

# تخمین لیتولوژی سنگ مخزن به کمک داده های چاه نگاری با استفاده از شبکه عصبی

## مصنوعی

محمد امین دزفولیان<sup>۱</sup>، دکتر مجید نبی بید هندی<sup>۲</sup> و دکتر محمود معماریانی<sup>۳</sup>

### چکیده

تعیین لیتولوژی سنگ مخزن توسط روش های معمول شامل آزمایش های مغزه و چاه آزمایشی صورت می پذیرد. متأسفانه، مغزه گیری از هر چاه در میدان های بزرگ نفتی مانند میدان های نفتی ایران، بسیار هزینه بر است. هر چند به علت اطلاعات بسیار ارزشمندی که لیتولوژی در اختیار ما قرار می دهد، ضروری است که با وجود گران بودن، از تعدادی از چاه های مخزن، مغزه گیری صورت گیرد.

هدف این تحقیق، پیش بینی لیتولوژی سنگ مخزن هیدروکربوری در میدان پارس جنوبی با به کارگیری تکنیک شبکه عصبی مصنوعی با الگوریتم پس انتشار خطا (BP) و الگوریتم آموزشی Trainlm با استفاده از نرم افزار Matlab از روی داده های نگارهای اشعه گاما، چگالی، نوترون، صوتی و اثر فتوالکتریک (PEF) می باشد. از این روش می توان هزینه های مربوط به شناسایی مشخصات مخزن و لیتولوژی سنگ مخزن را از طریق کم نمودن احتیاج به عملیات مغزه گیری با توجه به هزینه های بالای آن کاهش داد. قسمت مورد بررسی دارای سه لیتولوژی عمده می باشد که عبارتند از: دولومیت، شیل و انیدریت، که در صد حجمی هر یک به طور مجزا تخمین زده شده است و رگرسیون (Regression) به دست آمده هر یک به ترتیب عبارت است از: ۰.۸۷ و ۰.۷۶ و ۰.۹۰ که حاکی از قابل قبول بودن نتایج حاصله و تفکیک نسبتاً خوب آن ها از یکدیگر می باشد.

کلید واژه ها: مخزن هیدروکربوری، شبکه عصبی مصنوعی، لیتولوژی، مغزه، نگار چاه.

## Estimation of reservoir lithology based on log data using artificial neural network method

Mohammad Amin Dezfoolian, Dr Majid Nabi-Bidhendi and Dr Mahmood Memariani

### Abstract

We use core analysis and well testing to determinate the reservoir lithology. Unfortunately, coring from each wells in large oil fields such as Iran oil fields, is very expensive. However, because of the importance of this information which is obtained from lithology, it is necessary to coring from some of the reservoir wells.

Purpose of this study is prediction of hydrocarbon reservoir lithology in South Pars field using artificial neural network with back propagation error algorithm (BP) and Trainlm algorithm with Matlab software from wire-line logs including gamma ray, density, neutron, sonic and photoelectric (PE). This method can reduce requirement of coring and reduce the

<sup>۱</sup> دانشجوی کارشناسی ارشد مهندسی اکتشاف نفت دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران dezfoolian@rocketmail.com

<sup>۲</sup> دانشیار مؤسسه ژئوفیزیک دانشگاه تهران

<sup>۳</sup> استادیار پژوهشگاه صنعت نفت

costs. The area we have studied, consist of three lithologies, including Dolomite, shale and Anhydrite. The regression between the predicted and the real values of volume concentrations of Dolomite, shale and Anhydrite are obtained respectively, as 0.87, 0.76 and 0.90. The results show that the neural network gives a reasonable estimation for lithology.

