

بررسی بهبود برآورد تخلخل به کمک ترکیب روش‌های زمین‌آماري با تبدیل نشانگرهای چندگانه

علی حمیدی حبیب^۱، محمدعلی ریاحی^۲ و غلامحسین نوروزی^{*۱}

^۱ دانشکده فنی، دانشگاه تهران، ایران

^۲ موسسه ژئوفیزیک، دانشگاه تهران، ایران

(تاریخ دریافت: ۱۳۸۸/۸/۳۰، تاریخ پذیرش: ۱۳۹۰/۹/۳۰)

چکیده

هدف اصلی این مقاله، برآورد پارامتر تخلخل در یکی از میدان‌های دریایی ایران با روش‌های جدید برآورد پارامترهای مخزنی بود و روشن شد که چگونه می‌توان به کمک روش‌های جدید شبکه عصبی با تلفیق اطلاعات لرزه‌ای و داده‌های چاه‌نگاری به نقشه‌های بهتری از مدل تخلخل در مخازن رسید. در این مقاله با تلفیق اطلاعات لرزه‌ای و نمودارگیری و تعیین همبستگی موثر بین داده‌های چاه و اطلاعات لرزه‌ای معادله ریاضی به‌منظور استخراج پارامترهای مخزنی از اطلاعات لرزه‌ای در مکان چاه‌ها به‌دست آمد، سپس با تعمیم این رابطه به کل ناحیه عملیات لرزه‌ای در زون مخزنی مورد بررسی، نقشه‌های اولیه‌ای از پارامتر تخلخل در محدوده مخزن تهیه شد. در مرحله بعد به کمک زمین‌آمار و استفاده از نقشه‌های اولیه درحکم متغیر ثانویه در روش کولوکیتد کوکریجینگ به نقشه‌های بهتری از توزیع تخلخل دست یافته شد.

واژه‌های کلیدی: تخلخل، پارامتر پتروفیزیکی، نشانگر لرزه‌ای، شبکه عصبی، رگرسیون چندمتغیره، زمین‌آمار

Analysis of improvement of porosity estimation by combining geostatistical methods and multiattribute transforms

Ali Hamidi Habib¹, Mohammad Ali Riahi^{2*} and GholamHossein Norozi¹

¹Faculty of engineering, Tehran University, Iran

²Institute of Geophysics, University of Tehran, Iran

(Received: 21 November 2009, accepted: 21 December 2011)

Summary

During the last decade, there has been an increasing interest in the use of attributes derived from 3-D seismic data to define reservoir properties, such as the presence and amount of porosity and fluid content. Therefore, it is worthwhile to continue the advances in the study and application of expert systems in the petroleum industry so that it is possible to use the attributes in reservoir characterization more effectively. The

*Corresponding author:

norouzih@ut.ac.ir

*نگارنده رابط:

establishment of the existence of an intelligent formulation between two sets of data (inputs/outputs) has been the main topic of such studies. One such topic of great interest was the characterization of 3D seismic data with relation to lithology, rock type, fluid content, porosity, shear wave velocity, and other reservoir properties. Petrophysical parameters, such as water saturation and porosity, are very important data for hydrocarbon reservoir characterization. Hitherto, several researchers endeavored to predict them from seismic data using statistical methods and intelligent systems (Russell et al., 2002; Russell et al., 2003; Chopra and Marfurt, 2006). Correct recognition of porosity model and estimation of petrophysical parameters in reservoirs is a key issue in any oil project. The correct estimation of porosity as a petrophysical parameter can inform decisions that have high financial risk, such as drilling. By determining reservoir characterizations and assessing petrophysical parameters with a adequate accuracy during the first steps of studies, researchers would be able to produce optimum exploitation with a minimum number of wells.

This paper focuses on the link between seismic attributes and reservoir properties such as lithology, porosity, and pore-fluid saturation. Typically, seismic attributes have been the only information obtainable from seismic data. Using statistical rock-physics, the type of seismic attributes that are direct functions (analytically defined) of the elastic properties can be probabilistically transformed, sample-by-sample and independently one of each other, into reservoir properties. In this paper, we combine the methods of geostatistics and multiattribute prediction for the integration of seismic and well-log data, and illustrate this new procedure with a case study. A number of new ideas are developed for the statistical determination of reservoir parameters using seismic attributes, combining the classical techniques of multivariate statistics and the more recent methods of neural network analysis. We first extract average porosity values at the zone of interest, and then compare these values to average seismic attributes over the same zone. The technique of cross-validation is subsequently used to show which attributes are significant. We then apply the results of the training and cross-validation to data slices derived from both the seismic data cube and the inverted cube to produce an initial porosity map. Finally, we improve the fit between the well log values and the porosity map using co-kriging.

The main purpose of this paper is to present a quantitative assessment of porosity as a petrophysical parameter in an offshore oil field in Iran using the newly proposed method of reservoirs parameter estimation. This paper shows that by using both seismic data and well logging data it is possible to obtain a more accurate model of porosity in a given reservoir. Specifically, the study determines the relationship between a set of seismic attributes and a reservoir parameter such as porosity at well locations, and then uses this relationship to compute reservoir parameters from sets of seismic attributes throughout a seismic volume. Therefore, a primary plan of porosity is available for the area of study. In the next step, by using geostatistics and, according to the initial plan, as a secondary variable in collocated cokriging, we can approach a more accurate plan to show the distribution of porosity. In effect, the proposed method combines geostatistics with multiattribute transforms. This technique uses multivariate statistics and neural networks to improve the secondary dataset used in the collocated cokriging technique.

