموزشی، حدود ۲۰ درصد به عنوان داده‌های تست و از بقیه به عنوان داده‌های ارزیابی (دو دسته داده اخیر، در داده‌های آموزش نبودند) انتخاب شدند. قبل از آموزش شبکه، داده‌ها در بازه [۰، ۱] نرمال شدند. یکی از دلایل نرمال سازی این است که توابع محرک (سیگموئیدی) بین مقادیر بزرگ نمی‌توانند تمایزی قائل شوند.

۳. طراحی شبکه عصبی به روش پس انتشار خطا

برای به دست آوردن شبکه پس انتشار بهینه، در روش توقف سریع، از توابع آموزش مختلف و تابع ارزیابی میانگین برای ارزیابی شبکه، از دو فاکتور ضریب همبستگی (R) و جذر میانگین مربعات خطا (RMSE) استفاده گردید. برای طراحی شبکه، توابع آموزش، توابع محرک، تعداد لایه‌ها و نرون‌های مختلف به دفعات و با ترکیب‌های متفاوت، به صورت سعی و خطا استفاده گردید. به این صورت که با تغییر این پارامترها نتایج مربوط به R و RMSE در هر بار آموزش ذخیره گردید. این کار برای هر دو خروجی شبکه یعنی نفوذپذیری افقی و قائم چندین بار انجام شد. در نهایت با توجه به ضرایب رگرسیون و جذر میانگین مربعات خطا بین مقادیر حاصل از آنالیز مغزه و مقادیر پیش بینی شده، شبکه نهایی برای هر خروجی، انتخاب گردید. برای نفوذپذیری افقی، شبکه‌ای با دو لایه پنهان با تعداد ۹ نرون در لایه



شکل ۴: الف) همبستگی بین نفوذپذیری افقی پیش‌بینی شده توسط شبکه و مقادیر به دست آمده از آنالیز مغزه در داده‌های آموزش، ب) همبستگی بین نفوذپذیری افقی پیش‌بینی شده توسط شبکه و مقادیر به دست آمده از آنالیز مغزه در داده‌های تست.



شکل ۵: الف) همبستگی بین نفوذپذیری قائم پیش‌بینی شده توسط شبکه و مقادیر به دست آمده از آنالیز مغزه در داده‌های آموزش، ب) همبستگی بین نفوذپذیری قائم پیش‌بینی شده توسط شبکه و مقادیر به دست آمده از آنالیز مغزه در داده‌های تست.

RSE این مراحل باید طی شود: (Yang & Zhang 1999)

الف- پارامترهای ورودی را وارد نموده و مقادیر z_e (خروجی حاصل از لایه‌های مخفی) و e_k (خروجی حاصل از لایه خروجی) محاسبه شود.

ب- مقادیر تابع G در لایه‌های میانی و خروجی محاسبه شود.

$$G(e_k) = \exp(e_k) / (1 + \exp(e_k))^2$$

$$G(e_j) = \exp(e_j) / (1 + \exp(e_j))^2$$

۶-

ج- RS را به عنوان یک متغیر موقت برای محاسبه RSE در نظر بگیرید. برای لایه خروجی:

$$RS(e_k) = G(e_k)$$

۷-

د- مقدار RS در لایه قبلی با رابطه زیر محاسبه شود:

می‌شود و با مشتق‌گیری ورودی‌ها نسبت به خروجی متفاوت است و نشان‌گر میزان تاثیرگذاری ورودی بر خروجی است. RSE ، فاکتوری پویا و دینامیکی است که با تغییرات پارامترهای ورودی مقدار آن تغییر می‌کند. این مسئله بسیار حائز اهمیت است چرا که بدین وسیله می‌توان ماحصل تأثیر پارامترهای مختلف برهم را سنجید و به پارامترهایی که بیشترین تأثیر را بر رفتار خروجی دارند، بیشتر توجه نمود. هرچه میزان قدرمطلق RSE بزرگتر باشد، تأثیر آن بر خروجی بیشتر است. علامت RSE نشان‌دهنده جهت تأثیر آن است به این معنی که $RSE > 0$ نشان‌دهنده تأثیر مثبت ورودی بر خروجی و $RSE < 0$ نشان‌دهنده تأثیر منفی ورودی بر خروجی است. برای محاسبه

