

کاربرد روش وارون‌سازی لرزه‌ای و بررسی چندنشانه‌گرها در برآورد توزیع تخلخل در

میدان نفتی جنوب غربی ایران

عسل رحیمی زینال^۱ و محمدعلی ریاحی^{۲*}

^۱ دانشجوی کارشناسی ارشد ژئوفیزیک، گروه فیزیک زمین، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

^۲ دانشیار، گروه فیزیک زمین، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

(دریافت: ۸۷۱۱/۲۹، پذیرش نهایی: ۸۹/۷/۲۸)

چکیده

در این تحقیق روش ترکیب داده‌های نگار چاه همراه با مجموعه‌ای از نشانه‌گرهای حاصل از داده‌های لرزه‌ای، به منظور برآورد توزیع تخلخل بررسی شده است. منطقه مورد تحقیق در جنوب غربی ایران واقع است. قبل از پیدا کردن ارتباط بین نگار هدف و نگار به دست آمده از داده‌های لرزه‌ای، داده‌های لرزه‌ای حاصل از منطقه مورد نظر تفسیر شد. سپس داده‌های چاه با داده‌های لرزه‌ای به منظور مدل‌سازی مستقیم و وارون‌سازی لرزه‌ای ترکیب شد. روش وارون‌سازی یک مدل امپدانس صوتی با باند کامل زمین را تهیه می‌کند که باعث افزایش تفکیک پذیری لایه‌های مورد نظر مخزن می‌شود. سپس روش‌های وارون‌سازی با خارهای پراکنده و وارون‌سازی بر مبنای مدل مورد بررسی و استفاده قرار گرفته‌اند. به علت اینکه روش وارون‌سازی بر مبنای مدل دارای نتایج بهتری بود، در حکم روش اصلی تحقیق در نظر گرفته شده است. در مرحله بعدی تبدیل خطی و غیرخطی بین گروهی از نشانه‌گرهای لرزه‌ای و نگار تخلخل برای به دست آوردن حجم تخلخل منطقه مورد نظر به کار رفته است. در نهایت استفاده از روش شبکه عصبی نسبت به تبدیل خطی چندنشانه‌گر پاسخ بهتری به دست داده و روش شبکه عصبی تابع بر مبنای شعاعی (RBFN) برای برآورد توزیع تخلخل در میدان نفتی جنوب غربی ایران به کار برده شده است.

واژه‌های کلیدی: تخلخل، امپدانس صوتی، وارون‌سازی، نشانه‌گر لرزه‌ای، شبکه عصبی، RBFN

Application of seismic inversion and multi attribute analysis to prediction of porosity distribution in an oil field in SW of Iran

Rahimi Zeynal, A.¹ and Riahi, M. A.²

¹ M.Sc. Student of Geophysics, Earth Physics Department, Institute of Geophysics, University of Tehran, Iran

² Associate Professor, Earth Physics Department, Institute of Geophysics, University of Tehran, Iran

(Received: 17 Feb 2009, Accepted: 20 Oct 2010)

Abstract

This paper describes a methodology for the integration of well logs and a series of grid-based attributes extracted from interpreted seismic data for prediction of porosity distributions. The studied area is located in the southwest Iran. Before finding a relationship between the target logs and predicted logs from 3D seismic data, we have interpreted the 3D seismic data in the studied area. Also we matched and combined well data with seismic for forward modeling and seismic inversion. Inversion produces a full band acoustic impedance model of earth which improves the vertical resolution. Then we have checked other different inversion methods such as sparse spike and model based. Since the model based method resulted with a better resolution outcome, therefore we decided to apply model based inversion method in the reservoir level. In the next step we

applied a linear and a non linear transforms between a group of seismic attributes and porosity logs. Then we obtained a relationship for estimating the porosity at all locations of the seismic volumetric data. Finally we found an improvement in the porosity prediction from linear multi attribute transforms when using neural network methods.

Introduction: Nowadays integration of different sources of data and building static and dynamic reservoir models has increased efficiency of exploration and production activities. Seismic reservoir characterization has crucial importance in those activities attributes, their analysis and study form are major field of study in reservoir characterization.

Acoustic impedance is one of the attributes that from some years ago has been used extensively for determination of reservoir properties, especially porosity, fluid saturation and clay content. The idea of using multi attribute seismic analysis to estimate log properties was first introduced (Schultz et al., 1994). The integration of well-log and seismic data has been a consistent aim of geoscientists. One type of integration is forward modeling of synthetic seismic data from the logs. A second type of integration is inversion of the logs from the seismic data which is called seismic inversion. The method for finding the statistical relationship between seismic data and well logs has been described by Russell et al. (1997).

We used this method in an oil field in the southwest of Iran. The data have been supplied by the National Iranian Oil Company (NIOC) and consist of a 3-D seismic data, which ties 6 wells. In this paper we applied model based seismic inversion method.

The Main Description: We interpreted the 3-D seismic data in the studied area by formal Software then depth map were prepared and also appropriate velocity field. Synthetic seismogram method is used for horizon identification. Understanding of reflection characters is essential for tracking of target horizons in the whole area. The 3-D seismic volume was interpreted at different horizons and was reproduced by the model based inversion method.

