

## برآورد کردن تخلخل مؤثر مخزن با استفاده از تحلیل چندنشاندگی

علی عدالت<sup>۱\*</sup>، حمیدرضا سیاه‌کوهی<sup>۲</sup> و رضا توکلی مقدم<sup>۳</sup>

<sup>۱</sup>شرکت نفت و گاز پارس، تهران، ایران

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

<sup>۳</sup>استاد، گروه مهندسی صنایع، دانشکده فنی دانشگاه تهران، ایران

edalat\_ali@yahoo.com, hamid@ut.ac.ir, tavakoli@ut.ac.ir

(تاریخ دریافت: ۱۳۸۵/۱۱/۲۲، تاریخ پذیرش: ۱۳۸۷/۱۰/۱۶)

### چکیده

در این تحقیق با طراحی کردن یک شبکه عصبی احتمالاتی و همچنین استفاده همزمان از نشاندگی‌های لرزه‌ای و نگاره‌های تخلخل مؤثر چاه‌ها در محدوده مخزن، سعی در برآورد کردن تخلخل مؤثر در یکی از میداین نفتی واقع در خلیج فارس نموده‌ایم. برای رسیدن به این هدف از تبدیل چندنشاندگی بین زیر مجموعه‌ای بهینه از نشاندگی‌های لرزه‌ای و نگاره‌های تخلخل مؤثر استفاده شده است. داده‌های لرزه‌ای استفاده شده در این تحقیق شامل مکعب داده‌های لرزه‌ای سه‌بعدی مهاجرت یافته قبل از برانبارش (PSTM) می‌باشد که دارای اندازه بلوک  $12/5 \times 12/5$  متر می‌باشد که فاصله نمونه برداری زمانی این داده‌ها چهار میلی ثانیه و طول تریس‌های لرزه‌ای دو ثانیه است. همچنین از اطلاعات پنج چاه قائم که در منطقه مورد مطالعه حفر شده‌اند و دارای مجموعه کاملی از نگاره‌های صوتی (DT)، چگالی (RHOB)، تخلخل مؤثر (PHIE) و داده‌های سرعت چک شات (Check shots) هستند نیز استفاده شده است. لایه مخزنی مورد مطالعه، بخش میشریف از سازند سروک با سن کرتاسه میانی می‌باشد که یکی از مخازن نفتی مهم در خلیج فارس است. راس میشریف منطبق است با سطح ناپیوستگی ترونین میانی (Middle Turonian Unconformity) و توسط سازند شیلی لافان پوشیده شده است. بخش میشریف در منطقه مورد بررسی از دو زون مخزنی تشکیل شده است. زون پایینی با دارا بودن محتوای رسی بیشتر از زون بالایی متمایز می‌گردد. زون بالایی شامل سنگ آهک‌های تمیز با خصوصیات مخزنی مناسب‌تری است.

برای تولید نشاندگی‌های لرزه‌ای مورد نیاز، ردلرزه‌ای موجود در محل چاه‌ها از مکعب داده‌های لرزه‌ای سه بعدی استخراج شدند. در این تحقیق نگاره‌های تخلخل مؤثر در محدوده مخزن، حکم نگاره‌های هدف را داشتند.

شبکه عصبی طراحی شده شامل یک لایه ورودی، یک لایه مخفی با چهار واحد پردازشی (نرون) و یک لایه خروجی می‌باشد. به‌منظور تهیه نمونه‌های آموزشی برای آموزش شبکه عصبی، ابتدا نگاره‌های PHIE با استفاده از رابطه زمان - عمق که با استفاده از منحنی‌های چک‌شات و نگاره‌های DT در محل هر کدام از چاه‌ها محاسبه شده بودند، به حوزه زمان برگردانده شدند. سپس این نگاره‌ها با استفاده از فیلتر هنینگ با طول ۴ میلی ثانیه فیلتر شده و با نرخ نمونه‌برداری اطلاعات لرزه‌نگاری (۴ میلی‌ثانیه) نمونه‌برداری مجدد شدند. در مرحله بعد یک مجموعه از نشاندگی‌های لرزه‌ای شامل شانزده نشاندگی لرزه‌ای بر پایه نمونه تولید شد. نمونه‌های تهیه شده در این مطالعه (نشاندگی‌های لرزه‌ای انتخاب شده به همراه داده‌های تخلخل مؤثر متناظر در حوزه زمان) شامل ۵۷ نمونه می‌باشد. برای آموزش شبکه، نمونه‌ها به سه بخش نمونه‌های آموزشی، اعتبارسنجی متقابل و آزمایشی تقسیم شدند. از نمونه‌های آموزشی برای تنظیم وزن‌ها، از نمونه‌های اعتبارسنجی برای پیشگیری از آموزش اضافی شبکه و از نمونه‌های آزمایشی، برای اطمینان از قابلیت تعمیم شبکه استفاده شد.

