

به کارگیری مدل فازی عصبی در برآورد پارامترهای مخزن با استفاده از نشانگرهای لرزه‌ای - بررسی موردی در یک مخزن هیدروکربوری در ایران مرکزی

محمد رضا واشقانی فراهانی^۱، مجید نبی بیدهندی^{۲*} و حسین خوشدل^۳

^۱دانش آموخته کارشناسی ارشد ژئوفیزیک، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

^۲استاد، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

^۳کارشناس ارشد، مدیریت اکتشاف شرکت ملی نفت ایران، تهران، ایران

farahani.mreza@ymail.com, mnbhendi@ut.ac.ir, hkhoshdel@yahoo.com

(تاریخ دریافت: ۱۳۸۸/۶/۲۳، تاریخ پذیرش: ۱۳۸۹/۳/۲۶)

چکیده

در این مقاله از مدل فازی عصبی برای برآورد خواص مخزن با استفاده از نشانگرهای لرزه ای استفاده شده است. الگوریتم "درخت مدل خطی محلی (LOLIMOT)" برای آموزش مدل به کار رفته است. این مدل از نگارهای چاه و نشانگرهای لرزه ای در محل چاه در مرحله آموزش استفاده می کند. شبکه فازی عصبی آموزش دیده برای برآورد خصوصیات مخزن با استفاده از نشانگرهای لرزه ای مورد استفاده قرار می گیرد. این روش در یک تاکدیس هیدروکربنی در ایران مرکزی مورد استفاده قرار گرفته و تخلخل سنگ مخزن آهکی سازند قم (تخلخل نوترونی) با استفاده از نشانگرهای لرزه ای (مقاومت صوتی و کسینوس فاز وزن دهی شده با دامنه) برآورد شده است. نتایج این روش با نتایج به دست آمده از اعمال مدل های متداول، نظیر شبکه عصبی احتمالاتی (PNN) و شبکه عصبی پیش خور چندلایه (MLFN) مقایسه شده است. استفاده از مدل فازی عصبی، در مقایسه با شبکه های عصبی، منجر به خطای کمتری در برآورد خصوصیات مخزن شد.

واژه های کلیدی: مدل فازی عصبی، خواص مخزن، نشانگرهای لرزه ای

Applying neuro-fuzzy model to estimate reservoir properties using seismic attributes - A case study in a hydrocarbon reservoir in central Iran

Mohammadreza Vasheghani Farahani¹, Majid Nabi-Bidhendi^{1*}, and Hossein Khoshdel³

¹Institute of Geophysics, University of Tehran, Iran

²Exploration Directorate, National Iranian Oil Company (NIOC), Tehran, Iran

(Received: 14 September 2009, accepted: 16 June 2010)

Summary

Reservoir properties, such as porosity and permeability, can be derived at well locations from core samples or well log measurements. Since these properties vary laterally from one well to another, it is normally very difficult to predict reservoir properties away from wells. Seismic data, particularly 3D surveys, contain valuable information about the lateral variation of reservoir properties. When wells fall within the seismic coverage, it is

*Corresponding author:

mnbhendi@ut.ac.ir

*نگارنده رابط:

logical to predict reservoir properties between wells by interpreting seismic data and using reservoir properties at well locations as spatial control points.

Artificial neural networks (ANN) may be used to aid the estimation of reservoir properties between wells. In this case, a training sample set of input and output data pairs can be collected. The input of neural networks is seismic data relevant to the reservoir at well locations. The expected output from neural networks is reservoir properties at well locations.

This paper uses a local linear neuro-fuzzy model to predict reservoir properties from seismic attributes in one of the oil fields in the central region of Iran. The fundamental approach with the locally linear neuro-fuzzy model is dividing the input space into small linear subspaces with fuzzy validity functions. Any linear model produced, along with its validity function, can be described as a fuzzy neuron. Thus, the total model is a neuro-fuzzy network with one hidden layer and a linear neuron in the output layer, which simply calculates the weighted sum of the outputs of locally linear neurons.

An incremental tree-based learning algorithm, a locally linear model tree (LOLIMOT), is appropriate for tuning rule premise parameters, i.e. determining the validation hypercube for each locally linear model. In iteration, the worst performing locally linear neuron is determined and then divided. All of the possible divisions in the p dimensional input space are checked, and the best is performed. The splitting ratio is simply adjusted as $1/2$, which means that the locally linear neuron is divided into two equal halves. The fuzzy validity functions for the new structure are updated. Their centers are identical with the centers of the new hypercubes and the standard deviations are usually set as 0.3 . Just one parameter, the embedding dimension, should be defined before running the algorithm. In this work, the number of attributes is the embedding dimension.