**Keywords:** hydrocarbon reservoir, artificial neural network, lithology, core, well log.

#### مقدمه:

افزار صورت گرفته است (Borsaru et al., 2006). این تحقیق بر روی کاربرد شبکه های عصبی برای مسائل شناخت الگو برای زمین شناسی و لیتولوژی در یکی از مخازن میدان پارس جنوبی با استفاده از داده های حاصل از چاه در مواردی که مغزه گیری انجام نشده بحث می کند. در این جا در صد حجمی هر یک از لیتولوژی های سنگ مخزن که عبارتند از: دولومیت، شیل و انیدریت، به وسیله شبکه عصبی و الگوریتم پس انتشارخطا (BP) با استفاده از نگارهای اشعه گاما، چگالی، نوترون، صوتی و اثر فتوالکتریک (PEF) تخمین زده شده که در اشکال جدا گانه با مقدار واقعی مقایسه گردیده است. ضریب همبستگی هر یک نیز به دست آمده که نشان از آن دارد که شبکه ی عصبی پس انتشار خطا (BPNN)، توانایی تخمین لیتولوژی با استفاده از داده های حاصل از نمودارهای چاه را دارد. تغییرات حجم انیدریت، دولومیت و شیل در خروجی شبکه با داده های مغزه مقایسه شده که به ترتیب در اشکال ۳، ۵ و ۷ قابل مشاهده می باشند.

#### شبکه های عصبی مصنوعی


یکی از الهاماتی که در مورد شبکه های عصبی از مغز انسان گرفته شده است این است که مغز برای محاسبات خود از ساختاری کاملاً مغایر با ساختار کامپیوترها استفاده می کند. بدین معنی که مغز از یک سری عناصر اصلی به نام نرون (Neuron) تشکیل یافته است که عملکرد این نرون ها و پاسخ آنها به صورت جمعی بستگی به ذخیره سازی و حفظ اطلاعات در تک تک نرون ها و نحوه ارتباط بین آنها دارد (منهاج، ۱۳۸۴).

با نگرشی بر فرآیندهای مهندسی نفت، مشخص می گردد که در بسیاری از مراحل تولید از ابتدا تا فرآوری چاه ها، بواسطه تحت کنترل داشتن شرایط فرآیندی، اطلاعاتی که ماحصل از آنالیزهای مواد مختلف و سیستمهای کنترلی موجود در خط فرایند در دوره های زمانی مختلف و در مکان های خاص می باشد، توسط متخصصین اتخاذ می شود (Mohaghegh et al., 2004). تحقیقات نشان می دهد که در بسیاری از مراکز تحقیقاتی دنیا این اطلاعات بر اساس موضوع مورد تحقیق، دسته بندی شده و با برقراری ارتباط بین آنها جهت آموزش شبکه های عصبی مورد استفاده قرار می گیرند. با هوشمند کردن شبکه نرم افزاری، استفاده از آن در موارد مشابهی که دسترسی به این اطلاعات به دلایلی مقدور نبوده و یا بسیار مشکل می باشد نتایج قابل قبول و دقیقی حاصل می گردد که بسیاری از مشکلات پیش روی متخصصین را از میان برمی دارد (Daboisa et al., 2007).

با گسترش علوم کامپیوتری و نرم افزارهای شبیه سازی در بخشهای مختلف مهندسی، نگرش متخصصین به این بخش هر روز فزونی گرفته تا آنجایی که در حال حاضر می توان گفت نرم افزارهای تخصصی در هر گرایش مهندسی، یکی از ابزارهای مهم به شمار می آید. در این بین استفاده از نرم افزار شبکه های عصبی هوشمند که علمی جدید و نوپا محسوب می شود با داشتن قابلیت های خاص و مهم جایگاه ویژه ای را برای بسیاری از فرایندهای مهندسی به خود اختصاص داده است. از جمله در مهندسی نفت که یکی از شاخه های مهم و بزرگ علمی و صنعتی در دنیا می باشد، در بخش تحقیقات و مطالعات، کاربردهای زیادی در سراسر دنیا از این نرم

## ساختارهای شبکه عصبی مصنوعی (Architectures of ANN)

در شکل ۱ مدل یا شبیه سازی شده یک نرون ارائه شده است. این نرون دارای ورودی  $p$  و خروجی  $a$  است. یک مقدار ثابت تحت عنوان بایاس (Bias) هم استفاده شده است که در کلیه استفاده ها این مقدار، یک فرض می شود.



مقادیر  $w$  و  $b$  که به ترتیب پارامتر وزن و پارامتر بایاس نام دارند دو پارامتر قابل تنظیم این نرون هستند که به ترتیب در ورودی و مقدار بایاس ضرب می شوند و مجموع آنها به صورت ورودی تابع  $f$  که تابع فعال سازی (Activation Function) نرون است تلقی می شود (منهاج، ۱۳۸۴).

