

## برآورد توزیع تخلخل مخزن از نشانگرهای لرزه‌ای با استفاده از مدل

### عصبی - فازی NEFPROX در دشت گرگان

احمد اشتری تلخستانی<sup>۱</sup>، مجید نبی بیدهندی<sup>۲\*</sup> و جواد جمالی<sup>۳</sup>

<sup>۱</sup> دانش‌آموخته کارشناسی ارشد ژئوفیزیک، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

<sup>۲</sup> استاد، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

<sup>۳</sup> کارشناس ارشد مهندسی نفت، شرکت ملی نفت ایران، مدیریت اکتشاف، تهران، ایران

(تاریخ دریافت: ۱۳۸۹/۲/۱۸، تاریخ پذیرش: ۱۳۸۹/۱۰/۷، دسترسی برخط: ۱۳۸۹/۱۲/۲۵)

#### چکیده

برآورد توزیع تخلخل مخزن در فواصل بین چاه‌ها در تعیین دقیق گسترش جانبی مخزن و در نتیجه در برآورد میزان ذخیره هیدروکربوری و برنامه‌ریزی برای بهره‌برداری از مخزن، از اهمیت اساسی برخوردار است. یکی از دقیق‌ترین روش‌هایی که تاکنون برای این منظور به کار رفته، استفاده از برآوردگر غیرخطی مانند شبکه عصبی و مدل‌های عصبی - فازی برای برآورد پارامتر پیش‌گفته از نشانگرهای لرزه‌ای است. شبکه‌های عصبی و مدل‌های عصبی - فازی هر دو برآوردگرهای غیرخطی خوبی هستند، اما مدل‌های عصبی - فازی یک مزیت نسبت به شبکه‌های عصبی دارند و آن تفسیرپذیری مدل عصبی - فازی است. در این تحقیق از مدل عصبی - فازی NEFPROX برای برآورد تخلخل در یک مخزن گازی در دشت گرگان استفاده شده است. با توجه به مقاطع تخلخل به دست آمده، دو کانال ماسه‌ای و ماسه‌ای - رُسی با تخلخل نسبتاً کم در واحد زمین‌شناسی Brown Beds به وضوح قابل تشخیص است و تغییرات جانبی آنها را در این مقطع می‌توان دنبال کرد. مغزه‌های حاوی هیدروکربن که از چاه GO3 گرفته شده‌اند، وجود دو کانال پیش‌گفته را تأیید می‌کنند. نتایج برآورد تخلخل با این مدل عصبی - فازی نشان می‌دهد که دقت آن تقریباً برابر دقت شبکه عصبی MLP برای برآورد تخلخل است ولی از دقت شبکه عصبی RBF برای برآورد تخلخل بیشتر است.

واژه‌های کلیدی: تخلخل، مدل عصبی - فازی NEFPROX، نشانگرهای لرزه‌ای، دشت گرگان

### Prediction of reservoir porosity distribution from seismic attributes using NEFPROX neuro-fuzzy model in the Gorgan Basin

Ahmad Ashtari Talkhestani<sup>1</sup>, Majid Nabi-Bidhendi<sup>1\*</sup>, and Javad Jamali<sup>2</sup>

<sup>1</sup>Institute of Geophysics, University of Tehran, Iran

<sup>2</sup>National Iranian Oil Company, Exploration Directorate, Tehran, Iran

(Received: 08 May 2010, accepted: 28 December 2010, available online: 16 March 2011)

#### Summary

Prediction of spatial distribution of porosity in a reservoir is an essential issue for estimating reserves and planning production operations. In most cases, however, lateral variations of porosity cannot be delineated from measurements made at sparsely located

\*Corresponding author:

mnbhendi@ut.ac.ir

\*نگارنده رابط:

wells. The integration of 3D seismic data with petrophysical measurements can significantly improve the spatial description of porosity. In the last two decades, several methods have been developed for the estimation of reservoir porosity. A number of inversion methods are available in the industry to convert seismic amplitude into acoustic impedance. Acoustic impedance is indirectly related to porosity. Alternate integrative approaches for estimating porosity include geo-statistical methods, such as kriging and co-kriging using well and seismic data. One of the most accurate methods for estimating reservoir parameters is the application of seismic attributes by a nonlinear estimator, such as neural network or neuro-fuzzy model. Both neural networks and neuro-fuzzy models can be good estimators but the latter has the benefit of being interpretable. In this study, a neuro-fuzzy model called NEFPROX was used to estimate porosity in a gas reservoir located in the Gorgan Basin.

NEFPROX is a Mamdani-type neuro-fuzzy model, so it has an advantage of being interpretable that makes it distinct from other type of neuro-fuzzy models. The time-consuming characteristic of that method is irrelevant in this case because the prediction of porosity is an offline prediction problem.

The Gorgan Basin is located in the northern part of Iran, southeast of the Caspian Sea. This area consists mainly of three formations: the upper formation, called Clay-Sand Group I, belongs to quaternary period. Below Clay-Sand Group I is a tertiary formation called Clay-Sand Group II. A formation of Brown Beds is also a tertiary formation that lies below Clay-Sand Group II. All of these formations consist mainly of shale and sand. The discovery of gas in the Brown Beds Formation has persuaded explorationists to increase their activities in the Gorgan Basin. The purpose of this study is to recognize shale and sand bodies in the Brown Beds formation that consists of alternative sand and shale layers with variable thickness.

First, a list of 20 seismic attributes was prepared to extract from raw seismic data in the location of wells. Stepwise regression was used to select four appropriate attributes. The maximum number of attributes was set at four to avoid the model complexity. These attributes, in the order of priority, are instantaneous frequency, amplitude weighted frequency, apparent polarity, and second derivative instantaneous amplitude. Then these four selected attributes were introduced into the neuro-fuzzy model as input to predict porosity as an output of the model.

The neuro-fuzzy model was trained with the data of well GO3. Based on hydrocarbon core samples obtained from the Brown Beds formation and the potential of this formation as a probable reservoir, the data corresponding to this formation were selected as a training data. A model blind test was also conducted with the data of well GO5.