اصلی ایجاد می‌کند که ترکیبی خطی از متغیرهای موجود در مسئله است (Larose, 2006). در واقع بوسیله تحلیل مؤلفه اصلی وابستگی خطی بین متغیرها پیدا می‌شود (Jackson, 1991). با استفاده از این تحلیل می‌توان در فضای چند بُعدی داده‌ها، جهاتی را یافت که در راستای این جهات، داده‌ها بیشترین واریانس را دارند (Jolliffe, 2002). بنابراین با تصویر کردن داده‌ها بر روی این جهات می‌توان ابعاد آن را کاهش داد بدون اینکه اطلاعات قابل توجهی حذف شود. به عبارت دیگر این تحلیل، داده‌ها را به یک سیستم مختصاتی یا فضای برداری مستقل تصویر می‌کند. تحلیل مؤلفه اصلی، فضایی تولید می‌کند که در آن داده‌ها براساس مقدار واریانس مرتب می‌شوند. داده‌هایی با بیشترین واریانس به بُعد اول منتقل شده و به همین ترتیب بقیه مرتب می‌شوند به گونه‌ای که آخرین مؤلفه اصلی کمترین واریانس را دارد. انتخاب تعداد مؤلفه اصلی یا ابعاد فضای جدید به اختلاف بیشترین و کمترین مقدار ویژه بستگی دارد. معمولاً نمودار درصد تجمعی مقادیر ویژه رسم می‌شود. این نمودار درصد واریانس کل داده را بر حسب تعداد مؤلفه انتخاب شده به کاربر می‌دهد. کاربر براساس حجم اطلاعات قابل پردازش و اختلاف واریانس تصمیم می‌گیرد که چه تعداد از بردارهای ویژه متناظر با مقادیر ویژه بالاتر انتخاب شود و کل داده‌ها روی آن تصویر شود.

اعمال تحلیل مؤلفه اصلی بر روی داده‌های نگاری

تحلیل مؤلفه اصلی برای داده‌های نگاری و نفوذپذیری مغزه، انجام شد. مقدار و درصد واریانس که به وسیله هر نمودار چاه پیمایی بیان می‌شود، در جدول ۲، آورده شده است.

جدول ۲: مقادیر واریانس و درصد واریانس توضیحی برای مؤلفه های اصلی.

Principal Component	Variances	Percent of variance explained (%)
1st	17.514	66.69
2nd	2.874	10.94
3rd	1.850	7.05
4th	1.156	4.40
5th	0.834	3.18
6th	0.731	2.78
7th	0.521	1.98
8th	0.454	1.73
9th	0.273	1.04
10th	0.055	0.21

بنابراین برای داده نگارهای موجود، این مؤلفه می‌تواند توصیف نسبتاً خوبی از خصوصیات مجموعه داده‌ها باشد. ضرایب برای مؤلفه‌های اصلی در جدول ۳، آورده شده است. با توجه به این که در مؤلفه اصلی اول، قدرمطلق بزرگترین ضرایب، مربوط به نمودارهای DT، RHOB و

$$RS(e_{j_n}) = G(e_{j_n}) W_{j_n k} RS(e_k) \quad -8$$

۵- مقدار RS در دیگر لایه‌های مخفی را با این رابطه محاسبه نمائید:

$$RS(e_{j_{n-1}}) = G(e_{j_{n-1}}) \sum W_{j_{n-1} j_n} RS(e_{j_n}) \quad -9$$

به این ترتیب مقادیر RS تا اولین لایه مخفی پیدا خواهد شد.