عملکرد اساسی یک نرون مصنوعی شامل دریافت یک سیگنال ورودی وزن دار شده و اعمال یک تابع فعال سازی بر روی آن است، که یک نتیجه بصورت بردار خروجی تولید می کند تا به لایه بعدی انتقال یابد (غضنفری، ۱۳۸۳ و مهدی زاده، ۱۳۸۳)

### الگوریتم پس انتشار (Back Propagation) BP

در الگوریتم BP دو مسیر محاسباتی موجود است. مسیر اول، پیشخور یا رفت و مسیر دوم، پسخور یا برگشت نامیده می شود.

۱- مسیر رفت، این مسیر با معادلات زیر بیان می شود:

$$\underline{a} = \underline{p}(k) \quad (1)$$

(۲)

$$\underline{a}^{l+1}(k) = \underline{F}^{l+1}(W^{l+1}(k)\underline{a}^l + \underline{b}^{l+1}(k)), l = 0, 1, \dots, L-1$$

$$\underline{a}(k) = \underline{a}^L(k) \quad (3)$$

در این مسیر همان گونه که می بینیم پارامترهای شبکه در خلال اجرای محاسبات رفت تغییر نمی کنند و توابع محرک، روی تک تک نرونها عمل می کند، یعنی:

(۴)

$$\underline{F}^{l+1}(\underline{n}(k)) = [f^{l+1}(n_1(k)) \dots f^{l+1}(n_{s_{l+1}}(k))]^T$$

۲- مسیر برگشت که در این مسیر بردارهای حساسیت از لایه آخر به لایه اول برگشت داده می شوند. معادلات زیر دینامیک مسیر برگشت را بیان می کنند:

$$\underline{\delta}^L(k) = -2F^L(\underline{n})\underline{e}(k) \quad (5)$$

(۶)

$$\underline{\delta}^1(k) = F^1(\underline{n})(W^{1+1})^T \underline{\delta}^{1+1}, l = L-1, \dots, 1$$

$$\underline{e}(k) = \underline{t}(k) - \underline{a}(k) \quad (7)$$

به عبارت دیگر در مسیر برگشت، شروع کار از لایه آخر، لایه خروجی است. جایی که بردار خطا در اختیار می باشد. سپس بردار خطا از سمت راست به چپ از لایه آخر به لایه اول توزیع می شود و گرادیدان محلی، نرون با الگوریتم بازگشتی محاسبه می شود. در این مسیر هم پارامترهای شبکه تغییر نخواهند کرد.

۳- تنظیم پارامترها که نهایتاً ماتریس های وزن و بردارهای بایاس شبکه MLP با روابط زیر تنظیم می گردند:

(۸)

$$W^l(k+1) = W^l(k) - \alpha \underline{\delta}(k) (\underline{a}^{l-1}(k))^T$$

(۹)

$$\underline{b}^l(k+1) = \underline{b}^l(k) - \alpha \underline{\delta}^l(k), l = 1, 2, \dots, L$$

توجه داریم که پس از اعمال هر زوج ورودی - خروجی به عنوان الگوی یادگیری، بردارهای ورودی (الگوهای ورودی) در خلال سه مرحله فوق تغییر

وزن هایی با درجه پایین تر می شود. لذا یک سری نرمال سازی روی داده ها انجام می شود. در نرمال سازی سعی می شود که داده ها در یک بازه نزدیک به صفر (مثلاً بین +۱ تا -۱) و انحراف معیار استاندارد نزدیک به یک، توزیع شوند (Dubois et al., 2007). در این مطالعه داده ها در بازه (۰ و ۱) نرمال سازی شده اند.

تکنیک دیگری که در آموزش شبکه به ویژه در مواردی که داده های محدودی در اختیار است، می تواند مفید باشد، تکنیک جابجایی (Shuffling) است (Chang et al., 2002). در این تکنیک پس از آنکه آموزش شبکه با همه توضیحاتی که داده شد انجام شد، از وزنه های حاصل به عنوان وزنه های اولیه دور دوم آموزش شبکه استفاده می شود و در عین حال در این دور جدید آموزش، جای داده های آزمون و تأیید عوض می شوند. یعنی داده های تأیید قبلی به عنوان داده های آموزش جدید و داده های آموزش قبلی به جای داده های تأیید فعلی استفاده می شود.