به‌منظور انتخاب بهترین نشاندگی‌ها برای آموزش شبکه عصبی، از روش برازش گام به گام پیشرو استفاده شده است. چهار نشاندگی فرکانس غالب، دامنه تجمعی مطلق، فرکانس وزن‌دار دامنه و فیلتر میان‌گذر ۴۵-۶۰ هرتز تریس لرزه‌ای به‌عنوان بهترین نشاندگی‌ها انتخاب شدند.

\*Corresponding author:

edalat\_ali@yahoo.com

\*نگارنده رابطا:

پس از آموزش شبکه، از این شبکه برای تخمین داده‌های آزمایشی استفاده شد. نتایج بدست آمده حاکی از همبستگی خوب بین داده‌های واقعی و داده‌های تخمینی به میزان ۹۲٪ است. در نهایت به منظور بالا بردن قابلیت تعمیم شبکه، نمونه‌های آزمایشی به نمونه‌های آموزشی اضافه شد و شبکه مجدداً با تمامی داده‌ها آموزش داده شد و از آن برای تخمین تخلخل مؤثر در محل چاه‌ها استفاده شد. در این حالت ضریب هم‌خوانی بین داده‌های واقعی و داده‌های تخمینی به ۹۵٪ افزایش یافت. نتایج این تحقیق قابلیت بالای شبکه‌های عصبی احتمالاتی را در برآورد کردن تخلخل مؤثر، حتی در مواقعی که تعداد نمونه‌های آموزشی کم است، روشن ساخت.

واژه‌های کلیدی: شبکه عصبی، چندنشانه‌های لرزه‌ای، توصیف مخزن، تخلخل مؤثر

## Effective porosity estimation using multiattribute analysis

Ali Edalat<sup>1\*</sup>, Hamid Reza Siahkoochi<sup>2</sup> and Reza Tavakoli Moghaddam<sup>3</sup>,

<sup>1</sup>*Pars Oil and Gas Company, Tehran, Iran*

<sup>2</sup>*Institute of Geophysics, University of Tehran, Iran*

<sup>3</sup>*Department of Industrial Engineering, Faculty of Engineering, University of Tehran, Iran*

(Received: 13 March 2007, accepted: 05 January 2009)

### Summary

In this study, an attempt is made to predict effective porosity in one of the oil fields in the Persian Gulf by designing a probabilistic neural network (PNN) and simultaneously making use of seismic attributes and effective porosity logs in the reservoir window. This was done by deriving a multiattribute transformation between an optimum subset of seismic attributes and the effective porosity logs.

The geophysical data used in this study consist of 3D seismic pre-stack time migrated (PSTM) data with 12.5\*12.5 m grid size and a 4 ms sampling rate. The length of the seismic traces are two seconds. Well logs of five vertical wells in the study area, including Sonic (DT), Density (RHOB), Effective Porosity (PHIE) and Seismic Well Velocity Surveys (Check Shots), were used. The reservoir layer is a Mishrif member of the Sarvak formation with Cretaceous age, which is common in oil reservoirs in the Persian Gulf. The top of the Mishrif is adjusted with the Middle Turonian Unconformity and covered with shaley Laffan formation. The Mishrif Reservoir in study area contains two reservoir zones. The lower zone with higher clay content is separate from the upper zone. The upper zone consists of clean limestone with better reservoir properties. Seismic traces close to the well locations were used to generate seismic attributes. Effective porosity logs at the reservoir area were the target logs in this study.

The designed neural network consists of one input layer, one hidden layer with four processing units (neuron), and one output layer with one neuron. In order to prepare training samples for the neural network, PHIE logs were converted to time domain using a time-depth relationship calculated from the DT logs and check shot curves for each well location. Subsequently, these logs were filtered (using a Hanning filter with 4 ms length) and resampled with seismic sampling rate (4 ms). Finally, a set of seismic attributes, including sixteen sample-based seismic attributes, were generated using HRS software. Training samples in this study consisted of 57 samples (selected seismic attributes and their related effective porosity from PHIE logs in the time domain). For training the network, the samples were divided into three data sets: the training samples, cross validation samples and testing samples. The training data were used for adjusting the weights of the network; the cross validation data were used to prevent overtraining the

neural network; and the testing data were used to ensure generalizability of the network output.

A forward stepwise regression process was used to determine an optimum subset of attributes for use in the training of the neural networks. The optimum subset of attributes in this study consists of the Dominant Frequency, Amplitude Weighted Frequency, Integrated Absolute Amplitude and Filter 45-60 Hz.