۶- مقدار RS_{ki} با این معادله محاسبه شود:

$$RS_{ki} = \sum W_{ij_i} RS(e_{j_i}) \quad -10$$

۷- با فرض این که تعداد پارامترهای ورودی P است، لذا:

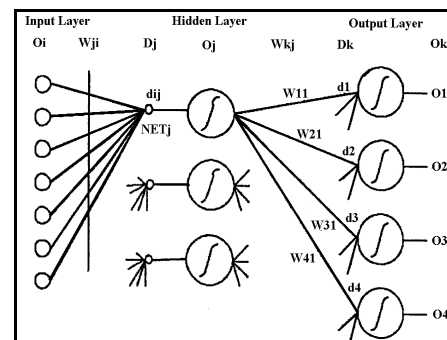
$$RS_{kx} = \max \{ |RS_{k1}|, |RS_{k2}|, \dots, |RS_{kp}| \} \quad -11$$

حال می‌توان مقدار RSE را برای هر ورودی به دست آورد:

$$RSE_{ki} = RS_{ki} / RS_{kx} \quad -12$$

مقدار RSE را می‌توان توسط مراحل فوق تعیین کرد که تاثیر نسبی متغیر i بر متغیر k اشاره دارد. از این رو برای یافتن متغیرهای ورودی کلیدی از میان همه متغیرهای ورودی باید مقایسه‌ای میان مقادیر RSE آن‌ها صورت پذیرد (شکل ۶).

به منظور تایید نتایج حاصل از آنالیز RSE و اثبات صحت و سقم این روش در ادامه تحلیل مؤلفه اصلی (PCA) نیز بر روی داده‌های نگاری انجام می‌گیرد.



شکل ۶: شبکه عصبی مصنوعی و اجزای آن (Yang & Zhang, 1999).

تحلیل مؤلفه اصلی (PCA)

تحلیل مؤلفه اصلی یک روش آماری برای کاهش بُعد داده‌هاست (Kendall, 1975; Gurney, 1997). در این روش یک مجموعه داده اولیه (که به وسیله نمونه‌های برداری ارائه شده است) به یک مجموعه جدید از نمونه‌های برداری با ابعاد مشتق شده تبدیل شود. ایده اصلی این روش می‌تواند به این صورت بیان شود که یک مجموعه از نمونه‌های برداری n بعدی باید به مجموعه‌ای دیگر با ابعاد مشابه تبدیل شود، ولی، این ویژگی را دارد که بیشتر اطلاعات در چند بعد اول ذخیره شده است.

تحلیل مؤلفه اصلی، یک سری پارامترهای جدید، به نام مؤلفه‌های

جدول ۳: ضرایب محاسبه شده برای مولفه های اصلی.

Petrologs	Principal Component									
	1st	2nd	3rd	4th	5th	6th	7th	8th	9th	10th
GR	0.028	0.016	0.214	-0.751	-0.067	0.500	-0.122	0.345	-0.02	-0.005
DT	0.578	-0.154	-0.158	0.255	0.112	0.062	0.069	0.541	-0.487	0.031
RHOB	-0.584	0.474	0.055	0.095	0.019	0.008	0.007	0.156	-0.63	0.027
NPHI	0.513	0.721	0.046	-0.138	0.275	-0.014	-0.028	-0.341	-0.026	0.041
PEF	0.112	-0.384	-0.035	-0.198	-0.155	0.079	-0.156	-0.632	-0.584	0.072
MSFL	-0.091	0.031	-0.270	0.393	0.178	0.816	-0.140	-0.163	0.113	-0.082
LLD	-0.046	0.057	-0.666	-0.280	0.017	-0.154	0.001	0.019	-0.040	-0.668
LLS	-0.103	0.027	-0.624	-0.213	0.076	-0.057	0.020	0.050	0.074	0.733
Kh	0.118	0.208	-0.093	0.155	-0.606	-0.074	-0.721	0.114	0.064	0.038
Kv	0.115	0.190	-0.092	0.041	-0.692	0.203	0.645	-0.072	0.007	0.017

نمودارها، مشاهده می شود که هر پارامتر سهم خاصی بر رفتار توده سنگ دارد و بعضی از پارامترها در هر حالتی تاثیر بسیار کمی دارند. لذا بهتر است در تحلیل های آنالیز برگشتی ابتدا به پارامترهای موثرتر دقت شود.