### آموزش شبکه

آموزش شبکه به صورت با ناظر (Supervised Training) می باشد. در این آموزش یکسری بردار به عنوان ورودی به همراه مقدار یا مقادیر خروجی مطلوب در اختیار شبکه گذاشته می شود تا به وسیله یک الگوریتم آموزش (Training Algorithm) مقادیر ضرائب وزن، تنظیم شوند (غضنفری، ۱۳۸۳).

شبکه می بایست هم در پیش بینی مقادیری که در آموزش به کار برده شده است و هم در پیش بینی مقادیری که در آموزش استفاده نشده است، موفق عمل نماید. لذا داده ها به سه دسته تقسیم می شوند:

۱- داده های آموزش (Training Data)

۲- داده های تأیید (Validation Data)

۳- داده های آزمون (Test Data)

از داده های آموزش برای تعیین وزن ها استفاده می شود. داده های تأیید اگر چه در حین آموزش

نمی کنند. به همین دلیل شماره مرحله تکرار  $k$  عملاً با اعمال  $k$  امین الگو به شبکه معادل است.

۴- توقف که جهت توقف تکرار الگوریتم، از شاخص زیر می توان استفاده نمود:

میانگین مربعات خطا در هر سیکل یا جمع مربعات خطا برای تمامی الگوهای یادگیری، کمتر از مقدار از پیش تعیین شده ای باشد که مد نظر بوده و یا این که گرادینان خطا از یک مقدار از پیش تعیین شده ای کوچکتر گردد (منهاج، ۱۳۸۴).

### انتخاب و آماده سازی داده ها برای آموزش شبکه عصبی

داده های نگارهای صوتی، چگالی و اشعه گاما و نوترون و اثر فتوالکتریک به همراه آنالیز و توصیف مغزه (Core Description) مربوط به سازند مخزنی تهیه گردید.

بدون شک یکی از مهمترین بخش های مربوط به ایجاد و توسعه شبکه های عصبی، انتخاب داده ها است. نخستین مسأله بررسی صحت داده های انتخاب شده براساس گزارش ها می باشد. در صورتی که در گزارشات مربوط به مغزه، قید شده باشد که شرایط گرفتن مغزه غیراستاندارد بوده است و تغییرات ثانویه ای حین عملیات مغزه گیری و انتقال ایجاد شده است (مثلاً شکستگی مغزه حین عملیات) داده ی مربوطه کنار گذاشته می شود. ممکن است به دلایلی مانند ریزش دیواره چاه، در قسمت هایی از چاه، یکی یا تعدادی از نگارها را نداشته باشیم که این داده ها نیز حذف می شوند (Borsaru et al., 2006, Nikravesh, 2004).

این داده ها که برای آموزش شبکه عصبی انتخاب می شوند را مستقیماً نمی توان مورد استفاده قرار داد. چرا که این کار فرایند آموزش را مشکل تر می کند و کارایی شبکه را کاهش می دهد و از طرفی از آن جا که درجه پارامترهای شبکه یکسان نمی باشد یعنی تغییرات جزئی در وزنی با بالاتر باعث تغییرات چشم گیری در

حال می توان شبکه آموزش دیده را برای پیش بینی لیتولوژی در چاه هایی که مغزه گیری انجام نشده است و یا قسمت هایی از چاه که بنا به هر دلیلی فاقد مغزه است به کار برد.

هر یک از الگوهای ورودی به شبکه بصورت زوج الگوی ورودی- خروجی می باشند. به عبارت دیگر، قرائتهای مربوط به نگارهای اشعه گاما، نوترون، چگالی، صوتی و اثر فتوالکتریک به عنوان داده های ورودی خام و درصد کانی شناختی و لیتولوژی به دست آمده از مغزه ها به عنوان خروجی مطلوب به طور هم زمان وارد شبکه می شود (Briqueu et al., 2002).

لایه ورودی دارای پنج نرون و لایه خروجی دارای سه نرون می باشد.