Porosity sections generated as the output of the model showed two low porosity sandy and shaly-sand channels in the Brown Beds formation. Lateral variations of these channels can clearly be recognized in these sections. The core samples available in well GO3 (containing hydrocarbon) confirm the existence of the two inferred channels. This clear image of channels is simply unidentifiable from raw seismic data. Hence, NEFPROX can be very helpful in supplying valuable information about extent, shape and lithological variation of a reservoir. Finally, compared comparison was made between the performance of the neuro-fuzzy model and regular neural networks in estimation of porosity. The comparison indicates that the accuracy of the NEFPROX estimation is equal to that of MLP and is greater than that of RBF.

**Key Words:** Porosity, NEFPROX neuro-fuzzy model, seismic attributes, Gorgan Basin

## ۱ مقدمه

نیست. پیشرفته‌ترین روش برای تبدیل دامنه لرزه‌ای به مقاومت لرزه‌ای استفاده از فنون بهینه‌سازی سراسری مانند الگوریتم ژنتیک برای تبدیل داده‌های پیش از برانبارش است (سِن و استفا، ۱۹۹۵؛ مَک گُرمَک و همکاران، ۱۹۹۹). این فنون قدرت وارون‌سازی را به‌نحو چشم‌گیری افزایش می‌دهند اما حجم محاسبات زیادی دارند. استفاده از نشانگرهای لرزه‌ای مانند AVO، همدوسی و بسامد به همراه دامنه لرزه‌ای روش دیگری برای بهینه ساختن برآورد خواص کشسانی مخزن است. البته این روش نیز به یک مدل فیزیکی برای ایجاد ارتباط بین نشانگرها و داده‌های چاه نیاز دارد.

روش دیگری که می‌توان داده‌های چاه و داده‌های لرزه‌ای را با یکدیگر ترکیب کرد، استفاده از فنون زمین‌آماری مانند کریجینگ (Kriging) و کوکریجینگ (Co-kriging) است. در اواخر دهه هشتاد میلادی، تک‌نشانگرهای لرزه‌ای به‌منظور برآورد داده‌های چاه با استفاده از فنون زمین‌آماری به‌کار گرفته شدند (دوین، ۱۹۸۸؛ دوپرل، ۲۰۰۰). البته دقت برآورد این روش نیز چندان زیاد نبود، زیرا فقط از یک نشانگر لرزه‌ای برای برآورد استفاده می‌شد. بنابراین در اوایل دهه نود میلادی، ایده استفاده از بیش از یک نشانگر مطرح شد و به‌این‌ترتیب قدرت برآورد نگارهای چاه افزایش یافت. این ایده را اولین بار شالتز و همکاران (۱۹۹۴a, b) و رونن و همکاران (۱۹۹۴) عرضه کردند. تاکنون چندین تحقیق موردی با موضوع برآورد داده‌های چاه با استفاده از وایازش (رگرسیون) گام‌به‌گام (stepwise regression) و شبکه عصبی (راسل و همکاران، ۱۹۹۷؛ همپسون و همکاران، ۲۰۰۱) به انجام رسیده است. در این تحقیق، برآورد تخلخل با استفاده از نشانگرهای چندگانه مدل عصبی-فازی NEFPROX مورد بررسی قرار گرفته و سپس نتایج آن با نتایج حاصل از شبکه‌های عصبی معمول مقایسه شده است.

برآورد تخلخل مخازن هیدروکربوری برای تعیین گسترش جانبی مخزن و برنامه‌ریزی برای حفر چاه و بهره‌برداری هیدروکربن از مخزن ضروری است. در برخی موارد نمی‌توان تغییرات جانبی تخلخل را فقط از اندازه‌گیری‌های درون چاهی مشخص کرد. زیرا زمین‌شناسی مخزن پیچیده است و درعین حال تعداد چاه‌هایی که به این منظور به‌کار می‌روند نیز محدود است. بنابراین درون‌یابی ساده بین این چاه‌ها برای این منظور چندان مفید نیست. به‌کارگیری توأم داده‌های لرزه‌نگاری سه‌بُعدی و داده‌های چاه، برآورد توزیع تخلخل در مخزن را بهبود می‌بخشد. داده‌های لرزه‌نگاری سه‌بُعدی، برخلاف داده‌های چاه، نمونه‌برداری متراکم و منظمی از خواص کشسانی مخزن به‌دست می‌دهند. پس از پردازش داده‌ها، می‌توان با به‌کارگیری داده‌های چاه، تغییرات جانبی دامنه داده‌ها را به مقاومت لرزه‌ای تبدیل کرد. همان‌طور که می‌دانیم، مقاومت لرزه‌ای نیز به‌طور غیرمستقیم با تخلخل رابطه دارد (آنجلیر و کارپی، ۱۹۸۲). در صنعت چندین روش وارون‌سازی برای تبدیل دامنه لرزه‌ای به مقاومت لرزه‌ای وجود دارد. اغلب این روش‌ها بر پایه مدل هم‌میخت (Convolution) یک‌بُعدی هستند که ابتدا ضریب بازتاب زمین استخراج، و سپس تبدیل به مقاومت لرزه‌ای می‌شود (لیندست، ۱۹۷۹؛ پرامانیک و همکاران، ۲۰۰۲). مشکلات اساسی استفاده از این نوع وارون‌سازی عبارت است از محدود بودن طیف داده‌های لرزه‌ای، وجود نوفه، غیر یکتا بودن جواب وارون‌سازی و وابسته بودن فوق‌العاده آن به مدل اولیه (آندرسون، ۱۹۹۶). به‌علاوه مقاومت لرزه‌ای محاسبه شده از متغیرهای زمین‌شناسی زیادی مانند سنگ‌شناسی، سیال درون حفرات، فشار حفرات و دما متأثر می‌شود. بنابراین، برآورد تخلخل فقط از راه مقاومت لرزه‌ای که از داده‌های لرزه‌ای سه‌بُعدی پس برانبارش تولید شده است، چندان معتبر

## ۲ روش‌شناسی

در این تحقیق، داده‌های چاه‌ها و همچنین نشانگرهای لرزه‌ای در محل چاه‌ها درحکم مجموعه داده‌های آموزش در نظر گرفته می‌شوند. البته داده‌های همه چاه‌ها برای آموزش مدل به کار نمی‌رود، بلکه یک یا دو چاه برای آزمایش مدل و جلوگیری از آموزش بیش از حد (overtraining) نگه داشته می‌شود. شبکه آموزش دیده رابطه غیرخطی بین نشانگرهای لرزه‌ای و داده‌های چاه را بازسازی می‌کند. توجه به این نکته بسیار مهم است که حل دقیق در این روش مورد نظر نیست بلکه بهترین برازش بین برآورد و داده‌های چاه در محل چاه‌ها مورد نظر است. در پایان، این رابطه استخراج شده، بر نشانگرهای چندگانه در کل مکعب سه‌بعدی داده‌های لرزه‌ای اعمال می‌شود تا بتوانیم پارامتر مخزنی مورد نظر را به صورت سه‌بعدی در کل مکعب به دست آوریم.