نتیجه گیری

مقادیر RSE مربوط به پارامتر عمق (Depth)

تخلخل و تراوایی رسوبات کربناته معمولاً پس از رسوبگذاری تحت تاثیر فشار روباره (افزایش عمق تدفین) در اعماق کم بشدت کاهش می یابد؛ ولی تقریباً در اعماق بیشتر از ۱ km افزایش عمق تاثیر چندانی بر روی کیفیت مخزنی سنگ های کربناته (همانند مخزن مورد مطالعه) نمی گذارد.

همان گونه که در شکل ۸، دیده می شود مقادیر درصد فراوانی تاثیر نسبی پارامتر عمق بر نفوذپذیری افقی، در بیش از ۷۵ درصد موارد در بازه [۰، ۰/۳] قرار دارد که نشان دهنده تاثیر ضعیف این پارامتر بر نفوذپذیری افقی است. همچنین برای نفوذپذیری قائم در حدود ۶۰ درصد موارد در بازه [۰، ۰/۳] و ۲۵ درصد موارد در بازه [۰/۴، ۰/۶] قرار دارد که نشان دهنده تاثیر ضعیف تا متوسط آن بر نفوذپذیری قائم است.

مقادیر RSE مربوط به نگار پرتوگاما (GR)

نگار گاما با مقدار شیل موجود در رخساره ها در ارتباط است و با افزایش آن، نگار گاما افزایش نشان داده و در نتیجه تخلخل و تراوایی در این ناحیه از توالی کاهش می یابد. در توالی مخزن مورد مطالعه مقدار شیل بسیار کم بوده و بطور مقطعی در برخی از چاه ها حضور دارد. که شکل ۹ نیز همین امر را نشان می دهد؛ با توجه به این شکل می توان این گونه بیان کرد که مقادیر درصد فراوانی تاثیر نسبی نگار پرتو گاما (GR)، بر نفوذپذیری افقی در حدود ۷۵ درصد و برای نفوذپذیری قائم بیش از ۶۰ درصد موارد در بازه [۰، ۰/۳] قرار دارد که نشان دهنده تاثیر ضعیف این پارامتر بر نفوذپذیری است. همچنین با توجه به این که مقدار RSE در اغلب موارد منفی است می توان به اثر

NPHI قدرمطلق بزرگترین ضرایب را به خود اختصاص داده اند، در نتیجه می توان گفت که این ضرایب بیشترین سهم را در تخمین نفوذپذیری این مخزن ایفا می کنند. همانگونه که مشاهده می شود این نتایج به نوعی اثبات کننده تحلیل ارائه شده در این تحقیق می باشد.

۱- تحلیل میزان تاثیر نمودارهای چاه پیمایی بر نفوذپذیری با روش RSE

تعیین میزان اثرگذاری نمودارهای چاه پیمایی بر روی نفوذپذیری بسیار حائز اهمیت است. با شناخت جهت و میزان تاثیر این پارامترها، حل این مسائل بسیار ساده و سریع تر انجام می شود. این کار با شبکه های عصبی به راحتی قابل انجام است. بدین صورت که شبکه با تعداد لایه ها و تعداد نرون های مختلف آموزش داده می شود. از آنجایی که به دست آوردن شبکه ای که کمترین مقدار خطا را دارد با سعی و خطا به دست می آید هر شبکه چندین بار آموزش یافته و شبکه ای که بهترین نتایج را داشته، ذخیره شده است. پس از آن اوزان و بایاس های مربوط به شبکه عصبی بهینه استخراج گردید. با کمک اوزان و بایاس های استخراج شده و نیز روابط ۶ تا ۱۲، می توان مقدار تاثیر نسبی (RSE) هر ورودی بر خروجی شبکه را تعیین کرد. در شکل ۷، مقادیر RSE محاسبه شده مربوط به هر نگار پتروفیزیکی را بر خروجی های شبکه (نفوذپذیری افقی و قائم) برای شش نمونه تصادفی نشان داده شده است.