شبکه با یک لایه مخفی برای تقریب توابع کافیست، اندازه لایه مخفی، به عبارتی روشنتر، تعداد نرون های مخفی، سوال اساسی است که عموماً مطرح می شود. برای شبکه لیتولوژی، در ابتدا تعداد پنج نرون برای لایه میانی در نظر گرفته شد و با افزایش تعداد آنها تا پنجاه نرون و بررسی روند الگوریتم توقف در هر مرحله، حالت بهینه سی و پنج نرون برای لایه میانی انتخاب گردید. بطور کلی تعداد بیشتر الگوها و تعداد کمتر نرون های لایه میانی برای شبکه بهتر است. تعداد خیلی کم الگوها و تعداد خیلی زیاد نرون های میانی باعث می شود که شبکه به حالت از بر کردن (Memorize) دست یابد. یعنی شبکه در طول آموزش خوب کار می کند ولی در مرحله آزمون بد کار می کند. به هر حال، تعداد لایه های میانی بیشتر بهتر از تعداد کم آنها نیست.

### ارائه و تحلیل نتایج

فرآیند یادگیری به این صورت انجام می گیرد که ابتدا حدس اولیه ای برای اوزان و مقادیر بایاس شبکه انجام می گیرد. سپس با استفاده از یک قانون یادگیری این مقادیر تصحیح می شوند و آن قدر این دفعات تکرار ادامه می یابند که اوزان و بایاس ها ثابت شوند و یا اختلاف آنها

مورد استفاده قرار می گیرند، اما در تعیین وزن ها نقش مستقیمی ندارند. وظیفه داده های تأیید اینست که بر قابلیت تعمیم (Generalization) شبکه به موازات آموزش شبکه نظارت داشته باشد (مهدی زاده، ۱۳۸۳).

بعد از آنکه همه داده های آموزش یک دور کامل به شبکه ارائه شدند، با استفاده از وزن های حاصل، داده های تأیید وارد شبکه شده و مقادیر مربوط لیتولوژی محاسبه می شوند. مقادیر لیتولوژی محاسبه شده توسط شبکه هم برای داده های آموزش و هم برای داده های تأیید با مقادیر اصلی مقایسه شده و مقادیر خطای داده های آموزش و تأیید محاسبه می شوند. این خطاها (خطای داده های آموزش و تأیید) بعد از هر دور کامل ارائه داده های آموزش به شبکه مجدداً محاسبه می شود. مشاهده می شود که از یک مرحله به بعد خطای داده های تأیید رو به افزایش می گذارد. این بدان معناست که شبکه قدرت تعمیم خود را رفته رفته از دست می دهد و در واقع به حفظ کردن داده های آموزشی می پردازد، بدون آنکه قادر به دریافت ارتباط صحیح بین داده های ورودی و خروجی باشد. لذا بعد از آنکه شبکه بعد از یک سری دفعات متوالی خطای تأیید بیشتری تولید نمود، فرآیند آموزش می بایست متوقف شود و وزن های مربوط به کمترین خطای تأیید، به عنوان بهترین نتیجه مربوط به آموزش در نظر گرفته شود. در صورتی که میزان خطاها مطلوب نباشد، دور جدیدی از آموزش بایستی آغاز شود. پس از آنکه خطای مربوط به داده های آموزشی و داده های تأیید به میزان مطلوب رسید، از داده های آزمون که هیچ گونه استفاده ای تا این مرحله از کار از آنها به عمل نیامده است، برای سنجیدن نهایی قابلیت تعمیم شبکه استفاده می شود. این دسته داده به شبکه آموزش دیده (که ضرایب وزن مطلوب آن تعیین شده است) وارد می شوند و خروجی آنها محاسبه شده و با مقادیر اصلی مقایسه می شود. خطای حاصله (خطای داده های آزمون) در صورتی که میزان مطلوبی داشته باشد کار به اتمام رسیده است.

گردیده است. تغییرات حجم انیدریت، دولومیت و شیل در خروجی شبکه با داده های مغزه مقایسه شده که به ترتیب در اشکال ۳، ۵ و ۷ قابل مشاهده می باشند.