To evaluate the performance of a locally linear neuro-fuzzy model in extracting the relationship between seismic attributes and reservoir property, this method was applied in an oil field located in central Iran. This field has two exploration wells. Additionally, a 3D seismic survey, recorded with a one-millisecond sampling interval, covers the area of the reservoir.

First, the logs were mapped to the time domain and then blocked it at each one millisecond to resolve the frequency difference of the logs and seismic data. Then, multi-attribute analyses were performed and the best seismic attributes, which had good correlations with porosity, were found to be acoustic impedance and amplitude weighted cosine phase. By applying the locally linear neuro-fuzzy model to train and validate the network, good results were obtained. The correlation coefficient between the modeled and original logs was 80% and the error was 2.6% in validation.

Finally, to compare the neuro-fuzzy model with traditional methods, the work was repeated with a probabilistic neural network (PNN) and a multi-layer forward neural network (MLFN). The results obtained by applying the MLFN (correlation 83% and error 4.5) and PNN (correlation 68% and error 5.7) were not better than neuro-fuzzy model.

Key words: Neuro-fuzzy model, reservoir properties, seismic attributes

پتروفیزیکی مخزن به طور جانبی از چاهی به چاهی دیگر تغییر می‌کند، لذا طبیعی است که برآورد این خصوصیات در نقاط دور از چاه براساس اطلاعات چاه مشکل باشد. این امر در برآورد خصوصیات لبه‌های مخزن نمود بیشتری

۱ مقدمه

خواص پتروفیزیکی مخزن نظیر تخلخل، تراوایی و اشباع آب را می‌توان در محل چاه‌ها با استفاده از نگاره‌های چاه یا نمونه‌های مغزه به دست آورد. از آنجاکه خواص

الگوریتم درخت مدل خطی محلی (LOLIMOT) معرفی می‌شود. سپس در یک بررسی موردی، با استفاده از نرم‌افزار همپسون-راسل (Hampson Russell) نشانگرهای لرزه‌ای (sample base attributes) متداول استخراج و از بین آنها نشانگرهای مناسب به منظور برآورد تخلخل انتخاب می‌شوند. با استفاده از امکانات نرم‌افزار، تخلخل مخزن با اعمال شبکه‌های عصبی برآورد می‌شود. بدون تغییر در پارامترهای مسئله و صرفاً با جایگزینی مدل فازی عصبی به جای شبکه عصبی، کار تکرار می‌شود. به این منظور داده‌ها از نرم‌افزار خارج، و با برنامه‌نویسی در محیط نرم‌افزار MATLAB، مدل فازی عصبی در برآورد تخلخل با استفاده از نشانگرهای لرزه‌ای اعمال می‌شود. در نهایت توانایی شبکه‌های عصبی و مدل فازی عصبی در برآورد خصوصیات مخزن با استفاده از نشانگرهای لرزه‌ای مقایسه می‌شود.

۲ مدل فازی عصبی خطی محلی

مقدار l را به منزله تابعی از متغیرهای u_1, u_2, \dots, u_p در نظر می‌گیریم. هدف، ساختن مدلی است که این رابطه مجهول را مدل‌سازی کند و با پذیرفتن متغیرها به صورت یک بردار ورودی $\underline{u} = [u_1 u_2 \dots u_p]$ ، مقدار l را برآورد کند (در این مقاله l معادل یک ویژگی مخزن نظیر تخلخل و u_1, u_2, \dots, u_p معادل نشانگرهای لرزه‌ای هستند). اساس کار در مدل فازی عصبی خطی محلی به این صورت است یک مسئله پیچیده مدل‌سازی به تعداد زیادی از زیرمسئله‌های کوچک‌تر و بنابراین آسان‌تر تقسیم می‌شود، که این زیرمسئله‌ها هر کدام به طور جداگانه با یک مدل خطی حل می‌شوند. برای تقسیم مسئله اصلی به چند زیرمسئله از الگوریتم LOLIMOT که نلس (۲۰۰۱) معرفی کرده است، استفاده می‌شود.

پیدا می‌کند. داده‌های لرزه‌ای و به خصوص لرزه‌نگاری سه‌بعدی حاوی اطلاعات با ارزشی در مورد تغییرات جانبی خصوصیات مخزن است. هنگامی که چاه‌ها در منطقه تحت پوشش داده لرزه‌ای قرار دارند، می‌توان با استفاده از تفسیر لرزه‌ای، خصوصیات مخزن را برآورد کرد و از خصوصیات پتروفیزیکی در چاه‌ها به منزله نقاط کنترلی استفاده کرد (بانچز و میشلنا، ۲۰۰۲).