فن مورد بحث در این مقاله شامل چهار مرحله است:

۱. آماده‌سازی داده‌های لرزه‌نگاری و نگارهای چاه.
۲. واسنجی (کالیبراسیون) نگارهای چاه با داده‌های لرزه‌نگاری.
۳. آموزش داده‌های لرزه‌نگاری به منظور برآورد پارامترهای مورد نظر مخزن در محل چاه‌ها.
۴. به کارگیری مدل آموزش داده شده برای برآورد تخلخل در کل حجم داده‌های لرزه‌ای.


## ۳ سیستم‌های استنتاج فازی

زاده با عرضه مجموعه‌های فازی (زاده، ۱۹۶۵)، اولین بار پایه‌های منطق فازی را بنیان نهاد. سازوکار اولیه‌ای که منطق فازی از آن برای تصویرکردن فضای ورودی به

فضای خروجی استفاده می‌کند، فهرستی از بیانات فازی است که قواعد فازی نامیده می‌شوند. همه قواعد به صورت موازی ارزیابی می‌شوند و ترتیب آنها مهم نیست. استنتاج فازی فرایند فرمول‌بندی کردن تصویرسازی داده‌های ورودی به داده‌های خروجی با استفاده از منطق فازی است. سیستم‌های فازی در دو دسته مجزا تقسیم‌بندی می‌شوند که شامل سیستم‌های فازی ممدتی (ممدتی و آسیلیان، ۱۹۷۵) و تاکاگی- سوگنو (سوگنو، ۱۹۸۵)؛ تاکاگی و سوگنو، ۱۹۸۵) هستند. در شکل ۱ یک سیستم فازی ممدنی همراه با روند ورود و خروج اطلاعات در آن نشان داده شده است.

به منظور تعیین یک مدل فازی مناسب برای یک مسئله خاص، پارامترهای مدل از جمله توابع عضویت و ساختار قواعد باید مشخص شود. برای تعیین این پارامترها می‌توان از دانش اولیه، الگوریتم آموزش و یا ترکیبی از این دو استفاده کرد. اگر بخواهیم از الگوریتم آموزش برای این منظور استفاده کنیم، یک مجموعه داده آموزش به مدل می‌دهیم و همانند آنچه که در شبکه‌های عصبی داریم، پارامترهای مدل را از این راه بهینه می‌سازیم. در این صورت معمولاً اصطلاح مدل عصبی- فازی برای این مورد استفاده می‌شود.

در این تحقیق از نوعی مدل عصبی- فازی به نام NEFPROX برای برآورد تخلخل از نشانگرهای لرزه‌ای استفاده شده است. این مدل عصبی- فازی را نخستین بار ناک و کروس (۱۹۹۷) عرضه کردند. در زیر الگوریتم آموزشی که در این مدل عصبی- فازی به کار می‌رود توضیح داده شده است.



شکل ۱. نمودار سیستم استنتاج فازی ممدنی (راهنمای جعبه ابزار منطق فازی نرم‌افزار Matlab، ۲۰۰۶).

به‌دست آوردن خروجی فازی مدل با استفاده از همه قواعد، نافازی‌سازی.

برای استفاده از این روش، ابتدا یک مدل فازی ممدنی اولیه با تعداد قواعد کافی تشکیل می‌دهیم، سپس ساختار قواعد و پارامترهای مدل را برطبق الگوریتم‌هایی که به ترتیب در زیر آمده‌اند بهینه می‌کنیم.

#### الگوریتم آموزش ساختار قواعد

۱. یک نمونه جدید  $(u_k, y_k)$  از داده‌های آموزش انتخاب شود.
۲. برای هر بُعد داده ورودی، تابع عضویتی که بیشترین درجه عضویت را برای آن داده ورودی به دست می‌دهد پیدا می‌کنیم:

$$\mu_{i_j}^j(u_k) = \max_{l=1, \dots, h_j} \{ \mu_{i_l}^j(u_k) \} \quad (1)$$

که در رابطه (۱)  $\mu_{i_l}^j$  تابع عضویت ورودی  $l$ ام از بُعد  $j$ ام و  $h_j$  تعداد توابع عضویت در بُعد  $j$ ام از فضای ورودی را نشان می‌دهند.

۱. اگر قاعده‌ای با فرض زیر در مجموعه قواعد مدل وجود نداشت، این قاعده را به مجموعه اضافه می‌کنیم.

#### ۴ مدل عصبی-فازی NEFPROX

این مدل در واقع یک مدل فازی ممدنی است که از الگوریتمی خاص برای آموزش پارامترهای آن استفاده می‌شود. در یک سیستم فازی ممدنی، قاعده به صورت زیر بیان می‌شود:

اگر

$$u_1 = A_{i1} \text{ AND } u_2 = A_{i2} \text{ AND } \dots \text{ AND } u_p = A_{ip} \\ y = B_i$$

آن‌گاه

که  $u_1, u_2, \dots, u_p$  در واقع  $p$  ورودی سیستم فازی هستند که در قالب بردار ورودی  $u$  به سیستم وارد می‌شوند و  $l$  نیز خروجی است. اندیس  $i = 1, 2, \dots, M$  روی  $M$  قاعده فازی تغییر می‌کند.  $A_{ij}$  مجموعه فازی را نشان می‌دهد که برای ورودی  $u_j$  در قاعده  $i$  از آن استفاده می‌شود و  $B_i$  مجموعه فازی است که برای خروجی قاعده  $i$  مورد استفاده قرار می‌گیرد. هر سیستم استنتاج فازی (مدل فازی) از پنج مرحله تشکیل شده است که عبارت‌اند از: فازی‌سازی، اعمال عملگرهای فازی بر فرض قواعد و به‌دست آوردن درجه اعتبار هر قاعده، اعمال درجه اعتبار قاعده بر تابع عضویت خروجی و به‌دست آوردن خروجی قاعده،

شرایط پایان تکرار برقرار شود. مراحل این الگوریتم به ترتیب زیر است:

۱. انتخاب یک نمونه جدید  $(u_k, y_k)$  از مجموعه داده‌های آموزش و عرضه آن به مدل فازی و سپس محاسبه خروجی مدل.