مدل ابتدا برای یکی از چاه های مخزن که دارای آنالیز مغزه بود طراحی شد و سپس در یکی دیگر از چاه های مخزن که آن هم دارای داده های آنالیز مغزه بود و داده های آن در ساخت مدل سهمی نداشت، آزمایش شد و پس از حصول اطمینان از کارایی مدل، جهت تخمین لیتولوژی در یک چاه دیگر مخزن مورد استفاده قرار گرفت.

پس از اجرای کد نوشته شده به زبان MATLAB و با در نظر گرفتن روش ها و موارد ذکر شده در قسمت های قبلی، نتایج به دست آمده به شرح زیر می باشند:

خطای داده های آموزش برای شبکه مذکور ۰.۲٪ بوده که می توان در شکل ۲ روند سیکل های (Epoch) طی شده تا رسیدن به شبکه مطلوب رامشاهده نمود.


شکل ۳ بیانگر مقایسه بین حجم انیدریت تخمین زده شده نسبت به داده های حاصل از مغزه می باشد که بر حسب عمق ترسیم شده است شکل ۴ ضریب رگرسیون (R) بین خروجی های شبکه و خروجی مطلوب (آنالیز مغزه) برای انیدریت را نشان می دهد. شکل ۵ مقایسه تخمین با واقعیت برای دولومیت است که شکل ۶ ضریب همبستگی آن می باشد در اشکال ۷ و ۸ نیز می توان نتایج را برای حجم شیل مشاهده نمود.

در دفعات به حداقل برسد. اگر شبکه مناسبی طراحی کرده باشیم (از نظر ساختار) و قانون یادگیری مناسبی هم انتخاب کرده باشیم و حدس اولیه خوبی هم از طرف رایانه به صورت اتفاقی زده شده باشد، می توان گفت که حتماً در کمتر از ۱۰۰ دفعه تکرار (در بسیاری از موارد حتی کمتر از ۵۰ دفعه تکرار) به جواب خواهیم رسید (Zhou et al., 2000, Dubois et al., 2007). در غیر این صورت، در انتهای هر مرحله که تعداد دفعات تکرار در فرآیند یادگیری به ۱۰۰ می رسد نتیجه نمایش داده خواهد شد.


تابع عملکرد انتخاب شده (MSE Mean square error) می باشد که میانگین مربعات خطاها برای داده های آموزشی می باشد. شبکه دارای یک لایه میانی سی و پنج نرونه می باشد که تابع تبدیل آن Tansig می باشد. شبکه دارای یک لایه خروجی سه نرونه با تابع تبدیل خطی یا Purelin است.

برای آموزش شبکه از تابع Trainlm استفاده شده است زیرا خطای الگوریتم LM با سرعت بیشتری نسبت به سایر الگوریتم ها کاهش می یابد.


منطقه مورد مطالعه سازند دشتک و کنگان (بخش فوقانی) از بخش فارس می باشد که خصوصیات لیتولوژی آن عمدتاً دولومیت، شیل، انیدریت و آهک می باشد. درصد حجمی هریک از آن ها توسط مغزه به دست آمده است، لازم به ذکر است که قسمت تخمین زده شده دارای آهک بسیار کمی بوده که از محاسبات حذف




شکل ۲- منحنی تغییرات میانگین مربعات خطا در برابر تعداد سیکل انجام شده



شکل ۳- مقایسه تغییرات حجم انیدریت در خروجی شبکه با خروجی واقعی نسبت به عمق




شکل ۴- نمودار رگرسیون حجم انیدریت بین خروجی واقعی با خروجی شبکه




شکل ۵- مقایسه تغییرات حجم دولومیت در خروجی شبکه با خروجی واقعی نسبت به عمق






شکل ۶- نمودار رگرسیون حجم دولومیت بین خروجی واقعی با خروجی شبکه



شکل ۷- مقایسه تغییرات حجم شیل در خروجی شبکه با خروجی واقعی نسبت به عمق



شکل ۸- نمودار رگرسیون حجم انیدریت بین خروجی واقعی با خروجی شبکه

فرآیند آموزش شبکه عصبی به عواملی چون تعداد نرون ها در هر لایه، تعداد لایه ها و توابع مورد استفاده و قوانین یادگیری مورد استفاده بستگی دارد و بایستی بسیار خوش شانس باشیم که شبکه عصبی در اولین طراحی پاسخ مناسبی بدهد چرا که هیچ نوع فرمول یا قانون مشخصی برای تعیین بهترین طراحی بسته به نوع کاربرد وجود ندارد و طراحی مناسب فقط بر پایه سعی و خطا استوار است. به زبان بهتر طراحی، یک فرآیند تجربی است.