The training data set for each well consist of the real porosity, a single composites seismic trace that was extract from the 3-D seismic volume around the well and the impedance log predicated with the seismic inversion method. The attributes available for the multi attribute analysis was 25 plus external of seismic inversion.

The cross plot of the target porosity value against predicted porosity from five seismic attributes (Cosine Instantaneous Phase, 1/Inversion-Result, Filter 25/30-35/40, Derivative Instantaneous Amplitude, Amplitude Weighted Phase) are shown in Figure 5. The normalized correlation is now 0.74 For improving the result we used the radial basis function neural network (RBF) method, the RBFN, described by Powell,1987, and first applied by Ronen et al, 1994, is a feed-forward network where the Gussian bell curve is the basis function.

Conclusions: In this study we have focused mainly on 3D seismic interpretation of gas bearing layer by using different seismic inversion and multi attribute transform methods, the acquired results are as follow:

1. The optimum number of attributes in this study was five (Cosine Instantaneous Phase, 1/Inversion-Result, Filter 25/30-35/40 Hz, Derivative Instantaneous Amplitude, and Amplitude Weighted Phase).
2. The quality of inverted data (as one of the main input) is very important in multi attribute analysis.
3. We found that correlation coefficient for porosity prediction is improved in RBFN method with respect to multi attribute transform.

Acknowledgments: The authors wish to thank NIOC, Exploration Directorate, and Geophysics Department for supporting this study. We are grateful to Research Council of the University of Tehran for providing full support of this study.

Key words: Porosity, Acoustic impedance, Seismic inversion, Neural network, RBFN

۱ مقدمه

به منطقه موردنظر با استفاده از نرم‌افزار رایانه‌ای مرسوم مورد تفسیر قرار گرفت و سپس نقشه عمقی و سرعت متناسب با منطقه تهیه شد. روش لرزه‌نگاشت مصنوعی برای جداسازی افق‌ها مورد استفاده قرار گرفته است که در سرتاسر منطقه جدا کردن افق‌های هدف با در نظر گرفتن نوع بازتاب‌ها صورت می‌گیرد. داده‌های سه‌بعدی لرزه‌ای با ۴ افق اصلی تفسیر شده و سپس با استفاده از روش وارون‌سازی بر پایه مدل، مدل امپدانس صوتی تهیه شده است.

در روش وارون‌سازی بر پایه مدل فرض بر این است که موجک لرزه‌ای شناخته شده باشد و برای هر ردلرزه، مدل لرزه‌ای مصنوعی براساس حدس آغازی امپدانس و موجک شناخته شده تهیه می‌شود، سپس امپدانس تهیه شده به ترتیب اصلاح می‌شود تا اینکه انطباق کامل برقرار شود. در این روش پارامتر کنترل‌کننده، که همان درصد خطای بین مدل امپدانس و ردلرزه است، تعیین می‌کند که چه زمانی الگوریتم باید از حرکت به سمت پاسخ نهایی بایستد و ثابت باقی بماند. در نتیجه وارون‌سازی بر پایه مدل، به‌خصوص در نواحی اطراف چاه در مقایسه با سایر روش‌ها قابل اعتمادتر است.

شکل ۱، یک مقطع از داده‌های سه‌بعدی لرزه‌ای همراه با نتیجه حاصل از وارون‌سازی مقطع پیش‌گفته را، نشان می‌دهد. داده‌های آموزشی چاه‌ها نیز در شکل ۲ نشان داده شده است.

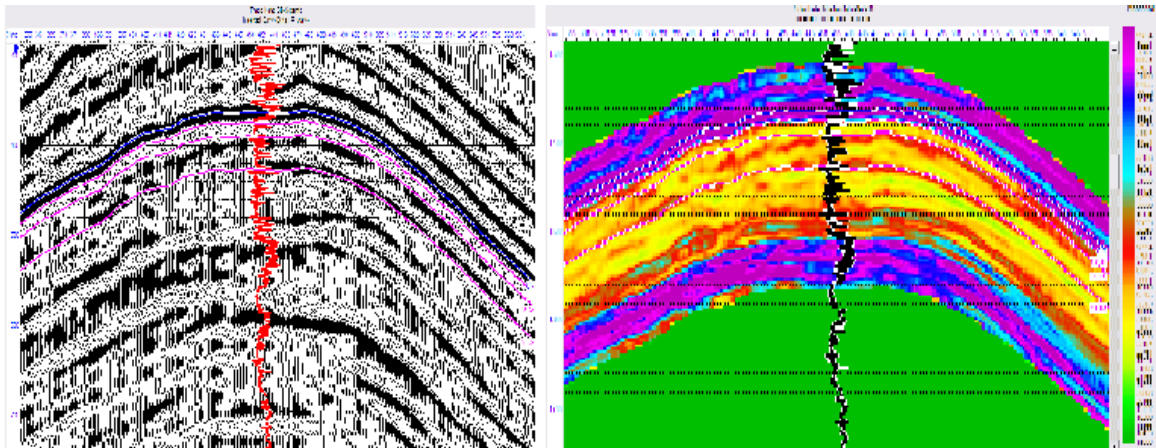
امروزه ترکیب داده مربوط به انرژی‌های گوناگون و تهیه مدل‌های ایستایی و دینامیکی مخزن در فعالیت‌های اکتشافی و تولیدی کاربرد گسترده‌ای پیدا کرده است.