۲. تعیین مقدار دلتا برای خروجی مدل:

$$\delta y_k = y_k - \hat{y}_k \quad (5)$$

که  $\hat{y}_k$  خروجی مدل برای ورودی  $u_k$  است. ۱. برای هر قاعده با  $\mu_i^{imp}(u_k, y_k) > 0$  که  $\mu_i^{imp}$  خروجی قاعده در مرحله سوم استنتاج فازی است (در اینجا فرایند بهینه‌سازی فقط برای مجموعه‌های فازی مثلثی با پارامترهای  $a, b$  و  $c$  که به ترتیب ابتدا، رأس میانی و انتهای آن را نشان می‌دهند، داده شده است. اما این مجموعه‌های فازی می‌توانند دوزنقه‌ای یا گاوسی نیز باشند).

الف) مقادیر دلتا را برای پارامترهای  $a, b$  و  $c$  مجموعه‌های فازی خروجی با نرخ یادگیری  $\sigma > 0$  محاسبه می‌کنیم.

$$\delta_b = \sigma \cdot \delta y_k \cdot (c - a) \cdot \mu_i^{imp}(u_k, y_k) \cdot [1 - \mu(y_k)] \quad (6)$$

$$\delta_a = \sigma \cdot (c - a) \cdot \mu_i^{imp}(u_k, y_k) + \delta_b \quad (7)$$

$$\delta_c = -\sigma \cdot (c - a) \cdot \mu_i^{imp}(u_k, y_k) + \delta_b \quad (8)$$

سپس تغییرات را بر مجموعه فازی خروجی مورد نظر اعمال می‌کنیم. البته اگر از قبل قیدهایی برای مقادیر قابل قبول پارامترهای  $a, b$  و  $c$  تعیین کرده‌ایم باید توجه داشت که اعمال تغییرات مورد نظر هیچ‌یک از قیدها را نقض نکند.

ب) مقدار  $\delta_R$  را با استفاده از رابطه زیر به دست می‌آوریم:

$$u_1 = \mu_{l_1}^1 \text{ AND } u_2 = \mu_{l_2}^2 \text{ AND } \dots u_R = \mu_{l_R}^R$$

۲. برای تعیین نتیجه قاعده‌ای که در مرحله قبل به مجموعه قواعد اضافه شد  $\mu_j(y)$  باید تابع عضویتی را که بیشترین درجه عضویت را به ازای خروجی ایدئال به دست می‌دهد، بیابیم:

$$\mu_{lc}(y_k) = \max_{l=1, \dots, g} \{ \mu_l(y_k) \} \quad (2)$$

که در رابطه (۲)  $\mu_l$  تابع عضویت خروجی  $l$  ام و  $g$  تعداد توابع عضویت خروجی است. سپس اگر  $\mu_{lc}(y_k)$  بزرگ‌تر یا مساوی با  $0.5$  بود، نتیجه قاعده مورد نظر را به شکل زیر تشکیل می‌دهیم:

$$y = \mu_{lc} \quad (3)$$

واگر نه برای خروجی، تابع عضویت جدیدی  $\mu_{new}$  تعریف می‌کنیم، به طوری که  $\mu_{new}(y_k) = 1$  و نتیجه قاعده مورد نظر به شکل زیر درمی‌آید:

$$y = \mu_{new} \quad (4)$$

۱. اگر هنوز نمونه‌ای در داده‌های آموزش وجود دارد که در فرایند آموزش شرکت داده نشده است، به مرحله اول برگرد و اگر نه فرایند تولید قواعد را متوقف کن.

۲. در پایان، مجموعه قواعد را ارزیابی می‌کنیم. به این شکل که برای هر قاعده از مجموعه قواعد، میانگین خروجی را فقط برای آن دسته از داده‌های ورودی که نتیجه مرحله سوم استنتاج برای آنها بزرگ‌تر از صفر باشد به دست می‌آوریم. سپس اگر تابع عضویت خروجی وجود داشته باشد که میانگین خروجی به دست آمده، درجه عضویت بیشتری در آن نسبت به تابع عضویت خروجی قاعده مورد نظر داشته باشد، تابع عضویت آن قاعده را با تابع عضویت جدید جایگزین می‌کنیم.

الگوریتم آموزش پارامترها

الگوریتم آموزش با نظارت NEFPROX برای بهینه‌سازی توابع عضویت ورودی و خروجی تکرار می‌شود تا یکی از

سازند برون بدز قرار گرفته است که آن نیز مربوط به دوران ترشیری است. هر سه سازند به‌طور غالب از رُس و ماسه تشکیل شده‌اند. البته سازند مخزنی موردنظر، سازند برون بدز است که مغزه‌های برداشت شده از آن نشان از وجود هیدروکربن دارد. بنابراین در این تحقیق فقط در این سازند، تخلخل برآورد شده است. این سازند از لایه‌های متوالی رُس و ماسه تشکیل شده که ضخامت این لایه‌ها به‌طور جانبی متغیر است و هدف کلی از این تحقیق، به‌دست آوردن این تغییرات جانبی است. اکتشافاتی که در این منطقه صورت گرفته، شامل برداشت داده‌های لرزه‌نگاری دو بُعدی و سه بُعدی و همچنین حفر چند حلقه چاه اکتشافی است. نمونه‌ای از داده‌های لرزه‌ای سه بُعدی و دو بُعدی این منطقه به ترتیب در شکل‌های ۲ و ۳ نشان داده شده است. با اینکه در منطقه چندین چاه وجود داشت اما به‌علت در دسترس نبودن نگارهای همه چاه‌ها، فقط از دو چاه GO3 و GO5 در این تحقیق استفاده شده است. این دو چاه تقریباً ۵۲ کیلومتر از یکدیگر فاصله دارند. در این تحقیق نگار نوترون برای محاسبه تخلخل مخزن در محل چاه‌ها مورد استفاده قرار گرفته است.