۲- تحلیل آماری مقادیر RSE

با استفاده از مقادیر RSE، می توان تاثیر نسبی هر پارامتر بر خروجی شبکه را در هر حالت دلخواه به دست آورد. اما با این مقادیر روند کلی تاثیر نسبی هر پارامتر بر خروجی را در حالات مختلف نمی توان بررسی نمود. لذا برای بررسی تاثیر هر پارامتر بر خروجی، پارامترهای ورودی شبکه به صورت اتفاقی انتخاب شد و مقادیر RSE پارامترها ثبت گردید. این فرایند به دفعات و برای تمام داده های موجود، انجام شد و نتایج به دست آمده به صورت درصد فراوانی مقدار RSE در بازه [۰، +۱]، [۰، -۱] و به فواصل ۰/۱ محاسبه شد و اعداد به دست آمده به صورت نمودار میله ای که در ادامه آمده است، رسم شد. با مطالعه این

این نگار بر نفوذپذیری اشاره کرد. تاثیر متوسط این نگار با توجه به وجود تخلخل ثانویه در مخزن قابل توجه می باشد.


مقادیر RSE مربوط به نگار چگالی (RHOB)

سیمان انیدرتی در میدان پارس جنوبی از مهمترین فرایندهای دیاژنزی است که باعث کاهش کیفیت مخزنی شده است. افزایش انیدریت سبب افزایش مقدار نگار چگالی می شود که این موضوع در مقادیر RSE نیز دیده می شود. با توجه به شکل ۱۱، برای نفوذپذیری افقی و قائم به


کاهش نگار GR بر نفوذپذیری نیز اشاره کرد.

مقادیر RSE مربوط به نگار صوتی (DT)

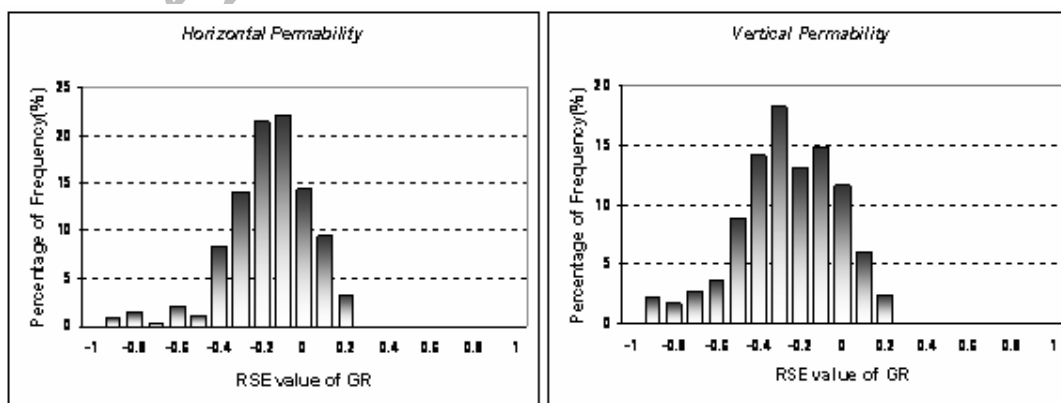
نگار صوتی تخلخل زمینه سنگ را اندازه گیری می کند ولی تخلخل حاصل از فرایندهای پس از رسوبگذاری (فرایندهای دیاژنزی) را نشان نمی دهد. برای نگار صوتی نیز مقادیر درصد فراوانی تاثیر نسبی، برای نفوذپذیری افقی و قائم به ترتیب حدود ۶۵ و ۴۵ درصد موارد در بازه [۰/۴، ۰/۷] قرار دارد (شکل ۱۰) که نشان دهنده اثر افزایشی متوسط



شکل ۷: مقادیر RSE به دست آمده از شبکه عصبی مصنوعی مربوط به هر نگار پتروفیزیکی برای شش نمونه تصادفی.



شکل ۸: نمودار میله‌ای درصد فراوانی مقادیر RSE مربوط به پارامتر عمق، و تاثیر آن بر روی نفوذپذیری افقی و قائم.




شکل ۹: نمودار میله‌ای درصد فراوانی مقادیر RSE مربوط به پارامتر GR، و تاثیر آن بر روی نفوذپذیری افقی و قائم.