برآورد ویژگی‌های لرزه‌ای مخزن نقش بسیار مهمی در این فعالیت‌ها دارند، نشانگرها و بررسی آنها مهم‌ترین عملکرد را در برآورد ویژگی‌های مخزن دارند. امپدانس صوتی یکی از نشانگرهایی است که از سالیان قبل در به‌دست آوردن ویژگی‌های مخزن از جمله تخلخل، اشباع آب و میزان رُس کاربرد گسترده‌ای داشته است. کاربرد بررسی نشانگرهای لرزه‌ای در برآورد ویژگی‌های نگار چاه را اولین بار توسط شولتز و همکاران (۱۹۹۴) عرضه کرد و ترکیب داده‌های نگار چاه با داده‌های لرزه‌ای از هدف‌های اصلی زمین‌شناسان بوده است.

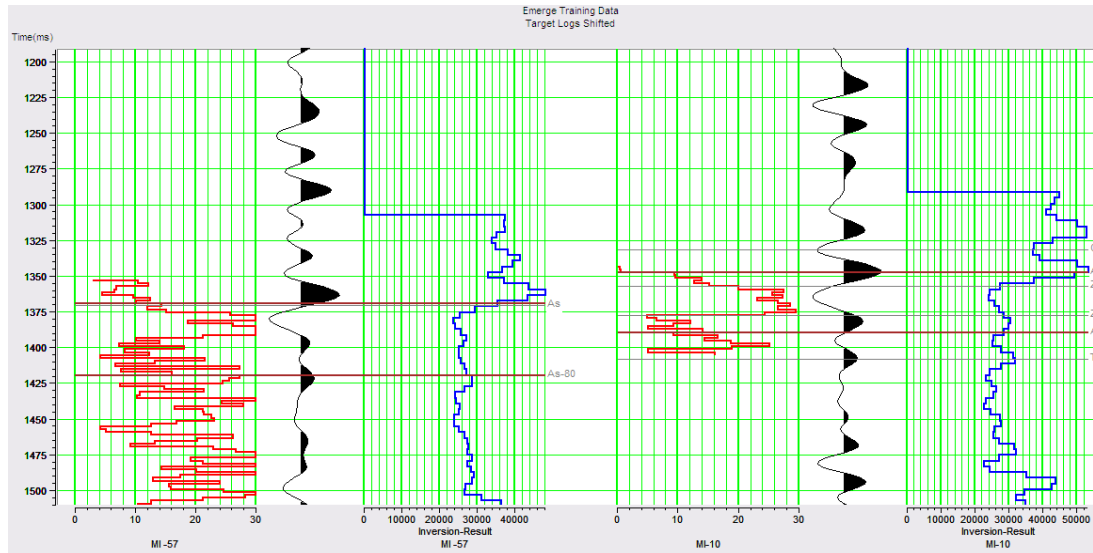
یک نوع ترکیب داده‌ها، مدل‌سازی مستقیم داده‌های مصنوعی لرزه‌ای از داده‌های چاه و نوع دیگر آن، وارون‌سازی داده‌های لرزه‌ای است. روش پیدا کردن ارتباط آماری بین داده‌های لرزه‌ای و نگارهای چاه را راسل و همکاران (۱۹۹۷) عرضه کردند. در این تحقیق، روش وارون‌سازی بر پایه مدل به کار رفته است. در این بررسی سعی می‌شود که از روش‌های ذکر شده در بالا در میدان نفتی جنوب غربی ایران برای تهیه نقشه تخلخل منطقه استفاده شود. داده‌های مورد بررسی در این مقاله را که شامل داده‌های سه‌بعدی لرزه‌ای منطقه و ۶ چاه است، شرکت ملی نفت ایران (NIOC) تهیه کرده است.

۲ روش کلی تحقیق

در ابتدا داده‌های سه‌بعدی لرزه‌ای مربوط



شکل ۱. مقطع داده‌های لرزه‌ای سه‌بعدی (سمت چپ) همراه با مقطع امپدانس صوتی حاصل از وارون‌سازی بر پایه مدل (سمت راست).



شکل ۲. داده‌های آموزشی مربوط به ۲ چاه.

جدول ۱. نتیجه تبدیل چندنشانه‌ها با رگرسیون مرحله‌ای به منظور برآورد تخلخل.


	Target	Final Attribute	Training Error	Validation Error
1	Porosity	Cosine Instantaneous Phase	6.661073	7.756447
2	Porosity	1 / (Inversion-Result)	6.149419	7.431166
3	Porosity	Filter 25/30-35/40	5.866987	7.390995
4	Porosity	Derivative Instantaneous Amplitude	5.513107	7.348148
5	Porosity	Amplitude Weighted Phase	5.190306	7.111189
6	Porosity	Filter 35/40-45/50	5.014175	8.321942
7	Porosity	Second Derivative	4.776351	9.504861
8	Porosity	Filter 45/50-55/60	4.571244	10.153807

There are 8 transforms.


زمانی که همه چاه‌ها در بررسی‌ها استفاده شده‌اند. همان‌طور که انتظار می‌رود با افزایش تعداد نشانگرها منحنی به سمت پایین می‌رود. منحنی بالایی مربوط به خطای اعتبارسنجی است. همان‌طور که در شکل مشخص است با افزایش تعداد نشانگرها به بیش از پنج نشانگر، میزان خطا نیز افزایش می‌یابد. نتیجه کاربرد روش چند نشانگرها با استفاده از ۵ نشانگر در شکل ۴ آورده شده است.