هوش محاسباتی شامل شبکه‌های عصبی مصنوعی، منطقی فازی و الگوریتم ژنتیک، اخیراً کاربردهای گسترده‌ای در علوم زمین یافته است. این موضوع ناشی از طبیعت غیر قطعی و همراه با خطای بسیاری از داده‌های مورد استفاده در علوم زمین و توانایی فنون هوش محاسباتی در مواجهه با این نوع داده‌ها است. مروری جامع بر کاربردهای اخیر هوش محاسباتی در اکتشاف و توسعه میدانی نفتی از سوی محققان گوناگون عرضه شده است (وانگ و همکاران، ۲۰۰۲؛ نیک روش و همکاران، ۲۰۰۳؛ سندهام و همکاران، ۲۰۰۳). هوش محاسباتی را می‌توان در حکم ابزاری برای کمک به برآورد خصوصیات مخزن در بین چاه‌ها به کار برد (امین‌زاده و دی گروت، ۲۰۰۴). شبکه عصبی و منطقی فازی از جمله متداول‌ترین فن‌های هوش محاسباتی‌اند. از آنجاکه این دو روش بیش از آنکه رقیب هم باشند، تکمیل‌کننده هم هستند (نیک‌روش، ۲۰۰۷)، برخی محققان شبکه عصبی و منطقی فازی را با هدف دستیابی به مدل‌های کارآمدتر ترکیب کرده‌اند (امین‌زاده و براور، ۲۰۰۶). مدل فازی عصبی خطی محلی یک روش ترکیبی است. این مدل همانند شبکه عصبی قابلیت یادگیری از داده‌ها را داشته و یک برآوردگر عمومی است (نلس، ۲۰۰۱) و می‌تواند در برآورد خصوصیات مخزن با استفاده از نشانگرهای لرزه‌ای به کار رود.

در این مقاله ابتدا مدل فازی عصبی و همچنین

۱-۲ ساختار مدل فازی عصبی خطی محلی

ساختار مدل فازی عصبی خطی محلی در شکل ۱ آمده است. هر نرون در واقع شامل یک مدل خطی محلی (LLM) و یک تابع اعتبار $\phi_i(\underline{u})$ است که محدوده اعتبار LLM را مشخص می‌کند.

خروجی LLM به صورت رابطه (۱) است (نلس، ۲۰۰۱).

$$y_i = w_{i0} + w_{i1}u_1 + w_{i2}u_2 + \dots + w_{ip}u_p \quad (1)$$

که $\underline{u} = [u_1 u_2 \dots u_p]$ بردار ورودی، پارامترهای LLM برای i امین نرون و y_i خروجی LLM در i امین نرون است. خروجی مدل که شامل M نرون باشد از رابطه زیر محاسبه می‌شود.

$$\hat{y} = \sum_{i=1}^M y_i \phi_i(\underline{u}). \quad (2)$$

که $\phi_i(\underline{u})$ تابع اعتبار i امین نرون برای بردار ورودی \underline{u} است. بنابراین خروجی مدل، در واقع مجموع وزن‌دهی شده خروجی‌های مدل‌های خطی محلی است. تابع اعتبار هر نرون عددی در بازه $[0, 1]$ و در واقع تعیین‌کننده اعتبار جواب LLM مربوط به آن نرون است و با ضرب شدن در خروجی LLM، میزان مشارکت نرون مربوط در خروجی نهایی را تعیین می‌کند.

توابع اعتبار نوعاً توابع گاوسی نرمال شده، انتخاب می‌شوند. اگر این گاوسی‌ها متعامد نیز باشند، در این صورت توابع اعتبار به صورت زیر خواهند بود.


$$\phi_i(\underline{u}) = \frac{\mu_i(\underline{u})}{\sum_{j=1}^M \mu_j(\underline{u})} \quad (3)$$

که در آن μ_i از رابطه زیر به دست می‌آید

$$\mu_i(\underline{u}) = \exp \left(-\frac{1}{2} \left(\frac{(u_1 - c_{i1})^2}{\sigma_{i1}^2} + \dots + \frac{(u_p - c_{ip})^2}{\sigma_{ip}^2} \right) \right) \quad (4)$$

$$= \exp \left(-\frac{1}{2} \frac{(u_1 - c_{i1})^2}{\sigma_{i1}^2} \right) \dots \exp \left(-\frac{1}{2} \frac{(u_p - c_{ip})^2}{\sigma_{ip}^2} \right)$$

که توابع اعتبار گاوسی نرمال شده $\phi_i(\underline{u})$ ، به مختصات مرکزی c_{ij} و انحراف معیارهای σ_{ij} بستگی دارند. این پارامترها غیرخطی و معادل پارامترهای لایه پنهان شبکه عصبی اند. این پارامترها در فرایند آموزش، با استفاده از الگوریتم درخت مدل خطی محلی بهینه می‌شوند.



شکل ۱. ساختار شبکه یک مدل فازی عصبی خطی محلی با M رشته عصبی برای p ورودی (نلس، ۲۰۰۱).