و همان طور که در شکل ۱۲، دیده می شود در حدود ۸۵ درصد موارد، مقادیر درصد فراوانی تاثیر نسبی، برای نفوذپذیری افقی و برای نفوذپذیری قائم بیش از ۶۰ درصد، در بازه $[0.8, 1]$ قرار دارد که نشان دهنده تاثیر افزایشی بسیار قوی نگار نوترون اصلاح شده بر نفوذپذیری می باشد. در واقع این گونه می توان بیان کرد این نگار بیشترین اثر افزایشی را در بین نگارهای موجود برای تخمین نفوذپذیری دارد.

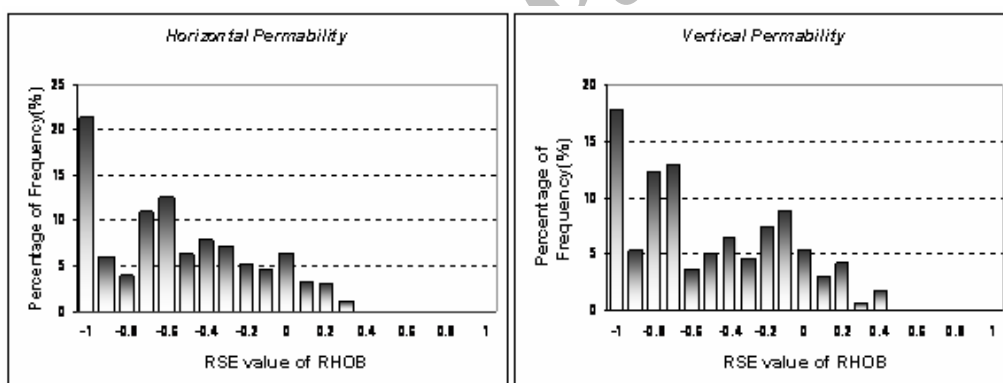
ترتیب ۷۰ و ۶۰ درصد موارد مقادیر درصد فراوانی تاثیر نسبی، در بازه $[-1, -0.4]$ قرار دارد که نشان از تاثیر متوسط تا قوی نگار چگالی بر نفوذپذیری افقی است. اثر این نگار در اکثر قریب به اتفاق موارد کاهش می یابد. شایان ذکر است که نگار RHOB در بین تمام نگارهای موجود بیشترین اثر کاهش می دهد.

مقادیر RSE مربوط به نگار نوترون اصلاح شده (NPHI)


نگار NPHI تخلخل کل سنگ (تخلخل اولیه و ثانویه) را نشان می دهد



شکل ۱۰: نمودار میله ای درصد فراوانی مقادیر RSE مربوط به پارامتر DT، و تاثیر آن بر روی نفوذپذیری افقی و قائم.



شکل ۱۱: نمودار میله ای درصد فراوانی مقادیر RSE مربوط به پارامتر RHOB، و تاثیر آن بر روی نفوذپذیری افقی و قائم.



شکل ۱۲: نمودار میله ای درصد فراوانی مقادیر RSE مربوط به پارامتر NPHI و تاثیر آن بر روی نفوذپذیری افقی و قائم.

مقاومت مربوط به اعماق میانی را اندازه گیری می نماید. نحوه قرارگیری نگارهای مقاومت بیان کننده حضور هیدروکربن یا آب و یا نبود اینها در سنگ می باشد. نگار LLD در بین تمام نگارها دارای کمترین مقدار تاثیر نسبی می باشد. همان طور که در شکل ۱۵، دیده می شود برای نفوذپذیری افقی حدود ۷۵ درصد موارد مقدار RSE برابر ۰/۱ است. برای نفوذپذیری قائم نیز در حدود ۹۰ درصد موارد مقدار RSE در بازه $[-0/1, 0/1]$ است. این مقادیر نشان از تاثیر بسیار ضعیف این پارامتر بر نفوذپذیری می باشد.