جدول ۱، نتیجه محاسبات رگرسیون مرحله‌ای را نشان می‌دهد که هر سطر مربوط به تبدیل چند نشانگر است و هر سطر مربوط به تبدیل چند نشانگر همان سطر با نشانگرهای بالای آن سطر است، به طوری که در اینجا از ۷ نقطه عملگر مرسوم استفاده شده و بیشترین تعداد نشانگرها در رگرسیون مرحله‌ای ۸ است.

همانند اطلاعات موجود در جدول ۱، شکل ۳ به صورت ترسیمی نتیجه اعتبارسنجی را بیان می‌کند. در شکل ۳ منحنی پایینی مربوط است به خطای پیش‌بینی



شکل ۳. خطای متوسط و اعتبارسنجی همه چاه‌ها.



شکل ۴. نگار تخلخل هر چاه (رنگ مشکی) و نگار تخلخل پیش‌بینی شده (رنگ سرخ) با استفاده از روش چند نشانگرها.

فراهم می‌آورد.

۳ نورون RBF

عملکرد نورون شبکه RBF را می‌توان به دو بخش تقسیم کرد: در قسمت اول فاصله بُردار ورودی $\underline{u} = [u_1 u_2 \dots u_p]^T$ با بُردار مرکز $\underline{c}_i = [c_{i1} c_{i2} \dots c_{ip}]^T$ با توجه به ماتریس انحراف‌های استاندارد ($\underline{\Sigma}_i$) محاسبه می‌شود. این عمل همان سازوکار ساختار شعاعی است که قبلاً به آن اشاره شد. در قسمت دوم، این فاصله x (به صورت نرده‌ای)، به تابع فعال‌ساز غیرخطی $g(x)$ تبدیل می‌شود. در RBF معمولاً از تابع‌ها فعال‌سازی گاوسی به صورت زیر:

$$g(x) = \exp\left(-\frac{1}{2} x^2\right) \quad (1)$$

و معکوس جذر تابع درجه دوم به صورت:

$$g(x) = \frac{1}{\sqrt{x^2 + a^2}} \quad (2)$$

با پارامتر اضافی a استفاده می‌شود.

فاصله x_i به کمک مرکز c_i و ماتریس انحراف‌های استاندارد $\underline{\Sigma}_i$ که پارامترهای لایه پنهان نورون i ام هستند به صورت زیر محاسبه می‌شود:

$$x_i = \|\underline{u} - \underline{c}_i\|_{\underline{\Sigma}_i} = \sqrt{(\underline{u} - \underline{c}_i)^T \underline{\Sigma}_i^{-1} (\underline{u} - \underline{c}_i)} \quad (3)$$

بنابراین تابع شعاعی پایه‌ای $\phi_i(\cdot)$ برای شبکه RBF گاوسی به صورت:

$$\phi_i(\cdot) = \exp\left(-\frac{1}{2} \|\underline{u} - \underline{c}_i\|_{\underline{\Sigma}_i}^2\right) = \exp\left(-\frac{1}{2} \sum_{j=1}^p \frac{(u_j - c_{ij})^2}{\sigma_{ij}^2}\right) \quad \text{و } j = 1, 2, \dots, p \quad (4)$$

خواهد بود.

رسم متقاطع یا Cross Plot تداخل به دست آمده از نگار واقعی و تداخل پیش‌بینی شده با استفاده از ۵ نشانگر در شکل ۵ نشان داده شده است که در این حالت ضریب همبستگی ۰/۷۴ است. برای افزایش صحت پاسخ، از روش شبکه عصبی تابع بر مبنای شعاعی (RBFN) استفاده و نتایج در شکل ۶ نشان داده شده است. این روش را پاول (۱۹۸۷) عرضه کرده است و اولین بار رونن و همکاران (۱۹۹۴) آن را به کار برده‌اند. روش کار به صورت شبکه تغذیه مستقیم در جایی است که منحنی زنگوله‌ای گاوسی به منزله تابع اصلی به کار می‌رود.

شبکه‌های عصبی مصنوعی شامل رده‌ای از فنون غیرخطی اند که نیازی به انتخاب مدل ریاضی از قبل تعیین شده ندارند. در عوض روابط بین متغیرهای ورودی و خروجی آنها در نتیجه الگوریتم ANN به صورت خودکار تعیین می‌شود. بنابراین استفاده از شبکه‌های عصبی انتخابی برای حل مسائلی مناسب است که روابط عددی دقیق بین متغیرهای آنها معلوم نباشد و یا آشکار کردنشان مشکل باشد. ثابت شده است که این فن جدید موفق‌تر از روش‌های سنتی است. تابع‌های شعاعی پایه‌ای (RBF) از سال‌های دور در نظریه برآورد و ریاضیات مورد استفاده قرار گرفته‌اند و اولین بار در ۱۹۸۸ در قالب شبکه‌های عصبی، به کار رفته‌اند. اینکه این تابع‌ها برآوردگرهای عمومی هستند، حدود ده سال است که به اثبات رسیده است. تابع‌های شعاعی پایه‌ای، برای مدل‌سازی داده‌ها (برازش منحنی) از سوی بسیاری از محققان مورد استفاده قرار گرفته است. شوالتر و همکاران (۱۹۹۴) شبکه‌های عصبی RBF را در تحقیقات لرزه‌شناسی توصیف مخزن به کار بردند. در مقایسه با شبکه عصبی MLP، شبکه تابع‌های شعاعی پایه‌ای RBF از یک سازوکار ساختاری شعاعی بهره می‌جوید. این کار تفسیر بهتر پارامترهای شبکه RBF را نسبت به شبکه MLP به دست می‌دهد و بنابراین امکان روش‌های آموزش سریع‌تر و جدیدتر را