اعتبار تشکیل شده در مرحله سوم - a و LLM های بهینه شده در مرحله سوم - c برای مدل اعمال می شود. تعداد LLMs از M به M + 1 افزایش می یابد.

پنجم - هم گزینی آزموده می شود: شرط پایانی الگوریتم بررسی می شود و اگر الگوریتم به شرط پایان عملیات رسیده باشد، آن گاه متوقف می شود. در غیر این صورت به مرحله دوم برگشته و عملیات تکرار می شود. شرط پایان ممکن است رسیدن تعداد LLMS به مقداری خاص و یا کاهش خطای برآورد به کمتر از حدی آستانه باشد.

شکل ۲ عملکرد LOLIMOT در برآورد یک تابع یک متغیره را نشان می دهد. γ تابعی از متغیر u ، و $\hat{\gamma}$ ، LLMs ساخته شده با LOLIMOT در تکرارهای متفاوت است. در هر تکرار، توابع اعتبار $\phi_i(u)$ که از نوع گاوسی نرمال شده هستند نیز نشان داده شده اند. در اولین تکرار، تابع با استفاده از یک LLM برآورد شده و تابع اعتبار آن نیز طبعاً در همه جای فضای ورودی یک است. در تکرار دوم، فضای ورودی به دو قسمت مساوی تقسیم شده و در هر قسمت تابع با استفاده از یک LLM برآورد شده است. تابع اعتبار هر LLM نیز ایجاد شده است که در محدوده اعتبار آن مقدار یک دارد و با دور شدن از آن به شدت کاهش می یابد و به صفر می رسد. در تکرار سوم، با توجه به خطای زیاد LLM مربوط به نیمه اول در برآورد تابع، فضای ورودی نیمه اول به دو قسمت مساوی تقسیم و در هر قسمت تابع با استفاده از یک LLM برآورد می شود. تعداد LLMs به سه می رسد و توابع اعتبار هر سه LLM نیز از نو بازسازی می شوند. با افزایش تکرار، خروجی مدل $\hat{\gamma}$ ، تطبیق بیشتری با γ پیدا می کند. تکرار تا وقتی که شرط پایان محقق شود، ادامه پیدا می کند. شکل ۲ تکرار تا پنج مرحله را نشان داده است.

۲-۲ الگوریتم درخت مدل خطی محلی

اول - یک مدل اولیه ایجاد می شود: کل فضای ورودی یک LLM محسوب می شود ($M = 1$). این LLM، یک مدل خطی سراسری است و تابع اعتبار آن، تمام فضای ورودی را با تابع عضویت برابر یک می پوشاند.

دوم - بدترین LLM شناسایی می شود: یک تابع خطی محلی برای LLMs از $i = 1, \dots, M$ محاسبه می شود. توابع خطای محلی، با وزن دار کردن مربع خطاهای مدل با درجه اعتبار مدل محلی متناظر، و براساس رابطه (۵) محاسبه می شود (نلس، ۲۰۰۱). $e(j)$ اختلاف مقدار واقعی و مدل سازی شده آن برای هر ورودی J است.

$$I_i = \sum_{j=1}^N e^2(j) \phi_i(u(j)) \quad (5)$$

LLM با بدترین کارایی، که در آن I_i حداکثر است، شناسایی و L در حکم نشانه ای برای این بدترین LLM در نظر گرفته می شود.

سوم - همه تقسیم بندی ها بررسی می شود: L (LLM) با بدترین عملکرد) برای بهبود بیشتر انتخاب می شود. ابرمستطیل (hyperrectangle) مربوط به این LLM به دو نیمه تقسیم می شود. تقسیمات در تمام ابعاد امتحان می شود. برای هر تقسیم بندی، در ابعاد ورودی P تا P مراحل زیر صورت می گیرد:

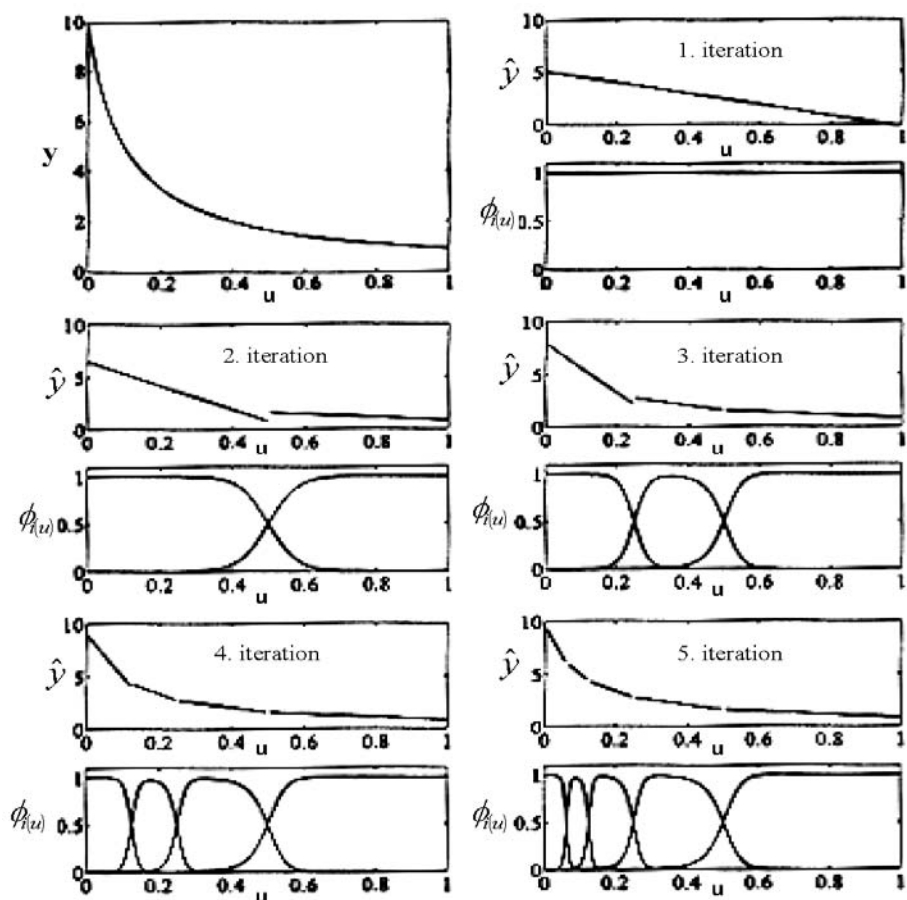
(a) تشکیل درجه عضویت های چندبُعدی برای هر دو ابرمستطیل.

(b) بازسازی همه توابع اعتبار.


(c) تقریب موضعی پارامترها برای هر یک از دو LLM تازه ایجاد شده.

(d) محاسبه تابع خطا برای مدل کلی حاضر.

چهارم - بهترین تقسیم بندی انتخاب و اعمال می شود: بهترین جایگزین از P بُعد بررسی شده در مرحله سوم (که منجر به بیشترین کاهش خطا شده است) انتخاب، و توابع



شکل ۲. عملکرد LOLIMOT در برآورد یک تابع یک‌متغییری. تابع y (بالا-چپ) با استفاده از مدل فازی عصبی محلی خطی و الگوریتم LOLIMOT برآورد شده است. پنج تکرار اول نشان داده شده است (با تغییر از نلس، ۲۰۰۱).



شکل ۳. توپوگرافی منطقه و موقعیت چاه‌ها (با تغییر از یولانگ و ژیانگ، ۲۰۰۵).

۳ برآورد تخلخل با استفاده از مدل فازی عصبی

خطی محلی

به منظور ارزیابی کارایی مدل فازی عصبی خطی محلی در برآورد خصوصیات مخزن، از این مدل در برآورد تخلخل در یک مخزن هیدروکربوری استفاده شد. مخزن بررسی شده در این تحقیق، در یکی از میداین نفتی ایران مرکزی است. در محدوده این مخزن، عملیات لرزه‌نگاری سه‌بعدی صورت گرفته و دو حلقه چاه اکتشافی نیز حفاری شده است. منطقه تحت پوشش داده لرزه‌نگاری به خوبی مخزن و چاه‌های حفر شده در آن را می‌پوشاند، به طوری که چاه‌ها در مرکز منطقه لرزه‌نگاری قرار گرفته‌اند. فاصله دو چاه در حدود پنج کیلومتر است و نگارهای متداول نظیر نگار تخلخل نوترون، نگار چگالی و نگار سرعت موج P در هر دو چاه به صورت تصحیح شده موجودند. شکل ۳ نشان‌دهنده توپوگرافی منطقه و موقعیت چاه‌ها است.

محل تجمع احتمالی هیدروکربن در این میدان، سنگ آهک سازند قم مربوط به دوره اولیگوسن-میوسن است. مجموعه‌ای از تاقدیس‌ها، بلوک‌های گسل خورده، ساختارهای دماغه‌ای گسل خورده و انواع تله‌های چینه‌ای در این میدان توسعه یافته‌اند. در این میدان سنگ‌های مادر متعلق به دوره ژوراسیک و ترشیری هستند که به خوبی بالغ شده و می‌توانند منشاء مناسبی برای نفت و گاز باشند. به علاوه وجود میدان گازی و نفتی در نواحی اطراف احتمال وجود هیدروکربن در این میدان را تقویت می‌کند (یولانگ و ژیانگ، ۲۰۰۵). شکل ۴ توالی لایه‌ها در امتداد خط واصل دو چاه را نشان می‌دهد. پایین‌ترین سازند که در شکل با رنگ سرخ مشخص شده است، سازند سرخ زیرین (LRF)، و لایه‌های روی آن عضوهای سازند قم هستند. در شکل ۵ افق C-4 (یکی از عضوهای سازند قم) و محل برخورد نسبی چاه‌ها نشان داده شده است. با توجه