Keyword: Porosity, petrophysical parameters, multiattribute transforms, neural network, multivariate statistics, geostatistics

۱ مقدمه

بررسی موردی این مقاله روی تاقدیس بلال صورت گرفته است. ساختمان بلال در بخش مرکزی خلیج فارس و حدود ۳۰ کیلومتری جنوب شرقی میدان پارس جنوبی قرار دارد. این ساختمان در نزدیکی مرز آبی با کشور قطر و به فاصله ۸۸ کیلومتری جنوب غربی جزیره لاوان و حدود ۷۰ کیلومتری غرب ساختمان رشادت واقع است. در این مقاله به یکی از مسائل بنیادی اکتشافات لرزه‌ای و تولید پرداخته شده است اینکه چگونه می‌توان داده‌های لرزه‌ای را که تفکیک‌پذیری زمانی کم اما پیوستگی فضایی بیشتری دارند با داده‌های چاه‌نگاری که تفکیک‌پذیری زمانی زیاد اما پراکنده‌ای در ناحیه مورد بررسی دارند، باهم تلفیق کرد. این مسئله با استفاده از روش‌های زمین‌آماري از قبیل کوکریجینگ که از نتایج حاصل از تبدیل نشانگرهای چندگانه، درحکم متغیر ثانویه استفاده می‌کنند حل شده است. (همپسون و همکاران، ۲۰۰۱) در روش‌های زمین‌آماري داده‌های چاه به منزله داده‌های اولیه تلقی می‌شوند و داده‌های ثانویه نقشه‌های اولیه توزیع تخلخل حاصل از ترکیب نشانگرهای متفاوت به کمک روش‌های رگرسیون چندمتغیره و شبکه‌های عصبی هستند. برای پیش‌بینی نگارهای چاه از نشانگرهای لرزه‌ای استفاده شده است. بعد از اینکه بهترین روابط بین نشانگرهای لرزه‌ای و پارامتر مخزنی در مکان چاه‌ها، استخراج شد، از این روابط برای به‌دست آوردن پارامتر مخزنی موردنظر در مکان‌های دیگر استفاده شده است. بدین ترتیب نقشه‌هایی از توزیع پارامتر موردنظر در منطقه مورد بررسی به‌دست آمد که در این تحقیق تحت عنوان نقشه‌های اولیه از آنها یاد می‌شود. نقشه‌های اولیه را می‌توان فقط به کمک رگرسیون چندمتغیره و یا استفاده از

نتایج رگرسیون چندمتغیره با روش‌های شبکه عصبی به‌دست آورد. درنهایت از نقشه‌های اولیه برای تولید نقشه‌های نهایی به کمک روش زمین‌آمار استفاده شده است.

۲ نشانگرهای لرزه‌ای

نشانگرهای لرزه‌ای توابع ریاضی مشتق شده از اطلاعات لرزه‌ای هستند که در حوزه زمان و بسامد از داده‌های لرزه‌ای استخراج می‌شوند. این اطلاعات پایه‌ای شامل زمان، دامنه، بسامد و جذب هستند و این خصوصیات پایه، طبقه‌بندی نشانگرها را ممکن می‌سازند. براساس بررسی‌های صورت گرفته، نشانگرهای مشتق شده از دامنه شامل اطلاعات چینه‌شناسی و مخزنی هستند. نشانگرهای مشتق شده از بسامد شامل اطلاعاتی در ارتباط با خصوصیات مخزن هستند. جذب انرژی نشانگر دیگری است که می‌تواند اطلاعاتی را در ارتباط با سیال و نفوذپذیری به‌دست دهد (تتر و همکاران، ۱۹۷۹). یکی از نشانگرهای مهم و اساسی که درحکم اطلاعات لرزه‌ای در روش تلفیق داده‌های لرزه‌ای و روش‌های زمین‌آماري وارد می‌شود، نتایج حاصل از وارون‌سازی است که تحت عنوان مدل مقاومت صوتی زمین از آن یاد می‌شود. مقاومت صوتی یعنی حاصل ضرب سرعت در چگالی لایه. تحقیقات قبلی نشان می‌دهد که نشانگر مقاومت صوتی با تخلخل همبستگی زیادی دارد. بنابراین در این مقاله نیز از این نشانگر درحکم یکی از مهم‌ترین اطلاعات لرزه‌ای به همراه داده‌های سه‌بُعدی لرزه‌ای استفاده شده است برای دستیابی به نشانگر مقاومت صوتی و یا به عبارتی مدل مقاومت صوتی زمین باید داده‌های لرزه‌ای را وارون‌سازی کرد. در مورد وارون‌سازی در بخش بعدی مطالبی را

۳ وارون‌سازی

وارون‌سازی در ژئوفیزیک، به نقشه درآوردن خواص فیزیکی و شکل لایه‌های زمین با استفاده از اندازه‌گیری‌های سطحی تعریف می‌شود (راسل، ۱۹۸۸). این تعریف عمومی برای حالت خاص وارون‌سازی لرزه‌ای، به صورت بازیابی نمودارهای مقاومت صوتی از ردلرزه‌ها بیان می‌شود. وارون‌سازی لرزه‌ای نقش بسیار مهمی در تعبیر و تفسیر لرزه‌ای، تشخیص خصوصیات مخزن، زمان تاخیر لرزه‌ای، پیش‌بینی فشار منفذی و دیگر کاربردهای ژئوفیزیکی دارد. از آنجا که امپدانس صوتی حاصل ضرب چگالی سازند در سرعت آن لایه است، یکی از خصوصیات لایه به حساب می‌آید و در تشخیص لیتولوژی و چینه‌شناسی نقش مهمی می‌تواند ایفا کند. امپدانس صوتی را همچنین می‌توان به صورت مستقیم به خصوصیات لیتولوژی یا خصوصیات مخزنی مانند شبه‌سرعت (Pseudo Velocity)، تخلخل و ویژگی‌های سیال پُرکننده خلل و فرج تبدیل کرد. در داده‌های لرزه‌نگاری ردلرزه‌های که در اختیار داریم حاصل هم‌امیخت موجک فرستاده شده به داخل زمین و پاسخ زمین است که این ردلرزه می‌تواند با نوفه‌های گوناگونی که در مسیر راه خود با آنها مواجه است همراه شود و به گیرنده‌ها برسد