نمودارهای اشعه گاما، چگالی، نوترون، صوتی و اثر فتوالکترونیک مهمترین پارامترها جهت تخمین لیتولوژی تشخیص داده شدند.

مدل، ابتدا در یکی از چاه های مخزن که دارای داده های آنالیز مغزه بود و داده های آن در ساخت مدل سهمی نداشت، آزمایش شد و پس از حصول اطمینان از کارایی مدل، جهت تخمین لیتولوژی در چاه دیگر مخزن مورد استفاده قرار گرفت.

## نتیجه گیری

این تحقیق نشان می دهد که شبکه ی عصبی پس انتشار خطا (BPNN)، توانایی تخمین لیتولوژی با استفاده از داده های حاصل از نمودارهای چاه را دارد. این طرح همچنین با ملزومات عملیاتی و واقعی نیز همخوانی دارد. چرا که در همه چاهها، لاگ گرفته می شود و همانطور که پیش تر نیز ذکر شد در تعداد معدودی از چاه ها مغزه گیری انجام می گیرد و یا اینکه ممکن است به دلایلی در قسمت هایی از چاه مغزه نداشته باشیم و یا تخریب شده باشد. لذا با در اختیار داشتن شبکه آموزش دیده مطلوب، می توان به تخمین لیتولوژی در چاه هایی که صرفاً لاگ دارند اقدام نمود و لیتولوژی آن چاه و یا قسمت های فاقد مغزه را شبیه سازی نمود. در نتیجه در هر چاه تخمینی از لیتولوژی حاصل می شود که با استفاده از این مقادیر می توان مدل بهتر و قابل اطمینان تری برای مخزن جهت شبیه سازی فراهم نمود.

- T., 2006. Automated lithology prediction from PGNA and other geophysical logs. Applied Radiation and Isotopes.
- Briquieu, L., Gottlib-Zeh, S., Ramadan, M., and Brulhet, J., 2002. Inferring lithology from downhole measurements using an unsupervised self-organising neural network: study of the Marcoule silty clayish Unit. C. R. Geoscience.
- Chang, H., Kopaska, C., and Chen, H., 2002. Identification of lithofacies using Kohonen self-organizing maps. Computers & Geosciences.
- Dubois, K., Geoffrey, C., and Bohling, S., 2007. Comparison of four approaches to a rock facies classification problem. Computers & Geosciences.
- Mohaghegh, S.D., Chevron, A., Gaskari, R., and Siegfried, R., 2004. Determining In-Situ Stress Profiles From Logs. SPE
- Zhou, Z.H., Chen, Z.Q., and Chen, S., 2000. Neural Networks Based Lithology Identification. Proceedings of the International Conference on Intelligent Information Processing

## قدردانی

با سپاس فراوان از جناب آقایان مهندس صدقی پور، مهندس فرخ شاد و مهندس خوشبخت که مساعدت ایشان در انجام این مقاله بسیار مؤثر بود. و با تشکر از شرکت نفت و گاز پارس برای در اختیار دادن داده های مورد نیاز.

## منابع

- غضنفری، م.، اراکات، ج.، ۱۳۸۳. شبکه های عصبی (اصول و کارکردها). مرکز انتشارات دانشگاه علم و صنعت ایران.
- منهاج، م.، ۱۳۸۴. مبانی شبکه های عصبی. مرکز نشر پرفسور حسایی.
- مهدی زاده، م.، ۱۳۸۳. شبکه های عصبی مصنوعی و کاربردهای آن در مهندسی. انتشارات عبادی.
- Borsaru, M., Zhou, B., Aizawa, T., Karashima, H., and Hashimoto,
- Nikraves, M., 2004. Soft computing-based computational intelligent for reservoir characterization. Expert Systems with Applications.