RBF (squares) تعیین می‌شود. برای آموزش شبکه‌های RBF می‌توان از روش‌های بهینه‌سازی سراسری مثل الگوریتم‌های ژنتیک (Genetic algorithms) یا Simulated annealing استفاده کرد، از جمله معایب این روش‌ها پرهزینه بودن آنها است. روش کمترین مربعات متعامد (Orthogonal least squares) (OLS) قدرتمندترین آموزش شبکه عصبی RBF به شمار می‌رود.

۵ شبکه RBF نرمال شده

یکی از ویژگی‌های نامطلوب شبکه‌های RBF شیب‌ها در رفتار درون‌یابی است که برای انحراف‌های استاندارد اتفاق می‌افتد و خیلی کوچک است. اینها تقریباً برای فضای ورودی دارای ابعاد بزرگ غیر قابل اجتناب هستند و باعث به وجود آمدن رفتار غیر یکنواختی می‌شود که دور از انتظار است. به علاوه رفتار برون‌یابی شبکه RBF استاندارد که به صفر می‌گراید، برای خیلی از کاربردها مطلوب نیست. این موانع با استفاده از شبکه RBF نرمال شده (NRBF) رفع می‌شوند. دیدیم که شبکه عصبی RBF از تعدادی نورون با تابع‌های فعالیت شعاعی پایه‌ای در لایه پنهان و یک نورون خطی در لایه خروجی تشکیل شده است. در فرم تابع‌های پایه‌ای، رابطه خروجی شبکه RBF نرمال شده به صورت زیر نوشته می‌شود:

$$\hat{y} = \frac{\sum_{i=1}^M w_i \phi_i(\|\underline{u} - \underline{c}_i\|_{\Sigma_i})}{\sum_{i=1}^M \phi_i(\|\underline{u} - \underline{c}_i\|_{\Sigma_i})} \quad (7)$$

که در آن بردار \underline{u} بردار p بُعدی ورودی‌ها، $\phi_i(\|\underline{u} - \underline{c}_i\|_{\Sigma_i})$ یک تابع شعاعی پایه‌ای با مراکز \underline{c}_i است و w_i ها وزن‌های لایه خروجی هستند. $\|\cdot\|$ بیانگر نرم اقلیدسی وزن داده شده با ماتریس انحراف‌های استاندارد Σ_i است. پارامترهای قابل تنظیم مدل NRBF شامل مقادیر مراکز

۴ ساختار شبکه RBF

ساختار شبکه RBF مشابه ساختار لایه‌ای شبکه MLP است. در شبکه‌های RBF، وزن‌ها فقط بین لایه خروجی و لایه پنهان قرار خواهند گرفت.

شبکه عصبی RBF از تعدادی نورون با تابع‌های فعالیت شعاعی پایه‌ای در لایه پنهان و یک نورون خطی در لایه خروجی تشکیل شده است. خروجی شبکه RBF به صورت زیر قابل محاسبه است:

$$\hat{y} = \sum_{i=1}^M w_i \phi_i(\|\underline{u} - \underline{c}_i\|_{\Sigma_i}) \quad (5)$$

$$\phi_0(\cdot) = 1 \quad (6)$$

که در آن w_i وزن‌های لایه خروجی است. پارامترهای لایه خروجی شامل بردار مرکز \underline{c}_i با توجه به موقعیت نام تابع پایه‌ای و ماتریس نرم Σ_i است.