به اینکه در این کار اعمال مدل فازی عصبی و مقایسه آن با شبکه‌های عصبی متداول مد نظر بود، لذا ابتدا با استفاده از نرم‌افزار همپسون-راسل و با اعمال شبکه‌های عصبی، تخلخل مخزن با استفاده از نشانگرهای انتخاب شده برآورد شد. مراحل کار به شرح زیر است:


داده‌های لرزه‌ای و چاه‌نگاری در نرم‌افزار همپسون-راسل بارگذاری شد. سپس رابطه زمان عمق با استفاده از چک‌شات و تطابق لرزه‌نگاشت مصنوعی و اطلاعات لرزه‌نگاری تصحیح شد. با استفاده از رابطه زمان عمق تصحیح شده، نگار تخلخل از حیطه عمق به زمان منتقل شد و با فاصله یک میلی‌ثانیه (که برابر با نرخ نمونه‌برداری لرزه‌ای است) میانگین‌گیری شد. بدین ترتیب نگار تخلخل براساس زمان و متناظر با داده لرزه‌ای در هر دو چاه تهیه شد. همچنین نشانگرهای لرزه‌ای متداول (از جمله مقاومت صوتی، کسینوس فاز وزن‌دهی شده با دامنه، قطبش ظاهری، فاز لحظه‌ای دامنه، مشتق، مشتق دوم، بسامد غالب، فاز لحظه‌ای و بسامد لحظه‌ای) از روی اطلاعات لرزه‌ای استخراج شدند. نشانگر مقاومت صوتی با وارون‌سازی (inversion) داده لرزه‌ای تولید شد. همبستگی هریک از این نشانگرها با تخلخل نیز بررسی شد. سپس نشانگرهای بهینه به روش رگرسیون مرحله‌ای انتخاب شدند. بهینه بودن نشانگرها به این معنی است که متوسط مربع خطای برآورد، بین نگار واقعی و نگار برآوردی (در مرحله ارزیابی) استفاده از این نشانگرها حداقل است و روش رگرسیون مرحله‌ای این مزیت را دارد که نشانگرهای انتخاب شده با این روش مستقل خطی‌اند و فرایند یافتن نشانگرهای بهینه با سرعت بیشتری صورت (همپسون و همکاران، ۲۰۰۱). جدول ۱ فهرست پنج نشانگر اول و خطای ایجاد شده در اثر به کارگیری آنها را که با استفاده از روش رگرسیون مرحله‌ای به دست آمده است نشان می‌دهد. شکل ۶ براساس جدول ۱ ترسیم

دریافت این دو نشانگر به دست آمده از یک نقطه از مخزن، تخلخل را در آن نقطه برآورد کند. با توجه به اینکه در این تحقیق، ارزیابی توانایی مدل فازی عصبی مد نظر بود، لذا از مدل آموزش دیده صرفاً در برآورد تخلخل در چاه دیگر که نگار تخلخل آن برای مقایسه در دسترس بود استفاده شد.


شده است و نشان دهنده میزان خطا برای نشانگرها است. با توجه به جدول ۱ و شکل ۶ دو نشانگر "مقاومت صوتی" و "اکسینوس فاز وزن دهی شده با دامنه" در حکم نشانگرهای بهینه انتخاب شدند. این دو نشانگر به منزله ورودی های مدل محسوب می شوند و خروجی مدل تخلخل است. مدل آموزش دیده قادر خواهد بود که با

جدول ۱. فهرست پنج نشانگر اول و خطای ایجاد شده در اثر به کارگیری آنها.


Attribute	Training Error (%)	Validation Error (%)
Acoustic Impedance	3.45	5.14
Amplitude Weighted Cosine Phase	2.76	3.41
Amplitude Envelope	2.62	3.62
Cosine Instantaneous Phase	2.56	3.66
Filter 45/50-55/60	2.51	4.01



شکل ۴. توالی لایه‌ها در امتداد خط واصل چاه‌ها (با تغییر از یولانگ و ژیانگ، ۲۰۰۵).



شکل ۵. افق C-4 و محل برخورد نسبی چاهها (با تغییر از یولانگ و ژیانگ، ۲۰۰۵).





شکل ۶. میزان خطا برای تعداد نشانگرهای استفاده شده در برآورد.