$$T(i) = \sum_j r(j)w(i-j+1) + n(i), \quad (4)$$

که $r(j)$ پاسخ زمین و $w(i)$ موجک فرستاده شده به درون زمین و $n(i)$ نوفه‌های موجود است. همان‌طور که گفته شد کاری که در وارون‌سازی صورت می‌گیرد، استخراج امپدانس صوتی از داده‌های لرزه‌ای است. یعنی ابتدا پاسخ زمین را از داده‌های لرزه‌ای استخراج می‌کنند و سپس با آن امپدانس را به دست می‌آورند. در واقع رابطه بین پاسخ زمین یا همان ضریب بازتاب زمین و مقاومت صوتی به صورت زیر است:

خواهیم آورد. نشانگرهای لحظه‌ای اولین بار تر (۱۹۷۹) با استفاده از نظریه‌هایی که برای کاربردهای مهندسی برق توسعه داده شده بود (براس ول، ۱۹۶۵) از داده‌هایی لرزه‌ای محاسبه کرد. از نشانگرهای متفاوتی در این مقاله استفاده شده است که مهم‌ترین آنها پوش ردلرزه، بسامد لحظه‌ای و فاز لحظه‌ای بوده‌اند. یک ردلرزه تحلیلی مانند $F(t)$ شامل یک بخش حقیقی، $f(t)$ ، و یک بخش مجازی، $g(t)$ است:

$$F(t) = f(t) + ig(t), \quad (1)$$

که $f(t)$ بخش حقیقی است و از داده‌های لرزه‌ای به دست آمده است. $g(t)$ بخش مجازی است و از تبدیل هیلبرت $f(t)$ به دست می‌آید.

با استفاده از این تبدیل، تابعی به دست می‌آید که فقط تابع زمان است و به کمک آن می‌توان نشانگرهای لحظه‌ای را محاسبه کرد. پوش ردلرزه نشانگری است که کل انرژی لحظه‌ای را نشان می‌دهد و اندازه آن در ابعاد اندازه ردلرزه ورودی است. مقدار آن بین صفر و بیشینه دامنه ردلرزه متغیر است و از رابطه زیر محاسبه می‌شود:

$$E(t) = \sqrt{f(t)^2 + g(t)^2}. \quad (2)$$

فاز لحظه‌ای نشانگری است که به صورت $g(t)/f(t)$ Arctan تعریف می‌شود. اطلاعات فاز مستقل از دامنه هستند و فاز انتشار جبهه موج را نشان می‌دهد زیرا معمولاً جبهه موج، با خطوط هم‌فاز تعریف می‌شود.

بسامد لحظه‌ای نشانگری است که نرخ تغییرات فاز لحظه‌ای را بیان می‌کند، به عبارتی مشتق فاز لحظه‌ای است. اما از آنجا که فاز بین ۱۸۰ درجه تغییر می‌کند، بسامد را نمی‌توان مستقیماً از فاز محاسبه کرد. پس به جای اینکه بسامد لحظه‌ای در حکم مشتق فاز محاسبه شود از کتانژانت محاسبه می‌شود.

$$\omega(t) = \frac{\partial [ph(t)]}{\partial t}. \quad (3)$$

$$w_i = \begin{bmatrix} w_i(0) \\ \vdots \\ w_i(L-1) \end{bmatrix},$$

و * عملگر هم‌میخت را نشان می‌دهد. تفاوت بین رگرسیون چندمتغیره معمولی و رگرسیون چندمتغیره با استفاده از عملگرهای هم‌میختی در شکل ۱ نشان داده شده است.

همچنان‌که از شکل ۱ پیداست در رگرسیون چندمتغیره فقط نمونه‌هایی از نشانگرها که به‌صورت زمانی با نمونه‌های نمودار هدف هم‌بسته شده‌اند وارد محاسبات می‌شوند این در حالی است که در روش هم‌میخت مجموعه‌ای از نمونه‌های نزدیک به نمونه نمودار هدف وارد محاسبات می‌شوند. ضرایب عملگر ممکن است از طریق مینیمم‌سازی کمترین مربعات برای برآورد خطا به کار رود. تفسیر معادله (۱) در حقیقت چنین است که به‌کارگیری عملگر هم‌میخت یک رشته جدید از نشانگرها را که به‌صورت ساده نسبت به نشانگرهای اصلی دارای جابه‌جایی هستند، تولید می‌کند.

$$E^2 = \frac{1}{N} \sum_{i=1}^N (L_i - w_0 + w_1 * A_{1i} + \dots + w_M * A_{Mi})^2. \quad (7)$$

۵ شبکه با تابع پایه شعاعی

شکل ۲ شبکه با تابع پایه شعاعی را نشان می‌دهد. در این شبکه سیگنال‌های ورودی مستقیماً وارد سلول‌های لایه مخفی می‌شوند برخلاف (Multi-layer Perceptron) MLP که دارای توابع فعالیت عمومی هستند، توابع فعالیت در این شبکه‌ها هستند. تعداد سلول‌های لایه مخفی از روش سعی و خطا به‌دست می‌آید. در لایه خروجی فقط جمع‌کننده وجود دارد که ورودی‌های آن خروجی سلول‌های لایه مخفی هستند. تعداد سلول‌های لایه خروجی برابر با تعداد خروجی‌ها است. در آموزش این

$$r(j) = \frac{I(j) - I(j-1)}{i(j) + I(j-1)}, \quad (5)$$


که $I(j)$ امیدانس یعنی حاصل ضرب سرعت در چگالی لایه است. در حقیقت در وارون‌سازی تلاش می‌شود که $I(j)$ لایه‌های گوناگون زمین به‌دست آید.