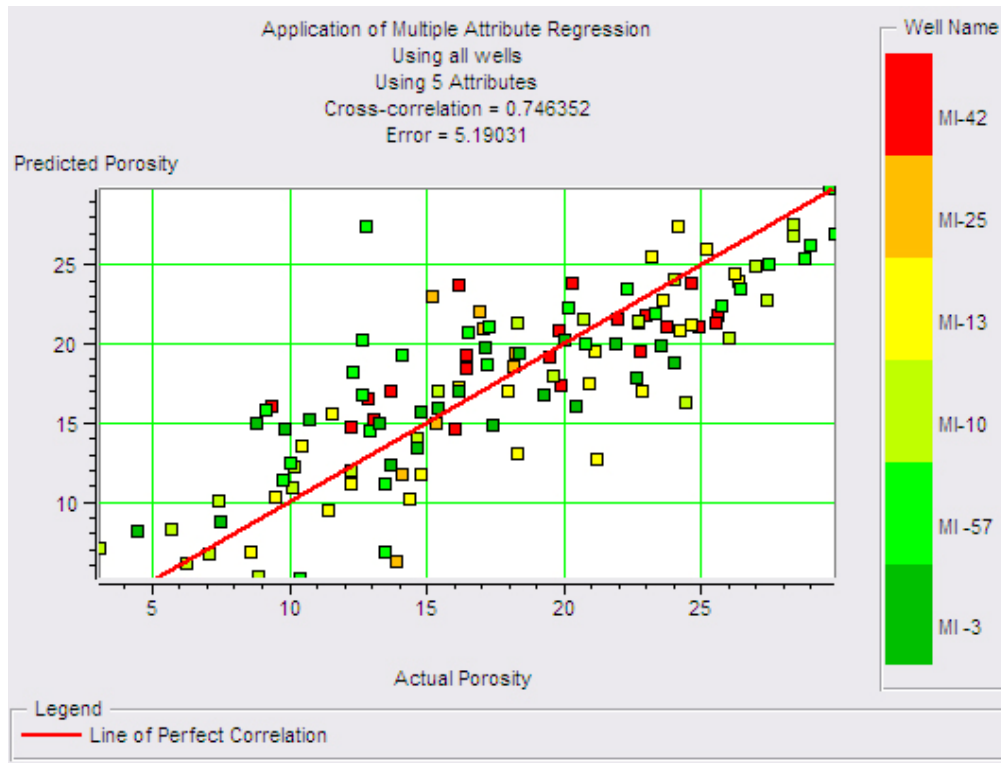
مشابه شبکه‌های عصبی MLP، شبکه RBF یک برآوردگر عمومی است.

شبکه عصبی RBF شامل سه نوع پارامتر است:

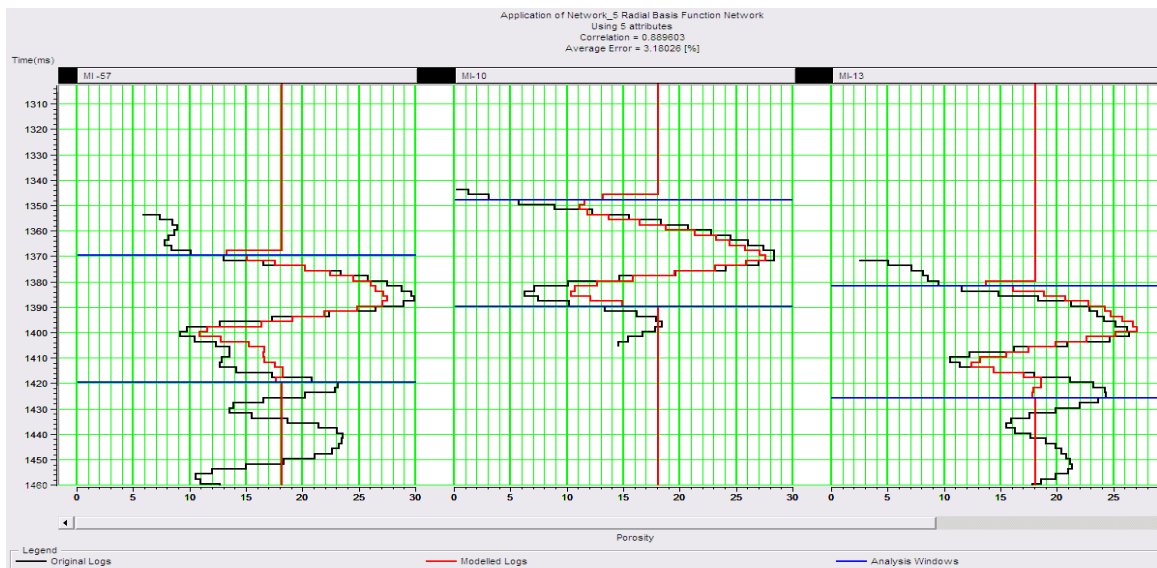
- وزن‌های لایه خروجی که پارامترهای خطی هستند. این وزن‌ها ارتفاع تابع‌های فعال‌ساز پایه‌ای و مقدار دورافت را تعیین می‌کنند.
- مراکز که پارامترهای غیر خطی نورون‌های لایه پنهان هستند. این مراکز موقعیت تابع‌های شعاعی پایه‌ای را تعیین می‌کنند.
- انحراف‌ها از استاندارد که پارامترهای غیر خطی نورون‌های لایه پنهان هستند. آنها عرض تابع‌های پایه‌ای را تعیین می‌کنند.

این پارامترها در حین آموزش شبکه RBF بهینه‌سازی یا تعیین می‌شوند. برای آموزش شبکه‌های RBF راهبردهای گوناگونی وجود دارد. اکثر این راهبردها ابتدا پارامترهای لایه پنهان را تعیین می‌کنند و به دنبال آن وزن‌های لایه خروجی به روش کمترین مربعات (Least