با عوض کردن چاهها تکرار شد. نتایج عرضه شده، در حکم همبستگی و خطا، میانگین به دست آمده از این تکرار است. آموزش و آزمایش مدل با استفاده از شبکه عصبی پیش خور چندلایه و شبکه عصبی احتمالاتی (PNN) با استفاده از نرم افزار همپسون-راسل صورت گرفت. آموزش و آزمایش مدل فازی عصبی با الگوریتم LOLIMOT، با برنامه نویسی در نرم افزار MATLAB و بدون تغییر در سایر پارامترها به انجام رسید.

در فرایند آموزش مدل، داده های مربوط به یک چاه (نگار تخلخل و نشانگرهای متناظر) به طور تصادفی به دو بخش آموزش و ارزیابی تقسیم شدند، به نحوی که ۸۰٪ داده ها به بخش آموزش اختصاص یافت. به منظور جلوگیری از آموزش بیش از حد مدل، در هر تکرار آموزش، توانایی برآورد مدل با استفاده از داده های ارزیابی، سنجیده شد. به محض کاهش خطای ارزیابی، آموزش مدل متوقف شد. توانایی مدل آموزش دیده در برآورد تخلخل، در چاه دیگر آزمایش شد. سپس این کار

مدل‌سازی شده در مراحل آموزش و آزمایش برای سه مدل عصبی و فازی عصبی است. ملاحظه می‌شود که مدل فازی عصبی با همبستگی ۸۵٪ و خطای ۲/۲٪ آموزش دیده و در مرحله آزمایش نیز همبستگی ۸۰٪ و خطای ۲/۶٪ داشته است. با مقایسه مدل فازی عصبی و مدل‌های پیش‌خورچندلایه و PNN ملاحظه می‌کنیم که مدل فازی عصبی در مرحله آموزش و آزمایش خطای کمتری نسبت به دو مدل دیگر دارد. همچنین همبستگی آن با تفاوت جزئی کمتر از پیش‌خورچندلایه است.

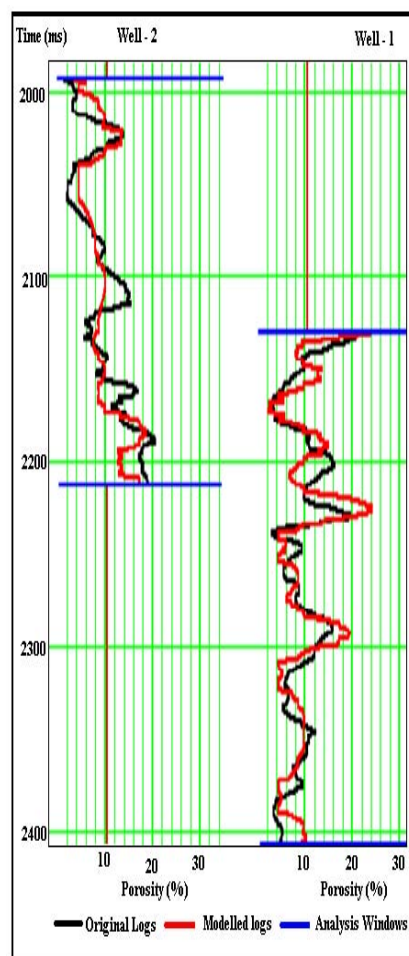

شکل‌های ۷ و ۸ به ترتیب نگارهای اصلی و مدل‌سازی شبکه MFLN و PNN را در مرحله آموزش و آزمایش نشان می‌دهند. شکل ۹ نگارهای اصلی و مدل‌سازی مدل فازی عصبی در برآورد تخلخل از نشانگرهای لرزه‌ای را نشان می‌دهد. همان‌طور که در این شکل‌ها مشخص است، هر سه مدل، کارایی قابل قبولی دارند و به‌رغم فاصله ۵ کیلومتری دوچاه، نگار تخلخل را به‌خوبی برآورد کرده‌اند. نتایج کمی این برآورد در جدول ۲ آمده است. این جدول نشان‌دهنده همبستگی و خطا (جذر میانگین مربعات) بین نگارهای واقعی و



شکل ۷. نگار اصلی و مدل‌سازی شبکه MFLN در مرحله آموزش (راست) و مرحله آزمایش (چپ).

جدول ۲. نتایج اعمال سه نوع متفاوت از مدل‌های عصبی و فازی عصبی در برآورد تخلخل.