## ۶ انتخاب نشانگرهای مناسب

ابتدا بیست نشانگر لرزه‌ای زیر از داده‌های خام لرزه‌ای در محل چاه‌ها محاسبه و استخراج شدند، که عبارت‌اند از:

- کسینوس فاز وزن داده شده با دامنه
- بسامد وزن داده شده با دامنه
- فاز وزن داده شده با دامنه
- قطبش ظاهری
- کسینوس فاز لحظه‌ای
- مشتق
- مشتق دامنه لحظه‌ای
- بسامد میانگین

$$\delta_R = \mu_i^{imp}(u_k, y_k) \cdot [1 - \mu_i^{imp}(u_k, y_k)] \cdot 2[\mu(y_k) - 1] \cdot |\delta_y| \quad (9)$$

(ج) برای هر مجموعه فازی ورودی  $(j = 1, 2, \dots, R)$  با  $\mu^j(u_k) > 0$ ، مقادیر دلتا را برای پارامترهای  $a$ ،  $b$  و  $c$  با نرخ یادگیری  $\sigma > 0$  به‌دست می‌آوریم:

$$\delta_b = \sigma \cdot \delta_R \cdot (c - a) \cdot [1 - \mu^j(u_k)] \cdot \text{sgn}(u_k - b) \quad (10)$$

$$\delta_b = -\sigma \cdot \delta_R \cdot (c - a) \cdot [1 - \mu^j(u_k)] + \delta_b \quad (11)$$

$$\delta_b = \sigma \cdot \delta_R \cdot (c - a) \cdot [1 - \mu^j(u_k)] + \delta_b \quad (12)$$

در روابط بالا تابع  $\text{sgn}(x)$  علامت  $x$  را به‌دست می‌دهد. سپس این تغییرات را بر مجموعه فازی ورودی مورد نظر اعمال می‌کنیم. در اینجا نیز باید توجه داشت که اعمال تغییرات، قیدهای گذاشته شده روی پارامترهای  $a$ ،  $b$  و  $c$  را نقض نکند.

۲. اگر کل نمونه‌های مجموعه داده آموزش به مدل وارد و شرایط پایان تکرار برقرار شده است، تکرار متوقف می‌شود و اگر نه به مرحله اول برمی‌گردد.

## ۵ منطقه مورد بررسی

منطقه‌ای که برای این تحقیق انتخاب شده، دشت گرگان واقع در شمال شهر گرگان است. شواهد به‌دست آمده از این منطقه نشان‌دهنده وجود مخزن گازی در آن است. از لحاظ چین‌شناسی، این منطقه عمدتاً از سه سازند زمین‌شناسی متفاوت تشکیل شده است، سازند زمین‌شناسی رُس - ماسه گروه I که مربوط به دوران کوارترنری است، بالاتر از بقیه سازندها قرار دارد. در زیر آن سازند زمین‌شناسی رُس - ماسه گروه II قرار دارد که مربوط به دوران ترشیری است و در پایین‌ترین قسمت



در مرحله دوم، بهترین جفت‌نشانگر را که شامل نشانگر انتخاب شده در مرحله قبل نیز هست، انتخاب می‌کنیم. معیار ما در این مرحله نیز خطای برآورد است. در مرحله سوم نیز به همین ترتیب بهترین سه نشانگر را که شامل بهترین جفت‌نشانگر در مرحله قبل است، می‌یابیم. این فرایند را تا هرجا که لازم باشد می‌توان ادامه داد.

نمودار خطای آموزش و آزمایش وایزش گام‌به‌گام برای برآورد تخلخل در شکل ۴ نشان داده شده است. همان‌طور که مشاهده می‌کنیم در هر مرحله با انتخاب نشانگر بعدی، هم خطای آموزش و هم خطای آزمایش کاهش یافته‌است. نتیجه فرایند انتخاب نشانگر به روش وایزش گام‌به‌گام به صورت زیر است:

نشانگر اول: بسامد لحظه‌ای

نشانگر دوم: بسامد وزن‌داده شده با دامنه

نشانگر سوم: قطبش ظاهری

نشانگر چهارم: مشتق دوم دامنه لحظه‌ای

قابل ذکر است که در این مرحله و همچنین در همه مراحل بعدی برای آموزش هر یک از مدل‌ها (شبکه‌ها) از داده‌های چاه GO3، و برای آزمایش از داده‌های چاه GO5 استفاده شده است.

#### ۷ برآورد تخلخل با مدل عصبی - فازی NEFPROX

یک مدل عصبی - فازی ممدتی با ۴ ورودی و یک خروجی در نظر گرفته شد. برای هر ورودی و خروجی سه حالت کم، متوسط و زیاد با توابع عضویت مثلثی در نظر گرفته شد تا مدل فازی قابل تفسیر باشد. زیرا تقسیم‌بندی ورودی و خروجی به حالت‌های بیشتر اگرچه کارایی مدل را در برآورد بیشتر می‌کند، اما تفسیرپذیری مدل را سخت‌تر می‌سازد. به‌منظور جلوگیری از آموزش بیش از حد مدل و به‌دست آوردن مدل بهینه، تعداد تکرار الگوریتم آموزش باید تعیین شود. به همین منظور ابتدا با ۵

- بسامد غالب
- فیلتر بسامدی میان‌گذر با حد کم ۵-۱۰ هرتز و حد زیاد ۱۵-۲۰ هرتز
- فیلتر بسامدی میان‌گذر با حد کم ۳۵-۴۰ هرتز و حد زیاد ۴۵-۵۰ هرتز
- فیلتر بسامدی میان‌گذر با حد کم ۵۵-۶۰ هرتز و حد زیاد ۶۵-۷۰ هرتز
- بسامد لحظه‌ای
- انتگرال قدرمطلق دامنه
- رد لرزه با تبدیل فاز ۹۰°
- پوش دامنه
- فاز لحظه‌ای
- انتگرال
- مشتق دوم
- مشتق دوم دامنه لحظه‌ای


سپس از میان آنها چهار نشانگر با استفاده از فن وایزش (رگرسیون) گام‌به‌گام (دراپر و اسمیت، ۱۹۶۶) انتخاب شد. انتخاب تعداد نشانگرهای بیشتر می‌توانست موجب پیچیده شدن بیش از اندازه مدل (شبکه) شود بنابراین حداکثر تعداد نشانگرها برابر با چهار در نظر گرفته شد. فرض کلیدی در این روش این است که اگر بهترین ترکیب M نشانگر از قبل معلوم است، بهترین ترکیب ۱+ M نشانگر، M نشانگر قبلی را نیز در بر دارد. فرایند انتخاب بهترین مجموعه نشانگرها در چند مرحله در زیر توضیح داده شده است.

ابتدا، بهترین تک‌نشانگر را با جست‌وجوی جامع در میان نشانگرها می‌یابیم. برای هر یک از نشانگرها در فهرست، وزن‌های بهینه را با استفاده از روش حداقل مربعات محاسبه می‌کنیم و سپس خطای برآورد را به‌دست می‌آوریم. بهترین تک‌نشانگر، کمترین خطای برآورد را خواهد داشت.




فازی در محل چاه GO5 با تخلخل حاصل از داده‌های چاه‌پیمایی در شکل ۶ با یکدیگر مقایسه شده‌اند. خطای آزمایش مدل در چاه GO5 برابر با ۰/۰۵۶ و ضریب همبستگی بین تخلخل برآورد شده و تخلخل حاصل از داده‌های چاه‌پیمایی برابر با ۰/۴۱ به‌دست آمد.

تکرار شروع کردیم و در هر مرحله ۵ تکرار به تعداد تکرارها اضافه کردیم. مدل عصبی-فازی بهینه با ۱۵ تکرار به‌دست آمد، و تکرار بیشتر موجب خارج شدن مدل از حالت بهینه می‌شد (شکل ۵). خطای آموزش مدل در این حالت برابر با ۰/۰۴۲ و ضریب همبستگی نیز ۰/۴۶ به‌دست آمد. نتیجه برآورد تخلخل با این مدل عصبی-




(الف)




(ب)

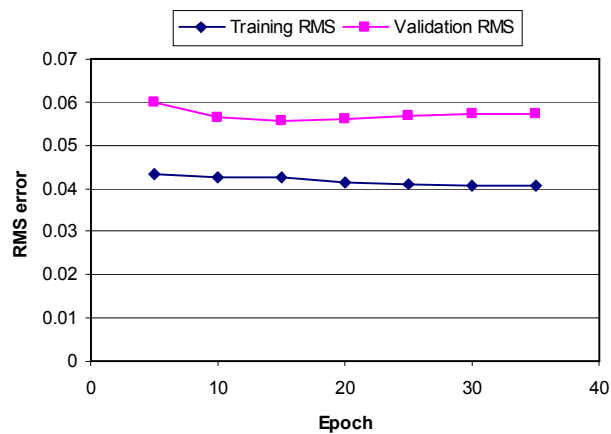
شکل ۲. مقاطع برانبارش شده خام از داده‌های لرزه‌ای سه‌بعدی در محل چاه GO3. (الف) inline شماره ۳۵۶، و (ب) xline شماره ۲۹۲.



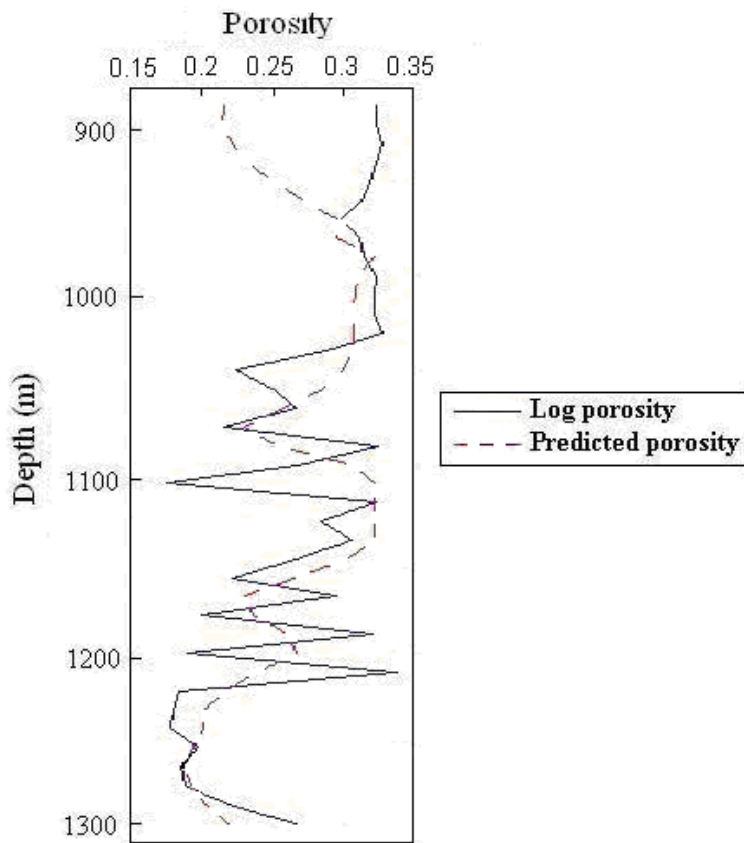
شکل ۳. مقطع برانبارش شده خام از داده‌های لرزه‌ای دو بُعدی در محل چاه G05.



شکل ۴. نمودار خطی آموزشی و آزمایشی و ابازش گام به گام.



شکل ۵. نمودار خطای آموزش و آزمایش مدل عصبی-فازی NEFPROX برحسب تعداد تکرار الگوریتم آموزش.



شکل ۶. مقایسه تخلخل برآورد شده با مدل عصبی-فازی NEFPROX و تخلخل حاصل از داده‌های چاه در محل چاه GO5.

شد، به منظور تفسیرپذیری مدل، برای هر ورودی فقط سه حالت در نظر گرفتیم که البته این مسئله همانطور که در شکل ۶ نیز مشخص است موجب نرم شدن خروجی مدل شده است. این نرم شدن ممکن است موجب پایین آمدن کارایی مدل در برآورد شود؛ البته همیشه این طور نیست. باین حال بسته به مسئله موردنظر، باید دید آیا تفسیرپذیری بودن مدل ارزش بهایی را که باید بابت آن پرداخت، که همان پایین آمدن کارایی برآورد مدل است، دارد؟ تفسیر مدل عصبی - فازی با استفاده از قواعد فازی آن صورت می گیرد. این قواعد فازی در واقع رابطه‌ای که بین ورودی مدل (در اینجا نشانگرهای لرزه‌ای) و خروجی آن (در اینجا تخلخل) وجود دارد را تا اندازه‌ای بازگو می کنند. این قواعد را می توانند برای حصول اطمینان از درستی کار سیستم فازی به کار برد؛ اما این قواعد ممکن است بسیار کارآمدتر باشند. شاید بتوان از این مجموعه قواعد در تفسیر مقاطع لرزه‌نگاری به دست آمده از نشانگرهای لرزه‌ای بهره برد.

عملکرد مدل عصبی - فازی NEFPROX در برآورد تخلخل از نشانگرهای لرزه‌ای در جدول ۱ با نتایج به دست آمده از شبکه‌های عصبی Multi Layer Perceptron (MLP) و Radial Basis Function (RBF) مقایسه شده است.


مقاطع تخلخل برآورد شده inline شماره ۳۵۶ و xline شماره ۲۹۲ از مکعب سه‌بعدی در شکل ۷ نشان داده شده‌اند. با توجه به این مقاطع، می توان دست کم دو کانال ماسه‌ای و ماسه‌ای - رُسی با ضخامت کافی که دارای تخلخل کم (رنگ آبی) هستند در زمینه رُسی (رنگ زرد و نارنجی) در سازند برون بدز تشخیص داد. تغییرات جانبی تخلخل این کانال‌ها را می توان در این مقاطع به خوبی مشاهده کرد. این کانال‌ها چاه GO3 را به ترتیب در ۷۷۵-۷۵۰ ms و ۱۱۰۰-۱۰۶۰ ms قطع می کنند. نشان‌های هیدروکربوری یافت شده در اعماق ۱۶۴۰، ۱۷۴۰، ۲۴۸۰ و ۲۵۰۰ متری از چاه GO3 وجود دو کانال پیش گفته را ثابت می کند. با توجه به برآورد به دست آمده از تخلخل مخزن می توان تصویر واضحی از گسترش سه‌بعدی مخزن به دست آورد. شکل ۲ مقاطع برانبارش شده خام inline شماره ۳۵۶ و xline شماره ۲۹۲ را نشان می دهد، همان طور که می بینیم تغییرات جانبی این کانال‌ها در این مقاطع با این وضوح قابل تشخیص نبوده و به تنهایی اطلاعات کاملی از گسترش مخزن به دست نمی دهد.

مهم ترین مزیت مدل‌های عصبی - فازی ممدنی تفسیرپذیری آنها است، مزیتی که شبکه‌های عصبی فاقد آن هستند و در مدل‌های عصبی - فازی خطی محلی نیز به سختی قابل اجرا است. ما نیز همان طور که در بالا ذکر


جدول ۱. خطای RMS و ضریب همبستگی مدل عصبی - فازی NEFPROX و شبکه‌های عصبی در برآورد تخلخل.

	خطای RMS		ضریب همبستگی	
	آموزش	آزمایش	آموزش	آزمایش
<b>MLP</b>	۰/۰۵۰	۰/۰۵۶	۰/۶۹	۰/۴۲
<b>RBF</b>	۰/۰۵۵	۰/۰۶۱	۰/۶۹	۰/۰۶
<b>NEFPROX</b>	۰/۰۴۲	۰/۰۵۶	۰/۴۶	۰/۴۱





(الف)



(ب)

شکل ۷. مقاطع تخلخل برآورد شده با مدل عصبی-فازی NEFPROX. (الف) inline شماره ۳۵۶، و (ب) xline شماره ۲۹۲.

پیوستگی آنها در همچنین فاصله زیاد نسبت داد. البته نکته‌ای که در اینجا لازم است به آن اشاره شود این است که، خطاها و ضریب همبستگی‌های به‌دست آمده در این تحقیق را نباید با برآوردهایی که روی داده‌های با دقت زیاد صورت می‌گیرد مقایسه کرد. مثلاً برآورد یک نگار از روی یک نگار دیگر به‌طور حتم دقت بسیار بیشتری نسبت به برآوردی که در این مقاله صورت گرفته دارد. زیرا همان‌طور که می‌دانیم، نشانگرهای لرزه‌ای قدرت تفکیک به‌مراتب کمتری نسبت به نگارها دارند و آمیخته با نوفه بیشتری هستند. بنابراین نتایج برآورد به‌دست آمده در اینجا، فقط با موارد مشابه قابل مقایسه است.

#### ۸ نتیجه‌گیری

همان‌طور که در قسمت‌های بالا نشان داده شد، مدل عصبی-فازی NEFPROX توانست تداخل مخزن را با دقت نسبتاً خوبی برآورد کند. تغییرات جانبی دو کانال ماسه‌ای در زمینه رُسی با توجه به تفاوت تداخل در مقاطع تداخل برآورد شده کاملاً مشخص است. همان‌طور که در این مقاطع دیده می‌شود، این کانال‌ها پیوسته نیستند و در بعضی قسمت‌ها درصد رُس فزونی می‌یابد؛ که البته هدف اصلی این روش نیز در واقع همین تفکیک ماسه از رُس به‌منظور تشخیص بهتر مخزن است. چنین تغییراتی در مقاطع خام لرزه‌ای یا قابل تشخیص نیست و یا به سختی تشخیص داده می‌شود. بنابراین این روش به فهم لایه‌بندی زیرسطحی کمک شایانی می‌کند و اطلاعات بسیار مفیدی در مورد وسعت، شکل و تغییرات جانبی لیتولوژی مخزن به‌دست می‌دهد که نتیجه آن کاهش هزینه‌های اکتشاف و تولید، مدیریت بهتر مخزن و تولید کارآمدتر است.