مقادیر RSE مربوط به نگار مقاومت ویژه القایی کم عمق (LLS)
با توجه به شکل ۱۶ می توان به وضوح دید که در بیش از ۷۰ درصد موارد مقدار RSE برای نفوذپذیری افقی و ۶۵ درصد موارد برای نفوذپذیری قائم، مربوط به نگار مقاومت کم عمق، در بازه $[0/5, 1]$ است، که مبین اثر افزایشی متوسط تا قوی این نگار در تعیین نفوذپذیری است.

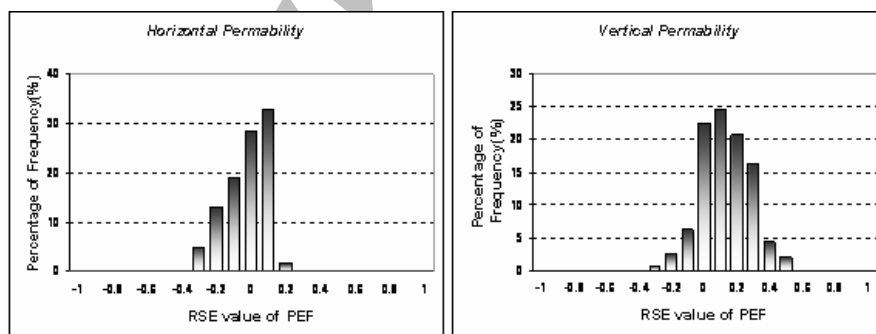
با توجه به نمودارهای میله ای رسم شده در شکل های ۸ تا ۱۶، می توان گفت که نگارهای RHOB، NPFI، DT و LLS موثرترین نگارهای پتروفیزیکی برای تعیین نفوذپذیری هستند. در این بین نگار RHOB دارای اثر کاهشی و سه نگار دیگر اثری افزایشی بر روی نفوذپذیری هستند. به این ترتیب برای تعیین نفوذپذیری، مطالعه تمامی نگارها ضرورتی ندارد، زیرا همان طور که مشاهده شد برخی نگارها در هر حال تاثیر بسیار کمی بر نفوذپذیری دارند.

مقادیر RSE مربوط به نگار شاخص فوتوالکتریک (PEF)

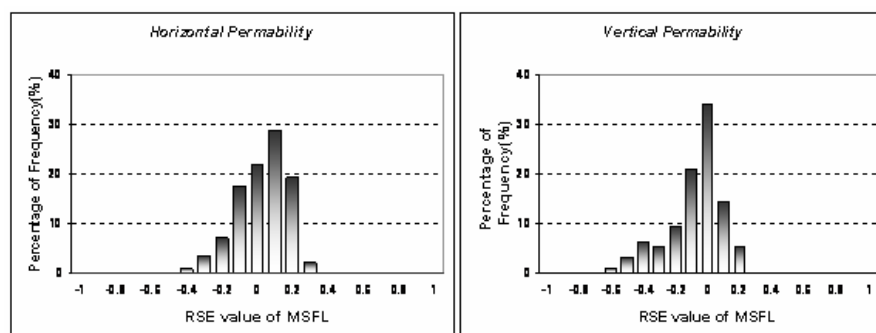
با توجه به شکل ۱۳، همان گونه که دیده می شود برای نفوذپذیری افقی در حدود ۸۰ درصد موارد، مقادیر تاثیر نسبی در بازه $[-0/1, 0/1]$ قرار دارد که نشان دهنده تاثیر بسیار ضعیف این پارامتر بر نفوذپذیری افقی است. برای نفوذپذیری قائم نیز حدود ۸۵ درصد موارد در بازه $[0, 0/3]$ قرار دارد که می توان به تاثیر نسبتاً ضعیف نگار شاخص فوتوالکتریک بر نفوذپذیری قائم پی برد. تاثیر ضعیف نگار فوتوالکتریک بدلیل یکنواختی نسبی لیتولوژی توالی مخزنی است که عمدتاً از نوع دولومیتی بوده و در برخی قسمت های توالی از نوع آهکی است.