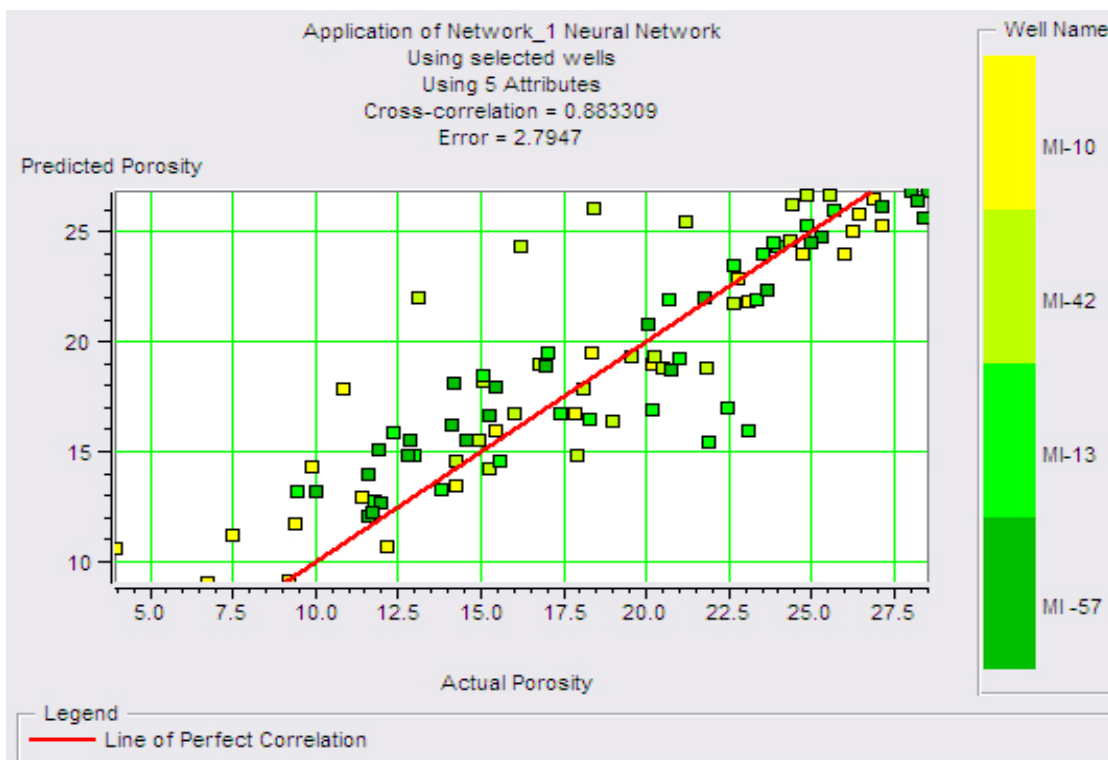
گاوسی (c_{ij} ها)، انحراف‌های استاندارد (σ_{ij} ها) و وزن‌های لایه خروجی به نورون خطی (w_{ij} ها) هستند. شکل ۶ ترسیم متقاطع تخخلخل نگار هدف با تخخلخل پیش‌بینی شده از روش RBFN را نشان می‌دهد که در این حالت ضریب همبستگی ۰/۸۸ است.



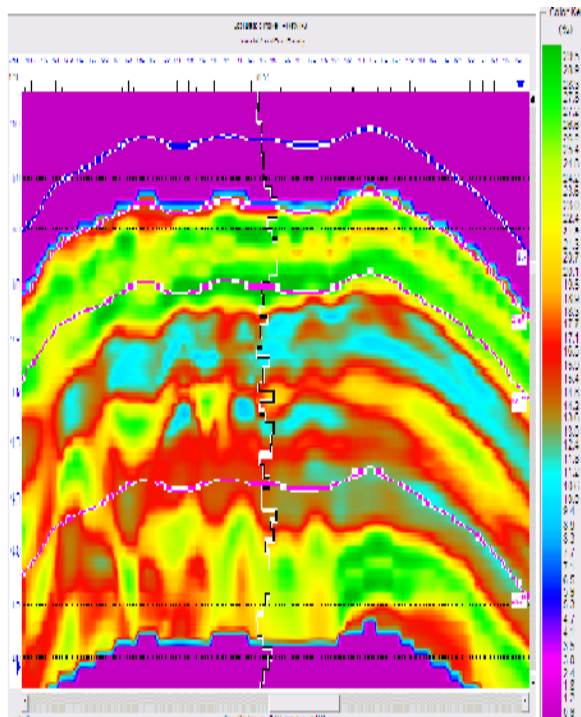
شکل ۵. ترسیم متقاطع با استفاده از چندشانگراها.




شکل ۶. نگار تخخلخل هدف و نگار تخخلخل پیش‌بینی شده با استفاده از روش RBFN.



شکل ۷. ترسیم مقاطع با استفاده از شبکه عصبی.



شکل ۹. مقطع تخلخل حاصل از روش RBFN.



شکل ۸. مقطع تخلخل حاصل از تبدیل چندشانگراها.

هیدروکربوری از نوع نفت است.

۶ نتیجه گیری

در این تحقیق هدف اصلی تفسیر سه بُعدی لرزه‌ای لایه‌های گازدار موجود در منطقه مورد نظر با استفاده از روش‌های وارون‌سازی و تبدیل چندنشانگرها به پارامترهای پتروفیزیکی مخزن بود و نتایج زیر به دست آمد:

۱- بهترین تعداد نشانگرهای مورد استفاده ۵ بوده است:

- کسینوس فاز لحظه‌ای (Cosine Instantaneous Phase)

- معکوس نتیجه وارون‌سازی (1/Inversion-Result)

- فیلتر ۳۵/۴۰-۲۵/۳۰ (Filter 25/30-35/40 Hz)

- دامنه لحظه‌ای فرعی (Derivative Instantaneous Amplitude)

- فاز وزنی دامنه (Amplitude Weighted Phase)

۲- کیفیت داده‌های وارون‌سازی شده در حکم داده ورودی

در بررسی چندنشانگرها بسیار مهم است

ضریب همبستگی مربوط به تخلخل پیش‌بینی شده در

روش RBFN نسبت به روش چندنشانگر افزایش قابل

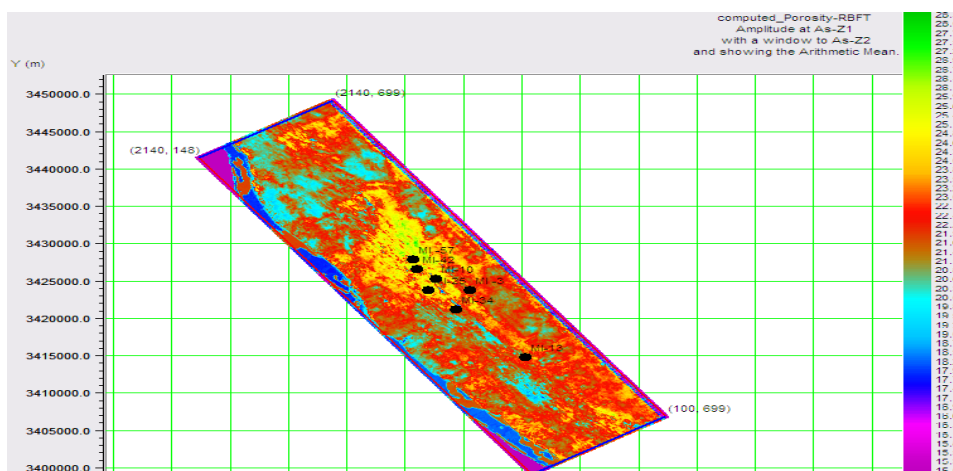
توجهی نشان داد و با توجه به اینکه روش RBFN ضریب

۸۸٪ را به دست داد، نتیجه حاصل از آن مطلوب تر از

روش چندنشانگر ارزیابی می‌شود.

شکل‌های ۸ و ۹ مقطع لرزه‌ای تخلخل پیش‌بینی شده با استفاده از نشانگرها را نشان می‌دهند. شکل ۸ مربوط به تبدیل خطی چندنشانگرها و شکل ۹ مربوط به برآورد تخلخل با استفاده از روش شبکه عصبی RBFN است. هر دو شکل نشان می‌دهند که استفاده از روش RBFN دارای نتایج بهتر و مطلوب‌تری نسبت به روش چندنشانگرها است.

شکل ۱۰ یک برش از مکعب تخلخل حاصل از روش RBFN در لایه گازدار است. همان‌طور که در شکل مشخص است، نواحی زردرنگ دارای تخلخلی در حدود ۲۴٪، نواحی سرخ دارای تخلخل ۲۱٪ و نواحی آبی دارای تخلخل در حدود ۱۹٪ هستند. یکی از مهم‌ترین فاکتورها در تعیین حجم ذخیره مخازن تخلخل است. تخلخل در موارد طبیعی می‌تواند از ۸۰ درصد برای رسوبات نرم کف اقیانوس‌ها تا کمتر از ۱ درصد در بعضی از سنگ آهک‌های بلورین تغییر کند. تخلخل در مخازن بین ۵ تا ۴۰ درصد و به‌طور معمول بین ۱۰ تا ۲۰ درصد متغیر است (نلسون و کیلبر، ۲۰۰۳). با توجه به بررسی‌های صورت گرفته مخزن مورد نظر دارای تخلخلی در حدود ۲۰٪ است که به بخش کرسست و شمالی میدان مربوط می‌شود که از نظر مخزنی این سازند دارای پتانسیل



شکل ۱۰. برشی از مکعب تخلخل حاصل از روش RBFN، نقاط سیاه‌رنگ محل چاه‌های حفر شده را نشان می‌دهند و نواحی زردرنگ دارای بیشترین تخلخل در حدود ۲۴٪ هستند.

تشکر و قدردانی

نگارندگان از اعضای شورای پژوهشی دانشگاه تهران که پشتیبان مالی این تحقیق بوده‌اند، تشکر می‌کنند.

منابع

- Nelson, P. H. and Kibler, J. E., 2003, A Catalog of Porosity and Permeability from Core Plugs in Siliciclastic Rocks, USGS, Science for Changing World, Open-file Report 03-420.
- Powell, M. J. D., 1987, Radial basis functions for multivariable interpolation: a review. In J.C. Mason and M.G. Cox (Eds.), Algorithms for Approximation, 143-167. Oxford: Clarendon Press.
- Ronen, S., Schultz, P.S., Hattori, M., and Corbett, C., 1994, Seismic-guided estimation of log properties, Parts 1, 2, and 3: The Leading Edge, **13**, 305-310, 674-678, and 770-776.
- Russell, B., Hampson, D. P., Schuelke, J. S. and Quirein, J. A., 1997, Multi attribute seismic analysis, The Leading Edge, 16, 1439-1443.
- Theory of the Radial Basis Function Neural Network, 2007, Hampson Russell Software Manual.