همان‌طور که از این جدول مشخص است در برآورد تداخل، مدل عصبی-فازی NEFPROX و شبکه عصبی MLP کمترین خطای RMS و همچنین بیشترین ضریب همبستگی را در آزمایش نشان داده‌اند. بنابراین نتیجه برآورد تداخل آنها بیشتر قابل اعتماد است. شبکه RBF با اینکه خطای آزمایش متوسطی دارد، ضریب همبستگی بسیار کمی را در آزمایش نشان می‌دهد و این نشان‌دهنده ناتوانی شبکه RBF در تعیین روند تغییرات تداخل است. چند عامل موجب پایین آمدن دقت برآورد مدل در این تحقیق شده است. در ادامه به ذکر این عوامل خواهیم پرداخت. چاه GO3 در قسمتی قرار داشت که داده‌های لرزه‌نگاری سه‌بُعدی برداشت شده بود اما از چاه GO5 تنها یک خط لرزه‌نگاری دو‌بُعدی می‌گذشت که انتهای آن به داده‌های سه‌بُعدی متصل می‌شد، از این‌رو مدل عصبی-فازی ابتدا با داده‌های سه‌بُعدی آموزش یافت و سپس با داده‌های دو‌بُعدی مورد آزمون قرار گرفت. این مسئله اگرچه مشکلی در آموزش مدل ایجاد نمی‌کند اما خود را در آزمایش مدل نشان می‌دهد و موجب کاهش ضریب همبستگی در آزمایش می‌شود. داده‌های لرزه‌ای به‌کاررفته در این تحقیق دارای فاصله نمونه‌برداری ۴ میلی‌ثانیه است که این مسئله به‌دلیل تأثیرپذیری هر نمونه ردلرزه از فاصله عمقی بیشتر موجب فقدان آموزش مناسب مدل شده است. همان‌طور که در شکل ۲-الف مشخص است، وجود گسل و شکستگی در تاق‌دیس مورد بررسی تا حدودی بر کیفیت داده‌های لرزه‌ای در اطراف چاه GO3 تأثیر گذاشته است. همچنین با توجه به فاصله زیاد دو چاه مورد استفاده در آموزش و آزمایش مدل، کاهش یافتن ضریب همبستگی و افزایش خطا در آزمایش مدل را می‌توان به امکان تغییرات جانبی رسوبات و نبود

- Neuro- Systeme'97 - Computational Intelligence. Proc. 4th Int. Workshop Fuzzy-Neuro-Systeme '97 (FNS'97) in Soest, Germany, Proceedings in Artificial Intelligence, Sankt Augustin. Infix, 316-323.
- Pramanik, A. G., Singh, V., Srivastava, A. K., and Rakesh, K., 2002, Post stack seismic inversion for enhancing vertical resolution: *Geohorizons*, **7**, 8-18.
- Ronen, S., Schultz, P. S., Hattori, M., and Corbett, C., 1994, Seismic guided estimation of log properties, part 2: using artificial neural networks for nonlinear attribute calibration: *The Leading Edge*, **13**, 674-678.
- Russell, B., Hampson, D., Schuelke, J., and Quirein, J., 1997, Multiattribute seismic analysis: *The Leading Edge*, **16**, 1439-1443.
- Schultz, P. S., Ronen, S., Hattori, M., and Corbett, C., 1994a, Seismic guided estimation of log properties, part 1: a data-driven interpretation technology: *The Leading Edge*, **13**, 305-315.
- Schultz, P. S., Ronen, S., Hattori, M., Mantran, P., and Corbett, C., 1994b, Seismic guided estimation of log properties, part 3: a controlled study: *The Leading Edge*, **13**, 770-776.
- Sen, M. K., and Stoffa, P. L., 1995, Global optimization methods in geophysical inversion: *Advances in Exploration Geophysics*, **4**, 269-277.
- Sugeno, M., 1985, An introductory survey of fuzzy control. *Information Sciences*, **36**, 59-83.
- Takagi, T., and Sugeno, M., 1985, Fuzzy identification of systems and its applications to modeling and control, *IEEE Trans. Systems: Man & Cybernetics*, **15**, 116-132.
- Zadeh, L. A., 1965, Fuzzy sets: *Information and Control*, **8**, 338-353.
- Anderson, J. K., 1996, Limitations of seismic inversion for porosity and pore fluid: Lessons from chalk reservoir characterization and exploration: 66th Ann. Internat. Mtg., Soc. Explo. Geophys., Expanded Abstracts, 309-312.
- Angelier, G. P., and Carpi, R., 1982, Porosity prediction from seismic data: *Geophysical Prospecting*, **30**, 580-607.
- Doyen, P. M., 1988, Porosity from seismic data-A geostatistical approach: *Geophysics*, **53**, 1263-1275.
- Draper, N. R., and Smith, H., 1966, *Applied regression analysis*: John Wiley & Sons, Inc.
- Dubrule, O., 2000, *Geostatistics in petroleum geology*: AAPG Distinguished Lecture Course Notes, 4-52.
- Hampson, D., Schuelke, J., and Quirein, J., 2001, Use of multiattribute transforms to predict log properties from seismic data: *Geophysics*, **66**, 220-236.
- Lindseth, R. O., 1979, Synthetic sonic logs-A process for stratigraphic interpretation: *Geophysics*, **44**, 3-26.
- Mamdani, E. H., and Assilian, S., 1975, An experiment in linguistic synthesis with a fuzzy logic controller: *Int. J. Man Machine Studies*, **7**, 1-13.
- McCormack, M. D., Stoisits, R. F., MacAllister, D. J., and Crawford, K. D., 1999, Applications of genetic algorithms in exploration and production: *The Leading Edge*, **18**, 716-718.
- Nauck, D., and Kruse, R., 1997, Neuro-fuzzy systems for function approximation: In A. Grauel, W. Becker and F. Belli, eds.: *Fuzzy*

منابع