۴ رگرسیون چندمتغیره و شبکه‌های عصبی

در روش رگرسیون چندمتغیره سعی می‌شود بهترین نشانگرها برای پیش‌بینی پارامترهای مخزنی باهم ترکیب شوند. رگرسیون چندخطه را به دو روش می‌توان مورد استفاده قرار داد، اول اینکه از این روش می‌توان مستقیماً برای پیش‌بینی پارامترهای مخزنی استفاده کرد یا اینکه می‌توان از این روش برای به‌دست آوردن بهترین نشانگرها که در روش شبکه عصبی مورد استفاده قرار می‌گیرند، استفاده کرد (همپسون، ۲۰۰۱). روش رگرسیون چندمتغیره را (همپسون و همکاران، ۲۰۰۱)، توسعه دادند. در این روش از فیلترهای هم‌میختی به جای نقاط منفرد در رگرسیون چندمتغیره استفاده می‌شود. این روش معادل ایجاد مجموعه‌ای از نشانگرهای جدید است که نسبت به نشانگرهای اصلی جابه‌جایی زمانی پیدا کرده‌اند که این جابه‌جایی‌های زمانی با فیلترهای هم‌میخت منطبق هستند. رابطه (۶) معادله اصلی رگرسیون چندمتغیره را که همپسون توسعه داده است، نشان می‌دهد. در این رابطه فرض بر این است که وزن‌ها نیز بُردار باشند.

$$t = w_0 a_0 + w_1 * a_1 + \dots + w_M * a_M, \quad (6)$$

که a_i ها بُردار نشانگرها، t بردار هدف و w_i ها بردار وزن‌های L نقطه‌ای با اولین نمونه در زمان $t=0$ هستند که به‌صورت زیر نوشته می‌شوند.




شکل ۱. اختلاف بین رگرسیون چندمتغیره معمولی (a) و رگرسیون چندمتغیره با استفاده از عملگر همایخت (b).

قبلا نیز ذکر شد، این توابع از نوع توابع محلی هستند.

$$\varphi(d) = \exp\left[-\frac{d^2}{\sigma^2}\right], \quad (9)$$

که σ ضریب هموار کننده است. توجه داشته باشید که فاصله در این رابطه، اختلاف بین دامنه نشانگرها به جای فاصله معمولی دکارتی است.



شکل ۲. شبکه با تابع پایه شعاعی.

۶ بررسی موردی

برای دستیابی به هدف تعریف شده در این مقاله، یکی از میدان‌های نفتی فراساحلی جنوب ایران در نظر گرفته شد تعداد ۸ چاه که در مکان‌های مناسبی از این میدان قرار گرفته بودند انتخاب شد. دو عدد از این چاه‌ها علاوه بر نگارهای تخلخل، صوتی، جرم مخصوص و گاما، اطلاعات چکش‌شات نیز داشتند. اطلاعات دیگری که از این میدان در دست بود اطلاعات لرزه‌نگاری سه‌بُعدی میدان مورد بررسی بود. موجک لرزه‌ای با استفاده از دو

شبکه، علاوه بر تنظیم وزنها، نیاز به تنظیم مرکز توابع فعالیت نیز خواهد بود. تنظیم وزن‌ها از روش گرادیان نزولی برطبق کمترین مجموع مربعات خطا و مرکز توابع فعالیت نیز به همین روش تنظیم می‌شود (سیمون، ۱۹۹۹). معایب روش MLP این است که نتیجه نهایی آن به وزن‌های حدس زده شده اولیه وابسته است. با به کارگیری بردار وزن‌ها و بعضی توابع غیرخطی، بردار نشانگرهای ورودی تحت عنوان توابع پایه شعاعی مقادیر عددی حاصل می‌شود که در ارتباط با خصوصیات مخزنی هستند و معایب روش MLP را ندارند.

فن توابع پایه شعاعی شامل انتخاب یک تابع F به صورت زیر است:

$$F(x) = \sum_{i=1}^N w_i \varphi(\|x - x_i\|), \quad (8)$$

که $\varphi(\|x - x_i\|)$ مجموعه‌ای از N تابع غیرخطی است که توابع پایه شعاعی نامیده می‌شوند و $\|x - x_i\|$ بیانگر نُرْم بردار است که معمولاً به صورت فاصله اقلیدسی در نظر گرفته می‌شود (راسل، ۲۰۰۴). $i = 1, 2, 3, \dots, N$ مراکز توابع پایه شعاعی هستند. در این مقاله توابع فعالیت φ ها برای شبکه (Radial Basis Function Neural Network) از نوع گاوسی به صورت (۹) در نظر گرفته شده‌اند. همان‌طور که

روش نشان می‌دهد. خطای متوسط RMS در این روش ۱/۰۷ نمودار شکل ۵ نیز نتایج ارزیابی مقاطع را برای این روش نشان می‌دهد. خطای متوسط RMS در این روش ۱/۰۷ درصد بوده است. همان‌طور که در شکل ۴ دیده می‌شود، برآورد در نزدیک چاه‌ها به خوبی صورت پذیرفته و مقدار خطا هم قابل قبول است اما در مناطق دور از چاه‌ها خطا به نسبت زیاد بوده است و نتیجه برای این نواحی چندان مناسب نیست. در قسمت بعد نشان خواهیم داد که اگر از داده‌های لرزه‌ای نیز هم‌زمان استفاده شود در این مناطق نیز به نتایج بسیار بهتری دست خواهیم یافت. به کمک روش کوکریجینگ (cokriging) می‌توان داده‌های لرزه‌ای را در حکم متغیر ثانویه وارد برآورد کرد. در این روش هر نقطه به کمک یک ترکیب خطی از داده‌های اولیه و ثانویه برآورد می‌شود. کوکریجینگ متداول به صورت زیر تعریف می‌شود.

$$z_{(v)}^* = \sum_{i=1}^n \lambda_i a_i + \sum_{j=1}^m \lambda_{n+j} b_j, \quad (11)$$

که λ_i ، وزن‌های مقادیر نقاط مجموعه اول a_i ها است و λ_{n+j} وزن‌های مقادیر نقاط مجموعه دوم b_j ها است.

چاهی که در آنها اطلاعات چکشات موجود بود، استخراج شده است. ردلرزه مصنوعی ساخته شده با استفاده از این موجک، ۷۰ درصد با ردلرزه اصلی انطباق داشته است. بعد از این مرحله داده‌های لرزه‌ای به رو مدل وارون‌سازی شده‌اند و از نتایج وارون، در بخش‌های بعدی به منزله یک نشانگر مهم و اساسی استفاده شده است.

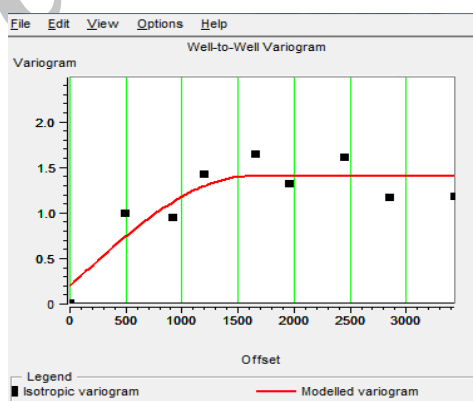
برای ورود به هسته اصلی بررسی، نگار تخلخل هر چاه در محدوده معزنی مورد بررسی متوسط‌گیری شد و عدد به دست آمده در محل چاه قرار گرفت.

بعد از محاسبه واریوگرام داده‌های تخلخل چاه‌ها (شکل ۳) با برآوردگر کریجینگ معمولی، نقشه توزیع تخلخل به دست. این برآوردگر به صورت زیر تعریف می‌شود (حسنی پاک، ۱۳۸۰):

$$z_v^* = \sum_{i=1}^n \lambda_i z_{vi}, \quad (10)$$

که z_v^* مقدار کمیت برآورد شده، λ_i وزن یا اهمیت کمیت وابسته به نمونه z_{vi} و مقدار کمیت نمونه z_{vi} است نقشه توزیع تخلخل به کمک برآوردگر کریجینگ (kriging) در شکل ۴ نشان داده شده است.

نمودار شکل ۵ نیز نتایج ارزیابی مقاطع را برای این



شکل ۳. واریوگرام داده‌های چاه‌به‌چاه.

نشان می‌دهد. شکل ۷ نیز نمودار ارزیابی مقاطع این روش را نشان می‌دهد. متوسط RMS خطای ارزیابی مقاطع در این روش ۰/۶۱ درصد بوده است و این بدین معنی است که نتیجه برآورد تخلخل در روش کولوکتید کوکریجینگ بسیار مناسب‌تر از روش کریجینگ صرف بوده است و دلیل آن استفاده از داده‌های لرزه‌ای به‌همراه داده‌های چاه‌ها بوده است. در این روش داده‌های لرزه‌ای در حکم متغیر ثانویه وارد برآورد می‌شوند و اطلاعات جدیدی را از مکان‌هایی که چاه در آنها موجود نیست، به‌دست می‌دهند.

در قسمت قبل دیده شد که استفاده از داده‌های لرزه‌ای به‌همراه زمین‌آمار باعث بهبود نتایج برآورد تخلخل می‌شود و خطای برآورد را تا حد مناسبی کاهش می‌دهد. در این مرحله نشان می‌دهیم اگر به‌جای یک نشانگر از چند نشانگر استفاده شود، به نتایج بهتری حاصل می‌شود. یافت. برای استفاده از نشانگرهای چندگانه از دو روش رگرسیون چندمتغیره و شبکه عصبی RBFN استفاده خواهیم کرد. بعد از اینکه نشانگرهای مناسب به روش رگرسیون چندمتغیره انتخاب شدند، نقشه اولیه‌ای از توزیع تخلخل به کمک نشانگرهای انتخاب شده ایجاد می‌شود. سپس این نقشه اولیه در حکم متغیر ثانویه در روش زمین‌آمار مورد استفاده قرار می‌گیرد. جدول ۲ نشانگرهای مناسب انتخاب شده با روش رگرسیون چندمتغیره را به همراه وزن‌های اختصاص یافته به هر نشانگر، نشان می‌دهد. شبکه عصبی RBFN نیز از نشانگرهای انتخاب شده با روش رگرسیون چندمتغیره استفاده می‌کند و نقشه اولیه‌ای از توزیع تخلخل در منطقه را تولید می‌کند.

شکل ۸ نقشه برآورد تخلخل به کمک زمین‌آمار و نشانگرهای چندگانه (نتایج رگرسیون چندمتغیره) را نشان می‌دهد. شکل ۹ نیز نقشه تخلخل نهایی تهیه شده به کمک روش زمین‌آمار و RBFN را نشان می‌دهد. شکل ۱۰

کوکریجینگ متداول یا عادی زمانی مورد استفاده قرار می‌گیرد که داده‌های ثانویه (لرزه‌ای) هم مانند داده‌های چاه، پراکنده باشند و در همه نقاط شبکه‌بندی وجود نداشته باشند. اما در این تحقیق داده‌های لرزه‌ای در سراسر منطقه مورد بررسی وجود داشته‌اند، بنابراین به‌جای کوکریجینگ متداول که در بالا به آن اشاره شد، از کولوکتید کوکریجینگ (collected cokriging) استفاده می‌کنیم. زمانی که از کولوکتید کوکریجینگ استفاده می‌کنیم در واقع داده‌های ثانویه در همان نقاطی که حضور دارند برآورد می‌شوند. کولوکتید کوکریجینگ به صورت زیر تعریف می‌شود.

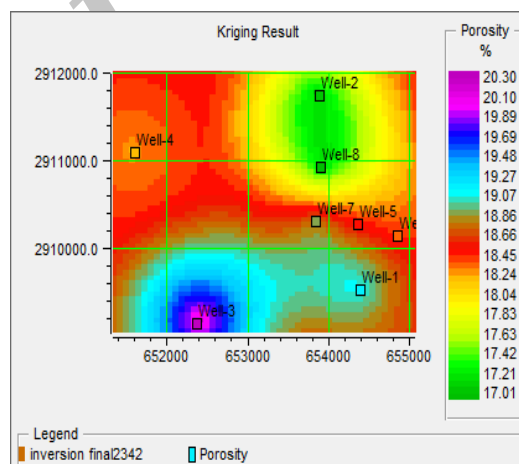

$$z_{(v)}^* = \sum_{i=1}^n \lambda_i a_i + \lambda_{n+1} b_0 \quad (12)$$

که b_0 مقدار داده ثانویه در محل برآورد است. هنگامی که از روش کوکریجینگ استفاده می‌کنیم به واریوگرام‌های داده‌های لرزه‌ای به داده‌های لرزه‌ای و داده‌های چاه به داده‌های لرزه‌ای نیز نیاز داریم. واریوگرام داده‌های چاه به داده‌های لرزه‌ای با نظریه مارکوف-بیز که رابطه‌ای خطی بین داده‌های پراکنده (داده‌های چاه) و داده‌های متراکم (داده‌های لرزه) در نظر می‌گیرد، به‌دست می‌آید (هندرسون، ۲۰۰۴). در این قسمت نشان می‌دهیم که وقتی از داده‌های لرزه‌ای در حکم متغیر ثانویه در روش‌های زمین‌آمار استفاده می‌کنیم، به نتایج به مراتب بهتری دست می‌یابیم. جدول ۱ میزان همبستگی داده‌های تخلخل چاه‌ها را با نشانگرهای متفاوت نشان می‌دهد. مشاهده می‌شود که نشانگر مقاومت صوتی بیشترین همبستگی را با داده‌های تخلخل دارد، بنابراین در مرحله اول این نشانگر را در حکم متغیر ثانویه در روش کولوکتید کوکریجینگ وارد می‌کنیم.

شکل ۶ نقشه توزیع تخلخل به‌دست آمده از روش زمین‌آمار و نشانگر مقاومت صوتی را در حکم متغیر ثانویه

استفاده قرار می‌گیرد. با توجه به بررسی‌های صورت گرفته در این مقاله، می‌توان نتیجه گرفت که هرچقدر از داده‌های بیشتری برای برآورد استفاده شود، به نتایج مناسب‌تری دست خواهیم یافت و خطای برآورد نیز به‌طور رضایت بخشی کاهش خواهد یافت. جدول ۳ نتایج ارزیابی متقاطع در برآورد تخلخل، برای همه چاه‌های ناحیه مورد بررسی و همه روش‌های بررسی شده را نشان می‌دهد. همان‌طور که در جدول ۳ مشخص است، خطای متوسط RMS روش کولوکتد کوکریجینگ نسبت به کریجینگ معمولی کمتر است و نقشه‌های تخلخل به‌دست آمده به کمک این روش، خطای کمتری نسبت به روش‌های معمولی زمین‌آمار دارند.

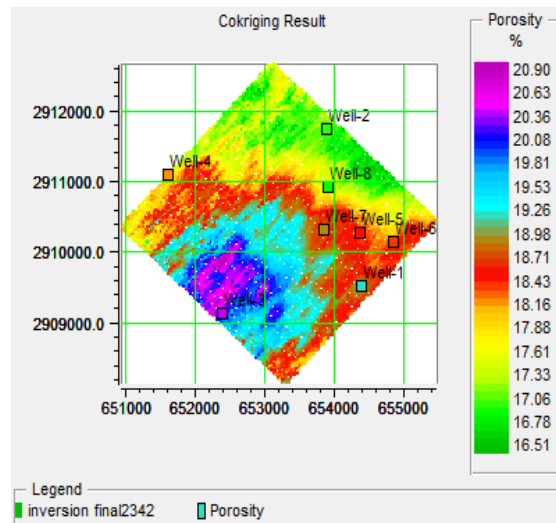

نمودار نتایج ارزیابی متقاطع را برای روش‌های زمین‌آمار به کمک نشانگرهای چندگانه (نتایج رگرسیون چندمتغیره) و همچنین زمین‌آمار به کمک RBFN، نشان می‌دهد. متوسط خطای RMS ارزیابی متقاطع برای روش زمین‌آمار و نشانگر چندگانه ۰/۱۸ درصد و برای زمین‌آمار به کمک RBFN، ۰/۱۴ درصد بوده است. بنابراین مشاهده می‌کنیم استفاده از داده‌های لرزه‌ای درحکم متغیر ثانویه در روش‌های زمین‌آماری، نتایج بسیار بهتری از روش زمین‌آمار صرف (کریجینگ معمولی) را به‌دست می‌دهد. دلیل افزایش بهبود برآورد تخلخل در این‌گونه روش‌ها، وارد شدن مجموعه جدیدی از اطلاعات است که در روش‌های زمین‌آماری به‌منزله متغیر ثانویه مورد



شکل ۴. نقشه توزیع تخلخل به‌دست آمده از روش کریجینگ معمولی. شکل ۵. نمودار نتایج اعتبارسنجی متقاطع برای روش کریجینگ معمولی.

جدول ۱. میزان همبستگی نشانگرهای متفاوت با داده‌های تخلخل در محل چاه‌ها.

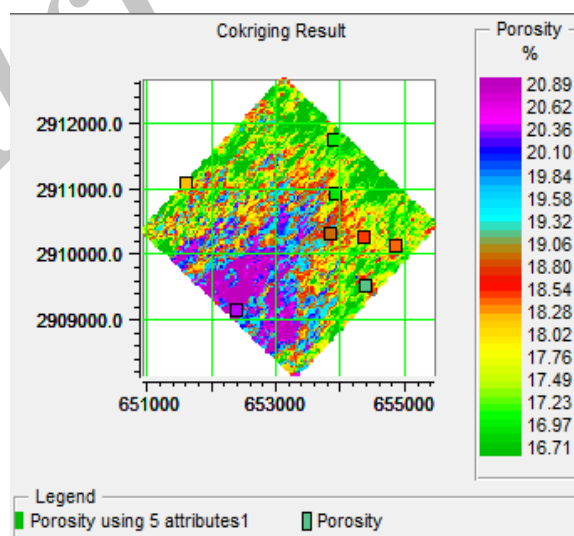
	Target	Attribute	
1	Porosity	Seismic attribute amplitude weighted frequency	-0.581334
2	Porosity	Inversion result	-0.626608
3	Porosity	Filter 25 30-35 40	-0.121108
4	Porosity	Filter 15 20- 25 30	-0.319372
5	Porosity	phase rms average	0.221763
6	Porosity	length	-0.527361
7	Porosity	integrated rms average	0.113034
8	Porosity	freq rms average	-0.193755
9	Porosity	envl rms average	-0.503296
10	Porosity	amp rms average	-0.467691
11	Porosity	Amplitude Weighted Phase	-0.483241



شکل ۶. نقشه تخلخل به دست آمده از روش کولوکیتد کوکریجینگ به کمک شکل ۷. نمودار نتایج اعتبارسنجی مقاطع برای روش زمین آمار و نشانگر یک نشانگر، نواحی با تخلخل متفاوت به خوبی از هم تفکیک شده و خطای صرف برآورد تخلخل در ناحیه، کاهش پیدا کرده است.

جدول ۲. نشانگرهای مناسب انتخاب شده با رگرسیون چندمتغیره برای تولید نقشه اولیه توزیع تخلخل.

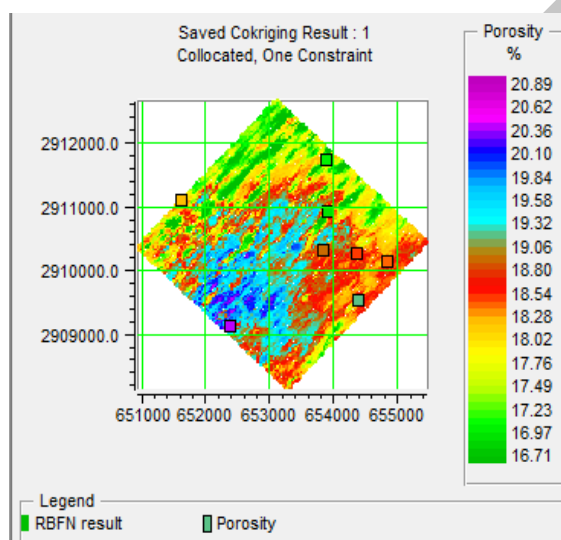
	Attribute Name	Weight
1	freq rms average	-0.088264
2	integrated rms average	-0.000232
3	phase rms average	-0.049916
4	Filter 25 30-35 40	0.0006244
5	Inversion	0.0006092
7	+ Constant	12.349
9	= Porosity	



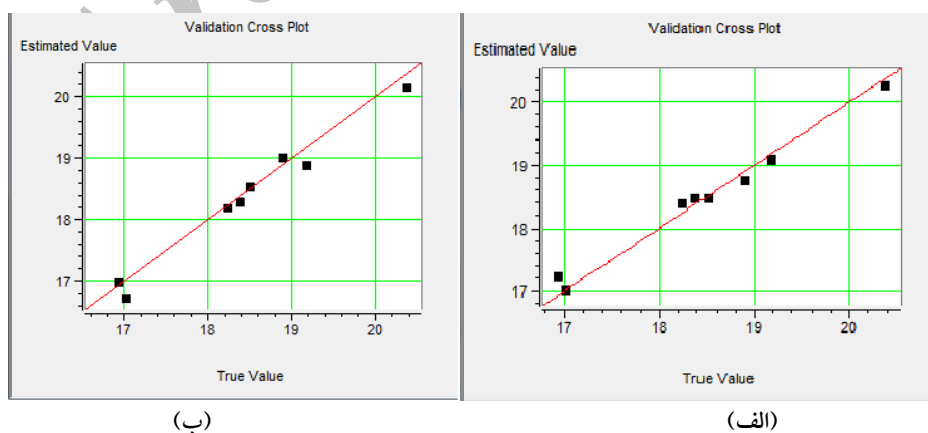
شکل ۸. نقشه برآورد تخلخل به کمک زمین آمار و نشانگرهای چندگانه (نتایج رگرسیون چندمتغیره).