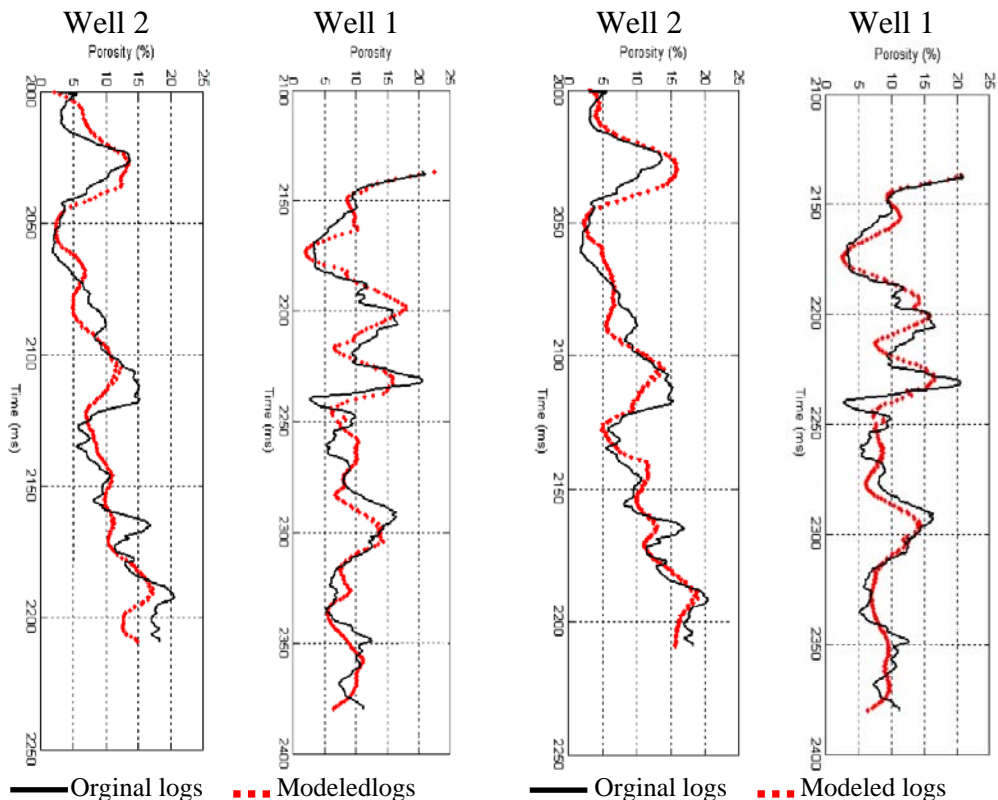
مرحله آزمایش		مرحله آموزش		نوع مدل
خطا (%)	همبستگی (%)	خطا (%)	همبستگی (%)	
۴/۵	۸۳	۲/۷	۹۳	پیش‌خور چندلایه (MLFN)
۵/۷	۶۸	۳/۴	۸۹	احتمالاتی (PNN)
۲/۶	۸۰	۲/۲	۸۵	فازی عصبی



شکل ۸. نگار اصلی و مدل‌سازی شبکه PNN در مرحله آموزش (راست) و مرحله آزمایش (چپ).

۴ نتیجه‌گیری
مقایسه با شبکه‌های عصبی، استفاده از مدل فازی عصبی منجر به خطای کمتری در برآورد خصوصیات مخزن می‌شود.

استفاده از شبکه فازی عصبی خطی محلی با الگوریتم یادگیری LOLIMOT در برآورد خصوصیات مخزن با استفاده از نشانگرهای لرزه‌ای، کارایی قابل قبولی دارد. در



شکل ۹. نگار اصلی و مدل‌سازی فازی عصبی در مرحله آموزش (راست) و مرحله آزمایش (چپ).

from classical approaches to neural networks and fuzzy models. Springer.

Nikravesh, M., 2007, Computational intelligence for geosciences and oil exploration, Forging new frontiers: Fuzzy Pioneers I, 267-332.

Nikravesh, M., Aminzadeh, F., and Zadeh, L. A., 2003, Soft computing and intelligent data analysis: Elsevier.

Sandham, W., Leggett, L., and Aminzadeh, F., 2003, Applications of artificial neural networks and fuzzy logic: Kluwer Academic Publisher.

Wong, P. M., Aminzadeh, F., and Nikravesh, M., 2002, Soft computing for reservoir characterization and modeling: Physica Verlag.

Yulong, H., and Zhiyong, L., 2005, Interpretation of two-dimensional/three-dimensional seismic data of Aran structural belt in Kashan block. Tehran: National Iranian Oil Company (NIOC). K-537, 30-40.

منابع

Aminzadeh, F., and Brouwer, F., 2006, Integrating neural network and fuzzy logic for improved reservoir property prediction and prospect ranking: SEG, Expanded Abstracts **25**, 1052-3812

Aminzadeh, F., and De Groot, P., 2004, Soft computing for qualitative and quantitative seismic object and reservoir property prediction: First Break, 22, March, 49-54.

Banchs, R. E., and Michelena, R. J., 2002, From 3D seismic attributes to pseudo-well-log volumes using neural networks: Practical considerations. The Leading Edge, October, 996-1001.

Hampson, D. P., Schuelke, J. S., and Quirein, J. A., 2001, Use of multiattribute transforms to predict log properties: Geophysics, **66**, 220-231.

Nelles, O., 2001, Nonlinear system identification: