

برآورد نفوذپذیری میدان گازی پارس جنوبی با استفاده از شبکه عصبی رگرسیون عمومی

علی مرادزاده^{۱*}، فرامرز دولتی ارده‌جانی^۲، رضا روکی^۳ و ماشاله رحیمی^۴

^۱ استاد، دانشکده مهندسی معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۲ استاد، دانشکده مهندسی معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۳ دانشجوی دکتری مهندسی اکتشاف معدن، دانشکده مهندسی معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۴ کارشناس ارشد مهندسی اکتشاف نفت، مدیریت اکتشاف شرکت ملی نفت ایران، تهران، ایران

(دریافت: ۸۷۹۱۷، پذیرش نهایی: ۸۹۱۲۲۴)

چکیده

نفوذپذیری یکی از ویژگی‌های بسیار مهم مخازن نفتی است که قابلیت انتقال یک شاره مانند نفت، گاز و یا آب را در فضاهای خالی موجود در سنگ مخزن نشان می‌دهد. تعیین نفوذپذیری در فرایندهایی چون برآورد ذخیره، تولید و توسعه مخازن نفتی، جایگاه خاصی دارد. در صنعت نفت معمولاً روش استاندارد برای تعیین نفوذپذیری، آنالیز مغزه و آزمایش چاه است. این روش‌ها بسیار پرهزینه‌اند. از طرفی همه چاه‌های یک میدان دارای مغزه نیستند. در نتیجه روشی که بتواند با استفاده از نگارهای چاه‌پیمایی خاص پتروفیزیکی مخزن از جمله نفوذپذیری را به دست دهد، اهمیت زیادی خواهد داشت، زیرا در همه چاه‌های یک میدان معمولاً نگارهای چاه موجود هستند. در این تحقیق از روش شبکه عصبی رگرسیون عمومی (GRNN, General regression neural network) برای برآورد نفوذپذیری دو سازند کنگان و دالان میدان گازی پارس جنوبی به روش نگارهای چاه‌پیمایی استفاده شده است و نتایج با روش برآورد رگرسیون خطی چندمتغیره نیز مقایسه شد. نتایج حاصل نشان می‌دهد که ضریب همبستگی متوسط بین نفوذپذیری پیش‌بینی شده با شبکه عصبی طراحی شده و نفوذپذیری مغزه برای دو سری داده آموزش و آزمون به ترتیب حدود ۰/۹۵ و ۰/۹۰۲ در مقایسه با مقادیر ۰/۸۵ و ۰/۸۱۲ روش رگرسیون خطی چندمتغیره است. این در حالی است که برای داده‌های مرحله آزمون میزان خطای برآورد شبکه عصبی در مقابل خطای روش رگرسیون خطی چندمتغیره به طور قابل ملاحظه‌ای کمتر بوده است (متوسط ۰/۶۵ در برابر ۰/۸۸۸) و به همین علت می‌توان نتیجه گرفت که شبکه عصبی رگرسیون عمومی با توجه به پیچیدگی‌های خواص مخازن نفتی، نسبت به روش رگرسیون خطی چندمتغیره، سرعت و دقت بهتری در برآورد نفوذپذیری سنگ مخزن دارد.

واژه‌های کلیدی: نفوذپذیری، داده‌های مغزه، نگارهای چاه، مخازن نفتی، شبکه عصبی رگرسیون عمومی، روش رگرسیون خطی

چندمتغیره

Estimation of the southern Pars gas field's permeability using General Regression Neural Networks (GRNN)

Moradzadeh, A.¹, Doulati Ardejani, F.², Rooki, R.³ and Rahimi, M.⁴

¹ Professor, Faculty of Mining and Geophysics, Shahrood University of Technology, Iran

² Professor, Faculty of Mining and Geophysics, Shahrood University of Technology, Iran

³ Ph. D. Student of Mining Engineering, Faculty of Mining and Geophysics, Shahrood University of Technology, Shahrood, Iran

⁴ M.Sc. in Petroleum Engineering, Exploration Directory of the NIOC, Tehran, Iran

(Received: 7 Dec 2008, Accepted: 15 March 2011)

Abstract

The permeability is a main property of oil reservoirs that shows the ability of rocks in the conduct of fluids such as oil, water and gas through the pore spaces of reservoir. The determination of the permeability is a crucial task in reserve estimation, production and

development of oil reservoirs. Due to this, an accurate estimate of such important reservoir rock parameter should not be made from log data alone. Thus a judicious combination of core analysis and log data is required to link the most relevant parameters in order to achieve more global relationships to estimate the permeability of a reservoir rocks.

The conventional methods for permeability determination are based on limited core analysis and well test data sets. These methods are however very expensive and time consuming. Furthermore, one or more wells in an oil field may have no core samples. In practice, all exploration data including log, core, and seismic data often reflect complex nonlinear underlying relationships. Also, these data may contain a high value of uncertainty and noise caused by measurement errors. An additional source of uncertainty arises from the mapping of a sparse data set to the entire reservoir domain. Therefore, there is significant uncertainty on the estimated values of the specific petrophysical parameter such as permeability at points between wells using data obtained at the well locations. So, there is a need to use a method could appropriately measure the petrophysical properties of reservoir using available well logs. The methods are currently used to propose permeability models with high generalization performance include empirical correlations like Kozeny-Carmen theory that relates permeability to porosity and the specific area of a porous rock, multi-linear regression, multilayer perception, and fuzzy neural networks. The main limitation of empirical models is that they are developed for a specific formation and perform poorly when estimating permeability in other oil fields. Although multi-linear regression models perform better on unseen data, they often overestimate low values and underestimate high values of petrophysical parameters of the hydrocarbon reservoirs. Alternatively, artificial neural networks (ANNs) have been increasingly applied as a proper computational tool to estimate the required petrophysical properties by identifying the complex non-linear relationships between permeability, porosity, fluid saturations and well log data.

Due to the inherent ability of the ANNs, this study attempts to evaluate the ability of the general regression neural network (GRNN) and to use it for predicting the horizontal and vertical permeability (K_h and K_v) of the gas reservoirs within the Kangan and Dalan formations in the South Pars gas field. To achieve the goal the well logs and core data of three wells are used and the required computational computer codes have been written in MATLAB multi-purpose software environment. The values of digitized well logs data including sonic (DT), gamma ray (GR), compensated neutron porosity (NPHI), density (ROHB), photoelectric factor (PEF), micro spherical focused resistivity log (MSFL), shallow and deep latero-resistivity logs (LLS and LLD) are taken as input, whereas horizontal or vertical permeability (K_h and K_v) are considered as the output of the networks. In order to find the most relevant input variables (logs data) to estimate the permeability, a series of statistical analysis has been done by SPSS statistical software and the obtained correlation matrix showed a strong positive correlation between the permeability and sonic and neutron logs and a strong negative correlation with the density log. The other logs show a low to moderate correlation with permeability.

Among the 250 number of logs and core permeability datasets of the Kangan and Dalan gas reservoirs, 70 percent was randomly divided for training and 30 percent of them was allocated as testing subsets. At the next stage and in order to increase the network resolution to discriminate the high and low values, the data of all input logs were normalized within the interval of -1 to 1, whereas the output of the networks was the logarithm of core derived permeability (i.e. LK_h and LK_v).

As the smooth factor (SF) is the most important feature in the structure of GRNN, the training of the designed network was done by different values of this factor within the

interval 0.1 to 1 and it was found that 0.27 is its optimum value with considering to the RMS error and correlation coefficient (R) of test dataset. The training of the designed network was then implemented by three, four, six, and nine combinations of input variables and it was found that the nine pattern of the input variables (i.e. X, Y, Z, DT, RHOB, NPHI, GR, PEF, MSFL) is the best relevant parameters based on the least RMSE and the highest correlation coefficient (R) values attained during the training and testing process. Consequently the designed multi-layer neural network contains a structure including one input layer with 9 neurons, one hidden layer of radial basis activation function comprising 174 neurons and an output layer containing only one neuron with linear activation function.

The obtained results of the designed networks are then compared to those provided by the multi variables linear regression (MVLRL) method. The GRNN results indicate that the average correlation coefficients between core and predicted permeability are 0.95 and 0.902 in comparison to 0.85 and 0.812 of MVLRL approach for train and test datasets respectively. Implementations of these methods on test datasets show that the average error of the GRNN technique is (0.65) considerably lower than that of the MVLRL method (0.888) for permeability estimation. Hence, it could be concluded that the GRNN approach is faster and is more precise than the MVLRL method in prediction of permeability for complex hydrocarbon reservoirs.

Key words: Permeability, hydrocarbon reservoirs, core data, well logs, MVLRL, GRNN

۱ مقدمه

(بات، ۲۰۰۲). در نتیجه، روشی که بتواند نموداری پیوسته از این پارامتر پتروفیزیکی مخازن به دست دهد و تا حدودی جایگزین مناسبی برای این روش‌های پُرخرج باشد، ارزش زیادی خواهد داشت (مرادزاده و قوامی ریایی، ۱۳۸۰).

با توجه به اینکه در اکثر چاه‌ها، نگارهای گوناگون موجود است، از این رو در تحقیقات زیادی سعی شده است که به طریقی نفوذپذیری را به کمک روابط تجربی که بین پارامترهای متفاوت حاصل از نگارها (مثل ارتباط نگارهای تخلخل و نفوذپذیری) وجود دارد، به دست آورند. استفاده از این روش‌ها علی‌رغم مفید بودن، در بسیاری از موارد به دلیل نیاز زیاد به داده‌های مغزه و دلایل دیگر، کاربرد محدودی دارند (براس، ۱۹۷۷؛ تیاب و دونالدسون، ۲۰۰۴). استفاده از روش‌های دیگر چاه‌پیمایی، مانند نگار تشدید مغناطیسی پروتون (Proton Magnetic Resonance, PMR) و نگارهای کامل موج صوتی که با استفاده از دامنه و زمان گذر موج لوله‌ای یا موج استانی

نفت و گاز یکی از منابع اصلی انرژی در جهان، و کشور ایران یکی از کشورهای مستعد از لحاظ منابع نفت و گاز است. با توجه به کاهش ذخایر در حال بهره‌برداری، توسعه میدان‌های نفتی و گازی در کشور اهمیت خاصی دارد. در همین راستا، آگاهی از خواص مخزن، اهمیت زیادی در صنعت نفت دارد. نفوذپذیری یکی از مهم‌ترین این خواص است که تعیین آن از سایر پارامترهای پتروفیزیکی مانند تخلخل و اشباع آب دشوارتر است. معمولاً مقادیر صحیح نفوذپذیری را از طریق اندازه‌گیری‌های مستقیم آزمایشگاهی روی مغزه‌ها و یا تفسیر آزمایش چاه به دست می‌آورند. هر دوی این روش‌ها دقیق‌اند، اما برای توصیف کامل مخزن کافی نیستند، زیرا در هر میدان نفتی به دلیل وقت‌گیر بودن و نیز هزینه زیاد، فقط تعداد محدودی از چاه‌ها مغزه‌گیری شده و نتایج حاصل از آزمایش چاه نیز محدود است. به همین دلیل هیچ‌یک از روش‌های فوق قادر به عرضه نمودار پیوسته‌ای از نفوذپذیری که برای ارزیابی مخازن هیدروکربوری اهمیت زیادی دارد، نخواهند بود

۱۳۸۵). شبکه عصبی مصنوعی از نظر عملکرد دارای روش‌های متفاوتی است که از جمله می‌توان به شبکه پُرکاربرد پرسپترون چندلایه (MLP, Multi-layer perceptron) با الگوریتم پس‌انتشار خطا (Back-Propagation, BP) اشاره کرد. از آنجا که شبکه‌های عصبی به‌خوبی قادرند تا روابط غیرخطی مجهول بین داده‌های حاصل از نگارهای گوناگون چاه را با دقت زیاد برآورد کنند. به همین دلیل در سال‌های اخیر در دنیا و کشورمان سعی شده است تا از شبکه‌های عصبی پرسپترون با الگوریتم پس‌انتشار خطا برای تهیه نمودارهای پیوسته پارامترهای پتروفیزیکی تخلخل و نفوذپذیری استفاده شود (هوانگ و همکاران، ۱۹۹۶؛ زنگ و همکاران، ۲۰۰۰؛ تدینی و همکاران، ۱۳۸۳؛ جلالی لیچایی و همکاران، ۱۳۸۳؛ حبیبیان و همکاران، ۱۳۸۴).

یکی از دیگر روش‌های شبکه عصبی، شبکه عصبی رگرسیون عمومی یا در واقع نوعی شبکه شعاعی (RNN, Radial neural network) با ساختار موازی است. این شبکه با توجه به سرعت زیاد برآورد و همچنین پارامترهای کمتر قابل تنظیم نسبت به شبکه پس‌انتشار خطا، در بسیاری از موارد ارجحیت دارد. در زمینه استفاده از این شبکه می‌توان به مدل‌سازی و تشخیص الگوی زمین‌شناسی با شبکه عصبی رگرسیون عمومی (هوانگ و ویلیامسون، ۱۹۹۴)، تعیین خواص مخزن با استفاده از معکوس‌سازی هوشمند داده‌های لرزه‌ای (آرتن و همکاران، ۲۰۰۵) و توسعه نگارهای مصنوعی هوشمند (رولان، ۲۰۰۴) اشاره کرد. بررسی منابع منتشر شده نشان می‌دهد که علی‌رغم توانمندی این نوع شبکه‌ها، از آنها برای برآورد نفوذپذیری سازندهای موردنظر استفاده نشده است. در نتیجه در این تحقیق در نظر است با اجرای یک رشته گُدنویسی در محیط نرم‌افزاری مت‌لب (MTLAB) توانمندیهای این روش برای برآورد نفوذپذیری مخازن گازی موجود در سازندهای کنگان و دالان منطقه پارس


(Tube or Stoneley wave) به تعیین نفوذپذیری سازند می‌پردازد، از دیگر روش‌های نوین در این امر هستند (برنز و همکاران، ۱۹۸۸؛ پیلت و ساندرز، ۱۹۹۰). با وجود اینکه این نگارها می‌توانند نمودار پیوسته‌ای از نفوذپذیری را به دست دهند ولی استفاده از آنها به دلایل فنی، همیشه نتایج مطمئنی ندارد و از این رو هرکدام محدودیت‌های مربوط به خود را دارند (علی‌پور و همکاران، ۱۳۸۳؛ کومار و همکاران، ۲۰۰۰).

در روش دیگر برای برآورد پارامترهای پتروفیزیکی مثل نفوذپذیری و تخلخل، ابتدا رابطه آماری بین پارامتر پتروفیزیکی موردنظر با نگارهای گوناگون چاه، اغلب با روش رگرسیون یک یا چندمتغیره خطی و گاه رگرسیون چندمتغیره غیرخطی مورد بررسی قرار می‌گیرد و در ادامه پس از یافتن رابطه ریاضی موجود، از آن برای پیش‌بینی پارامتر موردنظر استفاده می‌شود. از آنجا که رابطه ریاضی مابین پارامتر موردنظر پتروفیزیکی نظیر نفوذپذیری با متغیرهای مستقل ورودی (مثل داده‌های حاصل از نگارهای گوناگون) ناشناخته، پیچیده و اغلب غیرخطی است، از این رو استفاده از روش‌های رگرسیون خطی و حتی غیرخطی پیش‌گفته به نتایج تقریبی با خطای زیاد منجر خواهد شد. در مدل‌های رگرسیون غیرخطی نتایج به چگونگی انتخاب مدل ریاضی، فرضیه‌های صورت گرفته و به نوع متغیرهای ورودی، بستگی زیادی دارد، به‌خصوص اگر کواریانس زیادی بین آنها وجود داشته باشد (مرادزاده و بخشی، ۱۳۸۵؛ هوانگ و همکاران، ۱۹۹۶).

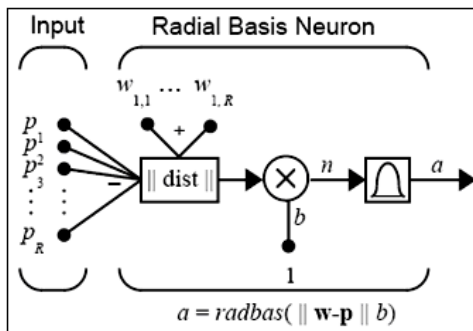
کاربردهای متفاوت شبکه‌های عصبی مصنوعی (ANN, Artificial neural networks) در دهه‌های اخیر در زمینه‌های گوناگون، حاکی از قابلیت زیاد آنها در مهندسی نفت برای تعیین پارامترهای پتروفیزیکی مخازن و نگارهای گوناگون است (محقق و عامری، ۱۹۹۵؛ بالان و همکاران، ۱۹۹۵؛ محقق، ۲۰۰۰؛ مرادزاده و بخشی،

۳ نظریه شبکه‌های عصبی شعاعی (RNN)

شبکه‌های عصبی مصنوعی در واقع تقلید بسیار ساده‌ای از رفتار سلول‌های زیستی هستند که از واحدهایی به نام نرون تشکیل شده‌اند. هر شبکه ساده شامل لایه ورودی، لایه میانی، لایه خروجی و تابع محرک است. لایه ورودی سیگنال‌ها را از محیط خارج (یا دیگر نرون‌ها) دریافت می‌کند. تابع محرک سیگنال‌های ورودی را جمع و پردازش می‌کند. شبکه‌های شعاعی احتیاج به نرون‌های بیشتری نسبت به شبکه‌های پسانتشار دارند ولی این شبکه‌ها زمانی طراحی می‌شوند که آموزش شبکه‌های پسانتشار خطا، وقت زیادی می‌برد. همچنین این شبکه‌ها زمانی آنجا که بُردارهای ورودی بیشتری وجود داشته باشد بهتر کار می‌کنند. در شکل ۲ شبکه‌ای شعاعی با R ورودی نشان داده شده است.



شکل ۱. موقعیت جغرافیایی میدان پارس جنوبی (وبسایت شرکت ملی نفت ایران، ۲۰۰۷).



شکل ۲. مدل نرون شبکه عصبی شعاعی (دمیوت و بیل، ۲۰۰۲).

جنوبی به کمک داده‌های مغزه و همچنین نگارهای گوناگون سه چاه، مورد بررسی قرار گیرند.

۲ زمین‌شناسی منطقه

حوضه رسوبی آب‌های فلات قاره ایران (خلیج فارس) بی‌شک از نظر تجمع مواد هیدروکربوری یکی از غنی‌ترین مناطق جهان شناخته شده است و فعالیت‌های شرکت‌های گوناگون نفتی در گذشته که منجر به کشف میدان‌های متعدد در این منطقه شده است، مؤید این ادعا است (رحیمی، ۱۳۸۱). عوامل متعددی در به‌وجود آوردن وضعیت مناسب نفتی-گازی فوق سهیم بوده‌اند که از آن جمله نهشته‌های رسوبی منسجم با ضخامت کافی، وجود سنگ‌های مادر، مخزن و پوششی با کیفیت خوب و مفید و بالاخره چندلایه بودن افق‌های هیدروکربوری را می‌توان نام برد.

نتیجه کارهای اکتشافی صورت گرفته از سوی شرکت ملی نفت ایران، کشف پدیده‌های مثبت زمین‌شناسی متعدد در مناطق گوناگون بوده است که از میان آنها، ساختمان زمین‌شناسی پارس جنوبی که ادامه یال شمالی میدان عظیم گازی شمال قطر است را می‌توان نام برد.

میدان گازی پارس جنوبی مطابق شکل ۱ روی خط مرزی مشترک ایران و قطر در خلیج فارس و در فاصله ۱۰۰ کیلومتری ساحل جنوبی ایران قرار دارد. وسعت این میدان گازی در بخش مربوط به ایران برابر ۳۷۰۰ کیلومتر مربع است (وبسایت شرکت ملی نفت ایران، ۲۰۰۷).

سازندهای موجود در این میدان به ترتیب سن از جدید به قدیم شامل سازند آسماری، سازند جهرم، سازند ساچون، سازند سروک، سازند کژدمی، سازند داریان، سازند گدوان، سازند فهلیان، سازند هیث، سازند سورمه، سازند نیریز، سازند دشتک، سازند کنگان و سازند دالان هستند. از بین این سازندها، دو سازند کنگان و دالان گازدارند (رحیمی، ۱۳۸۱).

اُمین عضو از a_1 و $i^{IW_{1,1}}$: اُمین سطر از بُردار $IW_{1,1}$ است.

جعبه $\|dist\|$ در این شکل بُردار ورودی p و بُردار وزنی ورودی $IW_{1,1}$ را دریافت و بُرداری تولید می کند که دارای S_1 عضو است. این عناصر فواصل بین بُردار ورودی و عضوهای $i^{IW_{1,1}}$ تشکیل شده از سطرهای ماتریس وزن ورودی است. بُردار آریبی b_1 و خروجی $\|dist\|$ از راه عملگر "*" که ضرب عضو به عضو را عملی می سازد، با هم ترکیب می شوند. خروجی لایه اول برای یک شبکه پیش خور net ، از کُد زیر حاصل می شود:


$$a\{1\} = \text{radbas}(\text{netprod}(\text{dist}(\text{net.IW}\{1,1\}, p), \text{net.b}\{1\}))$$

با توجه به موارد فوق به راحتی می توان فهمید که این شبکه چگونه یک بُردار ورودی p را به خروجی a_2 تبدیل می کند. اگر یک بُردار ورودی به چنین شبکه ای داده شود، هر نرون در لایه پنهان شعاعی، خروجی را با توجه به نزدیکی بُردار ورودی به بُردار وزن، به دست می دهد. نرون های شعاعی دارای بُردارهای وزن کاملاً متفاوت از بُردار ورودی p ، خروجی نزدیک به صفر را می دهند. بنابراین ورودی های کوچک فقط تاثیر جزئی روی نرون های خروجی خطی دارند. در مقابل نرون شعاعی، با بُردار وزن نزدیک به بُردار ورودی p ، مقدار خروجی نزدیک به ۱ تولید می کند (دمیوت و بیل، ۲۰۰۲).

باید توجه کرد که ورودی (نرون) این شبکه متفاوت از نرون های ورودی شبکه پس انتشار است. در اینجا ورودی شبکه برای تابع محرک شعاعی، فاصله بُرداری بین بُردار وزن w و بُردار ورودی p ضرب در آریبی (بایاس) است. جعبه $\|dist\|$ در این شکل بُردار ورودی p و ماتریس تک ردیفه وزن w را می گیرد و از آن دو تولید ضرب نقطه ای می کند. تابع محرک نرون شعاعی به صورت زیر است (دمیوت و بیل، ۲۰۰۲):

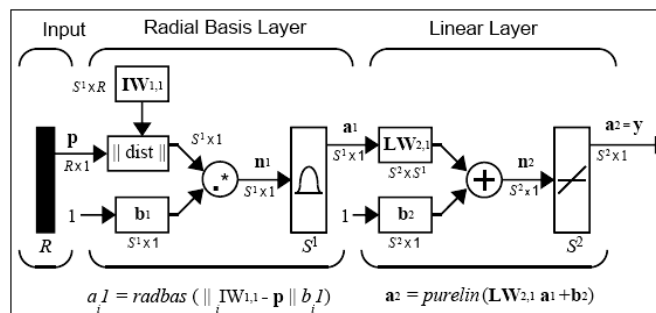
$$\text{radbas}(n) = e^{-n^2} \quad (1)$$

که در آن: n ورودی نرون و e تابع نمایی است. در شکل (۳) نیز نمودار تابع محرک شعاعی نشان داده شده است.



شکل ۳. تابع محرک استفاده شده در شبکه عصبی شعاعی (دمیوت و بیل، ۲۰۰۲).

شبکه های شعاعی شامل دو لایه هستند: یک لایه شعاعی پنهان با S_1 نرون و یک لایه خطی خروجی با S_2 نرون (شکل ۴). که R تعداد عضوهای بردار ورودی، S_1 : تعداد نرون ها در لایه ۱، S_2 تعداد نرون ها در لایه ۲، a_i^1 :




شکل ۴. ساختار شبکه عصبی شعاعی (دمیوت و بیل، ۲۰۰۲).

۳-۱ شبکه عصبی رگرسیون عمومی (GRNN)

GRNN را می‌توان درحکم یک شبکه شعاعی نرمال شده در نظر گرفت که برای هر واحد آموزشی یک نرون پنهان دارد (رولان، ۲۰۰۴). این شبکه الگوریتم یادگیری تک‌گذر با ساختار موازی که اسپچت (Specht) در ۱۹۹۰ آن را اختراع کرد (آرتون و همکاران، ۲۰۰۵) قادر به تولید خروجی‌های پیوسته است. این شبکه‌ها براساس تابع چگالی احتمال (PDF, Probability density function) پایه‌گذاری شده و از ویژگی‌های بارز آن زمان آموزش سریع و مدل‌سازی توابع غیرخطی است. این شبکه حتی با داده‌های پراکنده در یک فضای اندازه‌گیری چندبُعدی، تغییرات همواری از داده مشاهده‌ای را برای دیگر داده‌ها فراهم می‌کند. صورت الگوریتمی این شبکه برای هر مسئله رگرسیونی در جایی که هیچ‌گونه فرضیاتی برای قضاوت خطی بودن وجود نداشته باشد، می‌تواند مورد استفاده قرار گیرد. این شبکه پارامترهای شبکه پس‌انتشار خطا را ندارد ولی در عوض فاکتور هموارساز (Smooth factor) دارد که مقدار بهینه آن در طی چندین اجرا با توجه به میانگین مربعات خطا به دست می‌آید (آرتون و همکاران، ۲۰۰۵). همان‌طور که در شکل ۵ نشان داده شده است، ساختار این شبکه شبیه به ساختار کلی شبکه شعاعی است؛ فقط تفاوت جزئی در لایه دوم دارد (دمیوت و بیل، ۲۰۰۲).

۴ برآورد نفوذپذیری

داده‌های مورد استفاده در برآورد نفوذپذیری به کمک شبکه عصبی رگرسیونی، نگارهای پیوسته رقمی شده چاه (ورودی‌ها) و داده‌های نفوذپذیری مغزه (خروجی) مربوط به ۳ چاه موجود در منطقه هستند. نگارهای ثبت شده در چاه‌های منطقه شامل، نگار صوتی (DT)، نگار گاما (GR)، نگار نوترون اصلاح شده (NPFI)، نگار چگالی (RHOB)، نگار مقاومت ویژه میکروکروی (MSFL)، نگار مقاومت ویژه لاترولوگ عمیق (LLD)، نگار مقاومت ویژه لاترولوگ کم‌عمق (LLS) و نگار شاخص فتوالکتریک (PEF) هستند. داده مغزه مدنظر در اینجا نفوذپذیری افقی (KH) و نفوذپذیری قائم (KV) است که برای شبکه رگرسیونی، از لگاریتم آن دو (LKH و LKV) استفاده می‌شود. از داده‌های دیگر که مورد استفاده قرار می‌گیرند، موقعیت چاه‌ها شامل طول جغرافیایی (X)، عرض جغرافیایی (Y) و عمق (Z) هستند. برای تعیین اینکه از کدام‌یک از نگارهای فوق بایستی درحکم متغیرهای ورودی در برآورد نفوذپذیری استفاده شود ابتدا به کمک نرم‌افزار SPSS ماتریس همبستگی متغیرهای مستقل (نگارهای چاه) با متغیر وابسته (لگاریتم نفوذپذیری) - چون بعد از بررسی آماری مشخص شد نگارها با نفوذپذیری رابطه لگاریتمی دارند- تعیین شد.



شکل ۵. ساختار شبکه عصبی رگرسیون عمومی (دمیوت و بیل، ۲۰۰۲).

از نتایج حاصل از آموزش شبکه (به صورت ضریب همبستگی و جذر میانگین مربعات خطاها) با انتخاب ۹ متغیر ورودی (طول و عرض جغرافیایی و عمق چاهها، نگار گاما، نگار چگالی، نگار صوتی، نگار تخلخل نوترون، نگار شاخص فتوالکتریک و نگار مقاومت ویژه میکروکروی) در جدول (۲) آمده است. همان طور که در جدول دیده می شود با افزایش فاکتور هموارساز مقدار ضریب همبستگی در داده های آموزش با توجه به اساس روش شبکه عصبی رگرسیونی، به آرامی کاهش ولی برای داده های آزمون به آرامی افزایش می یابد. در نهایت مقدار فاکتور هموارساز بهینه با توجه به بیشترین مقدار ضریب همبستگی و کمترین میزان خطای مرحله آزمون برای هر الگوی ورودی و خروجی انتخاب می شود. به منظور بررسی پارامترهای موثر بر نفوذپذیری، آموزش شبکه در چهار مرحله، یعنی با سه، چهار، شش و نه ورودی صورت گرفت که بهترین نتایج مربوط به حالت نه ورودی بود. در جدول (۳) بهترین نتایج حاصل از آموزش شبکه با ورودی های متفاوت آورده شده است.

همان طور که در جدول (۱) مشاهده می شود لگاریتم نفوذپذیری با نگارهای صوتی و تخلخل نوترون اصلاح شده همبستگی مثبت زیاد و با نگار چگالی، همبستگی منفی زیاد نشان می دهد. نگارهای دیگر دارای همبستگی متوسط تا کم با نفوذپذیری هستند.

برای به دست آوردن نفوذپذیری، از تعداد ۲۵۰ داده موجود مربوط به نفوذپذیری دو سازند کنگان و دالان سه چاه میدان پارس جنوبی، ۱۷۴ داده (۷۰ درصد) به صورت تصادفی برای آموزش و بقیه (۳۰ درصد) برای آزمون شبکه انتخاب شد.

برای بالا بردن قابلیت تشخیص شبکه، ورودی های شبکه (نگارهای چاه پیمایی) در بازه ۱ تا ۱- نرمال شدند و خروجی شبکه، لگاریتم نفوذپذیری در نظر گرفته شد. آموزش شبکه برای برآورد نفوذپذیری افقی با فاکتورهای متفاوت هموارساز که همان $||dist||$ است، صورت گرفت. با مقدارهی این فاکتور، وزن های هر ورودی برای برآورد خروجی، مشخص می شوند. برای به دست آوردن مقدار بهینه این فاکتور، شبکه با تعداد ورودی های متفاوت و فاکتورهای هموارساز متغیر آموزش داده شد. نمونه ای

جدول ۱. ماتریس همبستگی متغیر وابسته لگاریتم نفوذپذیری با متغیرهای مستقل.

	LKH	LKV	X	Y	Z	GR	DT	RHOB	NPHI	PEF	MSFL	LLD	LLS
LKH	1												
LKV	.957	1											
X	-.112	-.161	1										
Y	.110	.162	-.999	1									
Z	.285	.258	.655	-.655	1								
GR	-.015	.028	.219	-.216	.490	1							
DT	.742	.751	-.025	.026	.347	.088	1						
RHOB	-.664	-.659	-.011	.010	-.397	-.182	-.915	1					
NPHI	.820	.848	-.110	.107	.240	.167	.746	-.615	1				
PEF	.125	.098	.125	-.119	.361	.210	.350	-.576	.009	1			
MSFL	-.318	-.311	.072	-.070	-.164	-.259	-.327	.401	-.318	-.236	1		
LLD	-.106	-.100	.107	-.110	.106	-.041	-.153	.169	-.101	-.078	.274	1	
LLS	-.206	-.187	.077	-.078	-.023	-.102	-.239	.248	-.203	-.115	.235	.767	1


جدول ۲. مقادیر درصد ضرایب همبستگی (R) و جذر میانگین مربعات خطا (RMS) با فاکتورهای هموارساز متفاوت با ۹ ورودی در دو سری داده آموزش و آزمون.

Smooth factor(SF)	R (آموزش)	R (آزمون)	RMS error (آموزش)	RMS error (آزمون)
0.050	1.000	0.874	0.004	0.767
0.070	1.000	0.874	0.021	0.766
0.090	1.000	0.874	0.046	0.765
0.110	0.999	0.875	0.075	0.760
0.130	0.997	0.878	0.107	0.751
0.150	0.996	0.883	0.140	0.737
0.170	0.993	0.888	0.170	0.719
0.190	0.991	0.893	0.198	0.700
0.210	0.988	0.897	0.225	0.684
0.230	0.986	0.900	0.253	0.671
0.250	0.982	0.902	0.281	0.664
0.270	0.979	0.903	0.309	0.660
0.290	0.975	0.903	0.338	0.662
0.310	0.970	0.903	0.367	0.663
0.330	0.965	0.901	0.395	0.666

جدول ۳. نتایج مطلوب حاصل از آموزش شبکه با ورودی‌های متفاوت.

ورودی‌های شبکه	SF (فاکتور هموارساز)	R (آموزش)	R (آزمون)	RMS (آموزش)	RMS (آزمون)
(DT, RHOB, NPHI)	0.170	0.930	0.907	0.546	0.653
(DT, RHOB, NPHI, MSFL)	0.130	0.945	0.906	0.486	0.653
(X, Y, Z, DT, NPHI, RHOB)	0.370	0.927	0.892	0.568	0.706
(X, Y, Z, DT, GR, NPHI, PEF, MSFL) RHOB,	0.270	0.979	0.903	0.309	0.66


شده است که نحوه ارتباط یکی از ورودی‌ها را با نرون‌های لایه میانی نشان می‌دهد.




شکل ۶. نمای کلی از شبکه عصبی رگرسیون عمومی و تعداد لایه‌های آن برای یک ورودی.

با توجه به نتایج به دست آمده از شبکه با ورودی‌های متفاوت (جدول‌های ۲ و ۳)، مدل نهایی با توجه به ضریب همبستگی و جذر میانگین مربعات خطا در دو مرحله آموزش و آزمون انتخاب شد. مدل نهایی شبکه‌ای است که از فاکتور هموارساز ۰/۲۷ برای آموزش استفاده می‌کند، این شبکه، برای برآورد نفوذپذیری افقی و قائم دارای یک لایه ورودی با ۹ نرون، یک لایه پنهان با تعداد ۱۷۴ نرون و تابع محرک شعاعی و یک لایه خروجی با یک نرون و تابع محرک خطی در آن است. نمای کلی شبکه پهنه و تعداد لایه‌های آن در شکل ۶ و قسمتی از لایه میانی (به علت حجیم بودن آن) در شکل ۷ آورده

۰/۹۰۳ و اندازه شیب بهترین خط برازش شده با داده‌ها ۰/۸۰۷ به جای ۱ است از این رو میزان پراکندگی موجود حول بهترین خط برازش شده بر داده‌ها کم‌باست و علاوه بر آن شبکه آموزش‌یافته قادر است با گرفتن داده‌های متفاوت شامل نگارهای مربوط به چاه‌های موجود، مقادیر نفوذپذیری سازند را با دقت نسبتاً خوبی تولید کند.

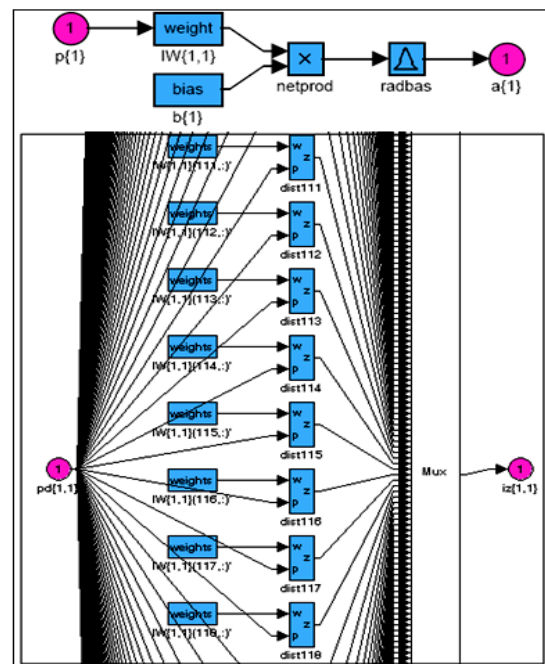


شکل ۸. همبستگی بین لگاریتم نفوذپذیری افقی شبکه با لگاریتم نفوذپذیری مغزه در مرحله آموزش با ۸ نرون ورودی.



شکل ۹. همبستگی بین لگاریتم نفوذپذیری افقی شبکه با لگاریتم نفوذپذیری مغزه در مرحله آزمون با ۸ نرون ورودی.

علاوه بر آن برای ارزیابی بهتر عملکرد شبکه، مقایسه‌ای بین نمودار تغییرات لگاریتم نفوذپذیری افقی مغزه با




شکل ۷. مشخصات بخشی از لایه پنهان شبکه عصبی رگرسیون عمومی.

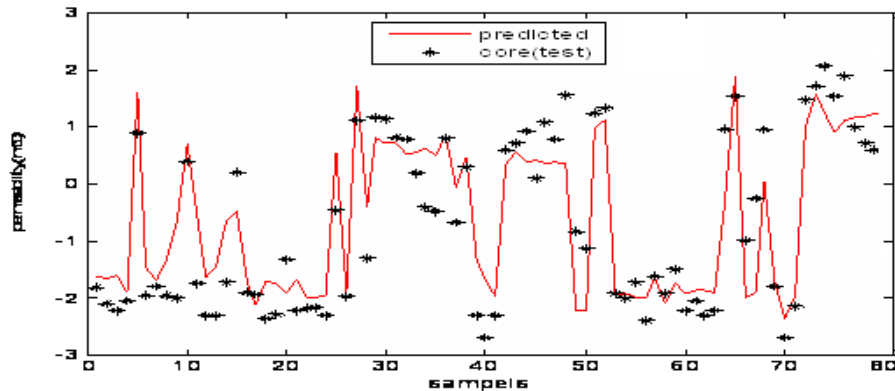
برای ارزیابی توانمندی شبکه طراحی شده رگرسیون عمومی در برآورد مقادیر نفوذپذیری سازندهای موردنظر نمودار همبستگی موجود بین مقادیر نفوذپذیری افقی برآوردی در مقابل مقادیر نفوذپذیری افقی مغزه در مرحله آموزش و آزمون شبکه به ترتیب در شکل‌های ۸ و ۹ آمده است. می‌دانیم که زاویه شیب بهترین خط برازش شده (خط سرخ‌رنگ در شکل‌های ۸ و ۹) کیفیت برازش مدل حاصل از شبکه را با داده نشان می‌دهد و علاوه بر آن مقدار ضریب همبستگی محاسبه شده بین پاسخ شبکه و داده‌های حاصل با مغزه پراکندگی، داده‌ها را حول بهترین خط برازش شده نشان می‌دهد (مرادزاده و بخشی، ۱۳۸۵). همان‌طور که در شکل‌های فوق دیده می‌شود مقادیر ضریب همبستگی در مرحله آموزش، نزدیک به ۰/۹۸ و برای مرحله آزمون ۰/۹۰۳ است. لازم به ذکر است که شبکه طراحی شده داده‌های آزمون (۳۰ درصد داده‌های موجود) را در مرحله آموزش ندیده است. با توجه به اینکه در مرحله آزمون (شکل ۹) مقدار ضریب همبستگی

هستند. این امر سبب می شود که شبکه در این محدوده ها به دلیل نبود داده نتواند به خوبی آموزش ببیند. این موضوع تا حدودی در شکل های ۸ و ۱۰ نمایان است. علی رغم این مسئله، با عنایت به شکل ۱۱ می توان دریافت که عملکرد شبکه برای پیش بینی نفوذپذیری در محدوده ۰/۰۱ تا حدود ۷۰ میلی داریسی خوب؛ زیرا در این محدوده شبکه آموزش دیده توانسته در مرحله آزمون با داده هایی که آنها را قبلاً ندیده است مقادیر نفوذپذیری را آنچنان برآورد کند که با خطای کم (RMS=0.66) در تطابق خوبی با مقادیر اندازه گیری شده از مغزه باشند. این موضوع قابلیت زیاد شبکه عصبی طراحی شده را در برآورد درست مقادیر نفوذپذیری سازندهای مورد بررسی به کمک داده های حاصل از نگارهای متفاوت (به جای آزمایش مغزه) بیان می کند.

نمودار لگاریتم نفوذپذیری افقی حاصل از شبکه در دو مرحله آموزش و آزمون به ترتیب در شکل های ۱۰ و ۱۱ آورده شده است. با عنایت به مقدار شیب ۰/۸۰۷ برای بهترین خط برازش شده بر داده ها مطابق شکل ۹ می توان دریافت که شبکه آموزش دیده برای الگوی ورودی های پیش گفته، مقادیر نفوذپذیری کم (کمتر از ۱/ میلی داریسی) را تا حدودی بیشتر و مقادیر نفوذپذیری زیاد را کمی کمتر از مقدار واقعی برآورد می کند. این موضوع به خوبی در شکل ۱۱ از نبود تطابق کامل بین مقادیر نفوذپذیری مغزه (علامت *) و مقادیر داده شده از شبکه (منحنی سرخ رنگ) در این محدوده ها آشکار است. بررسی های آماری روی داده های مغزه نشان می دهد که درصد کمی (فقط حدود ۵ درصد) از داده ها، دارای نفوذپذیری بیشتر از ۷۰ میلی داریسی و همچنین کمتر از ۱۰ درصد داده ها دارای نفوذپذیری کمتر از ۰/۰۱ میلی داریسی



شکل ۱۰. مقایسه بین منحنی لگاریتم نفوذپذیری افقی شبکه (-) با لگاریتم نفوذپذیری افقی مغزه (*) در مرحله آموزش.



شکل ۱۱. مقایسه بین منحنی لگاریتم نفوذپذیری افقی شبکه (-) با لگاریتم نفوذپذیری افقی مغزه (*) در مرحله آزمون.

از متغیرها (پارامترها) مثل NPHI, RHOB, DT با لگاریتم نفوذپذیری زیاد، و برای دیگر پارامترها وابستگی کمتر است. از این رو برای تعیین رابطه رگرسیون بین ورودی‌ها و لگاریتم نفوذپذیری، چهار مدل خطی چندمتغیره با شماره‌های ۱، ۲، ۳ و ۴ به ترتیب با سه ورودی (NPHI, DT, RHOB)، (NPHI, RHOB, DT, MSFL)، (RHOB, MSFL, Z, PEF) و سه ورودی شامل موقعیت چاه‌ها (NPHI, RHOB, DT, MSFL, Z, PEF, X, Y) طراحی و مورد استفاده قرار گرفت. مدل‌های فوق بر داده‌های مورد استفاده برازش شدند و روابط زیر به ترتیب برای هر کدام به دست آمد.

$$\text{Log}(KH) = 0.367 + 0.179\text{NPHI} + 0.01947\text{DT} - 1.126\text{RHOB}$$


$$\text{Log}(KH) = 0.123 + 0.178\text{NPHI} + 0.02075\text{DT} - 1.057\text{RHOB} - 0.000057\text{MSFL}$$

$$\text{Log}(KH) = 0.811 + 0.172\text{NPHI} + 0.0151\text{DT} - 1.474\text{RHOB} - 0.000058\text{MSFL} - 0.0515\text{PEF} + 0.00037\text{Z}$$


$$\text{Log}(KH) = -972.48 + 0.0001094\text{X} + 0.0003063\text{Y} + 0.003094\text{Z} - 0.0543\text{GR} - 0.0205\text{DT} - 2.191\text{RHOB} + 0.186\text{NPHI} - 0.0679\text{PEF} - 0.000194\text{MSFL}$$

همچنین نمودار همبستگی موجود بین مقادیر نفوذپذیری قائم برآوردی در مقابل مقادیر نفوذپذیری قائم مغزه در مرحله آموزش و آزمون و ارزیابی شبکه با نه ورودی به ترتیب در شکل‌های ۱۲ و ۱۳ آمده است. شکل‌های اشاره شده نشان می‌دهند که شبکه طراحی شده دارای دقت تقریباً یکسانی در پیش‌بینی نفوذپذیری افقی و قائم سنگ مخزن است.

در نهایت برای ارزیابی بیشتر کارایی شبکه طراحی شده در برآورد نفوذپذیری و مقایسه نتایج، از روش رگرسیون خطی چندمتغیره نیز در تعیین رابطه بین لگاریتم نفوذپذیری و پارامترهای متفاوت استفاده شد. همان‌طور که از مقادیر مندرج در جدول ۲ پیداست وابستگی بعضی



شکل ۱۳. همبستگی بین لگاریتم نفوذپذیری قائم شبکه با لگاریتم نفوذپذیری مغزه در مرحله آزمون با نه نرون ورودی.



شکل ۱۲. همبستگی بین لگاریتم نفوذپذیری قائم شبکه با لگاریتم نفوذپذیری مغزه در مرحله آموزش با نه نرون ورودی.

همبستگی سه مدل اول تقریباً یکسان و نزدیک ۰/۸۵ و ضریب همبستگی مدل چهارم برابر با ۰/۸۸ است. این موضوع نشان می‌دهد که در سه مدل اول داده‌ها

مقدار ضرایب همبستگی و خطای برآورد هریک از مدل‌ها برای داده‌های سری آموزشی در جدول ۴ آمده است. همان‌طور که در جدول ملاحظه می‌شود، ضریب


مقادیر خطای برآوردی و ضریب همبستگی به طور متوسط ۰/۸۸۸ و ۰/۸۱۳ محاسبه شد. مقایسه این مقادیر با ارقام متناظر در جدول ۳ که برای روش شبکه عصبی با ۳، ۴، ۶ و ۹ ورودی آمده است، نشان می‌دهد که در روش شبکه عصبی به کار گرفته شده، متوسط خطای برآورد ۰/۶۵ و متوسط ضریب همبستگی حدود ۰/۹۰ برای پیش‌بینی مقادیر نفوذپذیری افقی برای سری داده‌های آزمون است. شکل‌های ۱۴ و ۱۵ همبستگی بین مقادیر برآورد شده و مقادیر واقعی نفوذپذیری روش رگرسیون خطی چندمتغیره را برای مدل خطی با سه ورودی برای داده‌های مرحله آموزش و آزمون نشان می‌دهند.

پراکندگی تقریباً یکسانی حول بهترین خط برازش شده دارند. و این در حالی است که در مدل چهارم با اضافه کردن مختصات چاه‌ها و به‌ویژه عمق داده‌ها، پراکندگی داده‌ها حول بهترین خط برازش شده کمتر شده است (افزایش ضریب همبستگی به ۰/۸۸) و علاوه بر آن خطای پیش‌بینی نفوذپذیری نیز براساس جدول ۴ تا حدودی کاهش می‌یابد.


برای ارزیابی مدل‌های به دست آمده حاصل از آنالیز رگرسیون خطی چندمتغیره در برآورد مقادیر نفوذپذیری، از داده‌های آزمون که برای ساختن مدل‌ها استفاده نشدند در حکم متغیرهای ورودی مدل استفاده شد و با داشتن مقادیر واقعی نفوذپذیری حاصل از آزمایش مغزه‌ها،

جدول ۴. ضرایب همبستگی و خطای برآورد حاصل از چهار مدل برازش شده برای تعیین نفوذپذیری افقی.

مدل	ضریب همبستگی (R)	خطای برآورد	ورودی‌ها
۱	0.845	0.795	(NPHI, RHOB, DT)
۲	0.846	0.797	(NPHI, RHOB, DT, MSFL)
۳	0.847	0.799	(NPHI, RHOB, DT, MSFL, Z, PEF)
۴	0.883	0.713	PEF, MSFL) (X, Y, Z, DT, GR, NPHI, RHOB,



شکل ۱۵. همبستگی لگاریتم نفوذپذیری افقی حاصل از رگرسیون خطی چندمتغیره با سه متغیر مستقل در مقابل لگاریتم نفوذپذیری مغزه در مرحله آزمون.



شکل ۱۴. همبستگی لگاریتم نفوذپذیری افقی حاصل از رگرسیون خطی چندمتغیره با سه متغیر مستقل در مقابل لگاریتم نفوذپذیری مغزه در مرحله آموزش.

نتایج تحقیق حاضر نشان می‌دهد که استفاده از شبکه طراحی شده در مقایسه با روش رگرسیون خطی چندمتغیره برآورد دقیق‌تری را برای مقادیر نفوذپذیری سنگ‌های تشکیل دهنده مخازن نفتی نتیجه می‌دهد. این موضوع به این علت است که روابط مجهول حاکم بین متغیرهای تاثیرگذار بر نفوذپذیری اغلب غیرخطی است و شبکه‌های عصبی در این گونه موارد که تعداد ورودی‌های موثر بر خروجی نیز زیاد است، بهتر عمل می‌کند.

منابع

تدینی، م.، ربانی، ا. ر. و نبی بیدهندی، م.، ۱۳۸۳، تعیین نفوذپذیری سنگ‌مخزن میدان پارس با استفاده از شبکه عصبی مصنوعی، کنفرانس مهندسی معدن، دانشگاه تربیت مدرس، ص ۱۹۶۵-۱۹۷۸.

جلالی لیچائی، م.، نبی بیدهندی، م. و میرزائی، س.، ۱۳۸۳، برآورد تخلخل و نفوذپذیری میدان نفتی گچساران با استفاده از تکنیک شبکه عصبی، کنفرانس مهندسی معدن، دانشگاه تربیت مدرس، ص ۱۹۷۹-۱۹۹۴.

حسیان، ب.، نبی بیدهندی، م.، و کاظم‌زاده، ع.، ۱۳۸۴، پیش‌بینی نفوذپذیری از روی داده‌های چاه‌نگاری با استفاده از شبکه‌های عصبی مصنوعی در یکی از مخازن کربناته جنوب ایران. مجله فیزیک زمین و فضا، جلد ۳۱، شماره ۱، ص ۷۹-۸۶.

رحیمی، م.، ۱۳۸۱، تعبیر و تفسیر لرزه‌ای ناحیه پارس جنوبی در افق‌های آسماری، جهرم، سروک، داریان، فهلیان، سورمه، کنگان، نار و فراقون. مدیریت اکتشاف، شرکت ملی نفت ایران.

علی‌پور، ر.، مرادزاده، ع.، و مردمی، ه.، ۱۳۸۳، تعیین نفوذپذیری سازند با استفاده از روش تشدید مغناطیسی پروتون، مجموعه مقالات هشتمین همایش انجمن زمین‌شناسی ایران، جلد ۲، ص ۱۴۸-۱۵۶.

همان‌طور که در شکل‌های فوق نمایان است، در مدل خطی حاصل از آنالیز رگرسیونی چندمتغیره، شیب بهترین خط برازش بر داده‌ها در مرحله آموزش (۰/۷۱۵) و مرحله آزمون (۰/۶۳۸) در مقایسه با مقادیر مشابه در روش شبکه عصبی رگرسیونی عمومی به‌طور قابل‌ملاحظه‌ای کمتر است و این موضوع سبب می‌شود که مدل خطی، مقادیر نفوذپذیری را برای مقادیر بیشتر از ۱ میلی‌داریسی به‌طور قابل‌توجهی کمتر و برای مقادیر کمتر از آن، بیشتر برآورد کند و بدین ترتیب خطای برآورد افزایش می‌یابد. بنابراین مقایسه نتایج نفوذپذیری پیش‌بینی شده با نگارهای گوناگون در روش‌های رگرسیون خطی چندمتغیره و شبکه‌های عصبی مصنوعی طراحی شده نشان می‌دهد که شبکه عصبی رگرسیونی عمومی با داشتن ضرایب همبستگی زیادتر، دارا بودن شیب بیشتر برای بهترین خط برازش بر داده‌ها و همچنین تولید خطای برآورد کمتر، برتری لازم برای برآورد نفوذپذیری را دارد.

۵ نتیجه‌گیری

نتایج به‌دست آمده از تحقیق حاضر نشان می‌دهد که شبکه عصبی رگرسیونی طراحی شده با θ و ورودی (X,Y,Z,DT,GR,NPHI,RHOB,PEF,MSFL) و فاکتور هموارساز ۰/۲۷ با توجه به ضرایب همبستگی زیاد و زاویه شیب مناسب بهترین خط برازش شده بر داده‌ها، در پیش‌بینی نفوذپذیری سازندهای کنگان و دالان خوب عمل کرده است. در نتیجه می‌توان از این شبکه برای برآورد و پیش‌بینی نگار نفوذپذیری سازند کنگان و دالان برای چاه‌هایی که به دلیل نبود مغزه‌های سنگی مقادیر نفوذپذیری آنها در این میدان مجهول است، استفاده کرد. مزیت خوب این نوع شبکه‌ها بر شبکه عصبی پرسپترون چندلایه با الگوریتم آموزش پس‌انتشار خطا در این است که در این نوع شبکه‌ها پارامترهای قابل تنظیم کمتر و علاوه بر آن سرعت همگرایی بسیار زیادتر است. همچنین

- Mohaghegh, S. and Ameri, S., 1995, Artificial Neural Network As A Valuable Tool For Petroleum Engineers, SPE29220, Proceedings, SPE, West Virginia.
- Paillet, F. L. and Saunders, W. R., 1990, Geophysical application for geotechnical investigations, ASTM (American Society for Testing and Materials).
- Rolon, L., 2004, Developing Intelligent Synthetic Logs: Application to Upper Devonian Units in PA, M.Sc. thesis, West Virginia University, Morgantown, West Virginia.
- Tiab, D. and Donaldson, E. C., 2004, Petrophysics, theory and practice of measuring reservoir rock and fluid properties, Gulf Publishing Co.
- www.nioc.com/sub_Companies/7_pogc/findex.html, 2007.
- Zhang, Y. Salisch, H. A. and Arns, C., 2000, Permeability evaluation in glauconite- rich formation in the Carnarvon Basin, Western Australia, Geophysics, **65**(1), 46-53.
- مرادزاده، ع.، بخشی، ا.، ۱۳۸۵، شبیه‌سازی نگار فوتوالکتریک سازندهای نفتی به کمک شبکه‌های عصبی مصنوعی، مجله فیزیک زمین و فضا، جلد ۳۲، شماره ۳، ص ۱-۲۰.
- مرادزاده، ع.، و قوامی ریایی، ر.، ۱۳۸۰، چاه‌پیمایی برای مهندسين، دانشگاه صنعتی شاهرود، ۲۴۶.
- Artun, E., Mohaghegh, S. and Toro, J., 2005, Reservoir Characterization Using Intelligent Seismic Inversion, SPE98012, West Virginia University.
- Balan, B., Mohaghegh, S. and Ameri, S., 1995, State- Of- The- Art in Permeability Determination from Well Log Data, Part 1, A Comparative Study, Model Development, SPE 30978, SPE Eastern Regional Conference and Exhibition, Morgantown, West Virginia.
- Bhatt, A., 2002, Reservoir properties from well logs using neural networks, A dissertation for the partial fulfillment of requirements for the degree of PhD at the Department of Petroleum Engineering and Applied Geophysics, Norwegian University of Science and Technology.
- Brace, W. F., 1977, Permeability from resistivity and pore shape, Journal of Geophysical Research, **82**, 3343-3349.
- Burns, D. R., Cheng, C. H., Schmitt, D. P. and Toksoz, M. N., 1988, Permeability estimation from full wave acoustic logging data, The log analyst, 112-122.
- Demuth, H. and Beale, M., 2002, Neural Network Toolbox For Use with MATLAB, User's Guide Version 4.
- Huang, Z. and Williamson, M. A., 1994, Geological pattern recognition and modeling with a general regression neural network, Canadian Journal of Exploration Geophysics, **30**(1), 60-68.
- Huang, Z., Shimeld, J., Williamson, M. and Katsube, J., 1996, Permeability prediction with artificial neural network modeling in the Venture gas field, offshore eastern Canada, Geophysics, **61**(2), 422-436.
- Kumar, N., Hughes, N. and Scott, M., 2000, Using well logs to infer permeability, Center for Applied Petrophysical Studies, Texas Tech University.
- Mohaghegh, S., 2000, Virtual- Intelligence Applications in Petroleum Engineering: Part I- Artificial neural networks, Journal of Petroleum Technology, 64-73.