مقادیر RSE مربوط به نگار مقاومت ویژه کروی میکرو (MSFL)
نگار مقاومت ویژه کروی میکرو، مقاومت ناحیه نفوذ گل را اندازه گیری می کند و تاثیر چندانی در میزان تخلخل و تراوایی ندارد. مقدار درصد فراوانی تاثیر نسبی، برای نفوذپذیری افقی، در حدود ۷۰ درصد در بازه $[0, 0/2]$ قرار دارد. برای نفوذپذیری قائم نیز در ۵۵ درصد موارد، مقدار RSE در همین بازه قرار دارد (شکل ۱۴) که نشان دهنده تاثیر بسیار ضعیف این نگار بر میزان نفوذپذیری پی برد. همچنین اثر نگار MSFL بر نفوذپذیری در حدود نیمی از موارد افزایشی و برای نیم دیگر کاهشی است.


مقادیر RSE مربوط به نگار مقاومت ویژه القایی عمیق (LLD)
همانگونه که ذکر شد نگار MSFL مقاومت ناحیه کم عمق را اندازه گیری می کند در حالی که نگار LLD مقاومت عمیق و نگار LLS




شکل ۱۳: نمودار میله ای درصد فراوانی مقادیر RSE مربوط به پارامتر PEF و تاثیر آن بر روی نفوذپذیری افقی و قائم.



شکل ۱۴: نمودار میله ای درصد فراوانی مقادیر RSE مربوط به پارامتر MSFL و تاثیر آن بر روی نفوذپذیری افقی و قائم.



شکل ۱۵: نمودار میله‌ای درصد فراوانی مقادیر RSE مربوط به پارامتر LLD و تاثیر آن بر روی نفوذپذیری افقی و قائم.



شکل ۱۶: نمودار میله‌ای درصد فراوانی مقادیر RSE مربوط به پارامتر LLS و تاثیر آن بر روی نفوذپذیری افقی و قائم.

منابع:

منهاج م. ب. ۱۳۸۱: میانی شبکه‌های عصبی (جلد اول و دوم). مرکز نشر دانشگاه صنعتی امیرکبیر.

- Chen C., Lin Z. 2005: A committee machine with empirical formulas for permeability prediction. Elsevier Science Publications, Vol.32: 485-496.
- Demuth H., Beale M. 2002: Neural Network Toolbox for Use with MATLAB. User's Guide. Version 4.
- Gurney K., 1997, An introduction to neural networks, UCL Press.
- Hampson D.P., Schuelke J.S., Quirein J.A. 2001: Use of multiattribute transforms to predict log properties from seismic data. Geophysics. 66: 220-236.
- Jackson J.E., 1991: A user's guide to principal components, John Wiley and Sons Inc.
- Jolliffe I.T., 2002: Principal component analysis, 2nd edition, Springer.
- Kendall M., 1975: Multivariate analysis, Charles Griffin.
- Larose D.T., 2006: Data mining methods and models, John Wiley and Sons Inc.
- Lim J., 2005: Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea. Journal of Petroleum Science and Engineering, Elsevier Science Publications. 49:182-192.
- Mohaghegh S., Popa, A., Koperina, G. 1999: Reducing the Cost of Field-Scale Log Analysis Using Virtual Intelligence Techniques", SPE 57454, Proceedings, SPE Eastern Regional Conference, Charleston, WV.
- Pereira J., 2004: Permeability prediction from well log data using multiple regression analysis. M.Sc. Thesis. West Virginia.
- Rolon L. 2004: Developing Intelligent Synthetic Logs: Application to Upper Devonian Units in PA.M.Sc thesis. Morgantown. West Virginia University.
- Sonmez H. *et al.*, 2005: Estimation of rock modulus: For intact rocks with an artificial neural network and for rock masses with a new empirical equation. Int. J. of Rock Mechanics & Mining Sciences. 43: 224-235.
- Tonn T., 2002: Neural network seismic reservoir characterization in a heavy oil reservoir. The Leading Edge. Vol. 21. No.3: 309-312.
- Yang Y., Zhang Q. 1999: The Application of Neural Network to Rock Engineering System (RES). Int. J. of Rock Mechanics & Mining Sciences. 35: 727-745.