جدول ۳. بررسی نتایج خطای متوسط RMS اعتبارسنجی مقاطع در چاه‌های منطقه و روش‌های به‌کار رفته.

	Methods Error			
	Kriging	Cokriging with Single Attribute	Cokriging with Multi Attribute	Cokriging with RBFN
Well-1	0.56	0.24	0.1	0.30
Well-2	-1.16	-0.32	0.01	0.30
Well-3	2.27	0.42	0.11	0.23
Well-4	-0.36	0.54	-0.15	0.05
Well-5	-0.01	-0.02	0.03	-0.04
Well-7	0.71	0.54	0.15	-0.11
Well-8	-1.31	-1.46	-0.29	-0.05
Well-6	-0.26	0.1	-0.1	0.09
RMS	1.07	0.61	0.18	0.14



شکل ۹. نقشه توزیع تخلخل نهایی تهیه شده به کمک روش زمین‌آماري و RBFN



(ب)

(الف)

شکل ۱۰. نمودار نتایج اعتبارسنجی مقاطع برای روش زمین‌آماري و RBFN و (ب) روش زمین‌آماري و نشانگرهای چندگانه.

۷ نتیجه گیری

جدول ۳ نتایج ارزیابی متقاطع در برآورد تخلخل، برای همه چاه‌های ناحیه مورد بررسی و همه روش‌های بررسی شده را نشان می‌دهد. همان‌طور که در جدول ۳ مشاهده می‌شود هر چقدر از مجموعه داده‌های بیشتری برای برآورد تخلخل استفاده کنیم، نتایج مناسب‌تری به دست می‌آوریم. دلیل آن این است که، وقتی از رگرسیون چندمتغیره استفاده می‌کنیم، درحقیقت به جای استفاده از یک مجموعه داده درحکم متغیر ثانویه، از چندین مجموعه داده به منزله متغیر ثانویه در روش زمین‌آمار استفاده می‌شود. همچنین از جدول بالا می‌توان نتیجه گرفت که روش شبکه عصبی، الگوریتم بهتری را برای برآورد تخلخل به کمک زمین‌آمار در اختیار می‌گذارد و دلیل آن این است که تغییرات زمین خطی نیست و برخلاف رگرسیون چندمتغیره که تغییرات زمین را خطی در نظر می‌گیرد، شبکه عصبی تغییرات را غیرخطی در نظر می‌گیرد و نقشه‌های اولیه تخلخل را ایجاد می‌کند. بنابراین می‌توان چنین نتیجه گرفت که اگر از مجموعه‌ای از داده‌های لرزه‌ای به کمک زمین‌آمار برای برآورد تخلخل استفاده شود، نتایج به مراتب مناسب‌تر و قابل‌اعتمادتر خواهند بود. همچنین بهتر است به جای استفاده از روش رگرسیون چندمتغیره به همراه زمین‌آمار، از روش شبکه عصبی به همراه زمین‌آمار استفاده شود تا تغییرات غیرخطی زمین لحاظ شود. به بیان دیگر اگر تغییرات زمین را به صورت خطی مدل کنیم، رفتار زمین را خیلی ساده مدل کرده‌ایم و این با واقعیت همخوانی ندارد. ولی اگر از شبکه عصبی قوی RBFN استفاده کنیم، مسئله سادگی

بیش از حد مدل زمین برطرف می‌شود و نتایج نیز بهتر می‌شوند.

منابع

- حسینی پاک، ع.، ۱۳۸۰؛ زمین‌آمار؛ انتشارات دانشگاه تهران.
- Bracewell, R. N., 1965, The Fourier Transform and its Applications: New York, McGraw-Hill Book Co., Inc.
- Chopra, S., and Marfurt, K., 2006. Seismic attributes—a promising aid for geologic prediction: Canadian Society of Exploration Geophysicists Recorder 2006 Special Edition, pp.111–121.
- Hampson, D., Schuelke, J.S., and Quirein, J.A., 2001, Use of multi-attribute transforms to predict log properties from seismic data: Geophysics, **66**, 220-231.
- Russell, B. H., 2004, The application of multivariate statistics and neural networks to the prediction of reservoir parameters using seismic attributes: Ph.D. thesis, University of Calgary.
- Russell, B. H., Ross, C. P., and Lines, L. R., 2002. Neural networks and AVO. The Leading Edge **21**(3), 268–277.
- Russell, B. H., Lines, L. R., and Hampson, D. P., 2003, Application of the radial basis function neural network to the prediction of log properties from seismic data. Exploration Geophysics **34**, 15–23.
- Russell, B., 1988, Introduction to seismic inversion methods: Society of Exploration Geophysicists. (Course notes from SEG Continuing Education course).
- Taner, M. T., Koehler, F., and Sheriff, R. E., 1979, Complex seismic trace analysis: Geophysics, **44**, 1041-1063.
- Haykin., S., 1999, Neural Networks: Macmillan College Publishing Company.