After the network was trained using training and cross validation data sets, it was used to predict the testing data. The results show a good correlation between real and predicted data, with 92% correlation. Finally, in order to attain a better generalization of the network, testing data sets were inserted to trained data and the network was trained again. This network was then used to predict effective porosity in well locations which increased the correlation coefficient to 95%. This study shows the ability of the PNN networks to predict effective porosity even with a paucity of training examplars.

**Key words:** Neural network, seismic multiattributes, reservoir characterization, effective porosity

۱ مقدمه  
 صورت گرفته حتی در یک چاه برای توصیف مخزن کافی بود. ولی به خاطر ناهمگنی‌های موجود در سنگ مخزن، این پارامترها تغییرات زیادی در محدوده مخزن از خود آشکار می‌سازند. بنابراین نیازمند استفاده از روش‌های تجمیع (Integrated methodes) به منظور استفاده بهینه از همه داده‌های موجود برای دستیابی به مدلی مناسب از آنها هستیم. یکی از روش‌های تجمیع، استفاده از نشانگرهای لرزه‌ای (Seismic attributes) برای برآورد کردن خصوصیات نگاره (Log properties) است. نشانگر لرزه‌ای به هر پارامتری گفته می‌شود که بتوان آن را به نوعی از داده‌های لرزه‌ای قبل یا بعد از برانبارش به دست آورد، یا به شکل فضایی به صورت نقشه درآورد (تانر و همکاران، ۱۹۷۹). نشانگر لرزه‌ای پارامتری است که به نحوی بتواند داده‌های لرزه‌ای را به مشخصه‌های مخزن ارتباط دهد و ویژگی‌های مخزن را آشکار سازد. تعداد زیادی از تحقیقات قبلی نشان داده‌اند که برآورد کردن خصوصیات نگاره‌ها با استفاده از نشانگرهای لرزه‌ای امکان‌پذیر است (برای مثال لیپارت و هارت، ۲۰۰۱؛ همپسون و همکاران، ۲۰۰۱).

به دست آوردن توصیف صحیحی از تغییرات جانبی ناهمگنی‌های مخزن اغلب در ساخت مدل مخزن حیاتی است. از این نقطه نظر، داده‌های چاه به تنهایی نمی‌توانند تغییر خصوصیات مخزن را به درستی پوشش دهند. زیرا معمولاً توزیع آنها در میدان نفتی بسیار پراکنده است و فاصله آنها در مقایسه با ابعاد ناهمگنی‌هایی که باید مدل شوند خیلی بزرگ است. از طرفی در مقایسه با داده‌های پراکنده چاه‌ها، داده‌های لرزه‌ای سه بعدی یک نمونه برداری منظم و مترکم از پارامترهای مخزن را فراهم می‌آورد که می‌تواند توصیف فضایی مخزن را بهبود دهد. با وجود این داده‌های لرزه‌ای عموماً در راستای قائم، در مقایسه با نگاره‌های چاه، دارای دقت کمی هستند.

پارامترهای اصلی در توصیف مخزن عبارت از تخلخل، اشباع هیدروکربن و تراوایی. روش‌های مورد استفاده به منظور بررسی و تعیین تغییرات فضایی این پارامترها با عنوان توصیف مخزن (Reservoir characterization, RC) شناخته می‌شوند. اگر پارامترهای فوق در سراسر مخزن یکنواخت می‌بود، اندازه‌گیری‌های

معکوس سازی، برآورد فشار حفره ها و AVO نیز باشد. با در نظر گرفتن نام نشانگر برای مقادیر حاصل از محاسبات پیچیده مانند معکوس سازی مقاومت صوتی و برآورد فشار حفره ها، تصدیق می کنیم که این برآوردها به طریقی به خطا آلوده هستند و بنابراین نیاز است که با داده های چاه به روش های زمین آماری یا دیگر روش های تجمع، همسنجی شوند.

## ۱-۲ تاریخچه استفاده از نشانگرهای لرزه ای

بعضی از نشانگرهای لرزه ای مهم قبل از شروع برداشت لرزه ای به روش رقومی (دیجیتال) و هنگام استفاده از ثبت های کاغذی، کشف و مورد استفاده قرار می گرفتند. در آن زمان لرزه شناس ها دریافتند که محدوده هایی که در آنها بازتاب پیوستگی ندارد، می تواند منطبق با محل گسل ها باشد. شروع برداشت رقومی در سال ۱۹۶۳ که داده های با کیفیت زیاد در اختیار مفسران قرار می داد، تحول بزرگی در مطالعات لرزه نگاری به وجود آورد. در دهه ۱۹۶۰، مفسران بازتابنده های قوی مجزایی، که لکه های روشن (Bright spots) نامیده شدند، را روی ثبت های لرزه ای مشاهده کردند. حفاری های صورت گرفته در محل لکه های روشن مشخص کرد که این بازتابها مربوط به سنگ های مخزنی حاوی گاز هستند که دارای دامنه های قوی تری نسبت به زون های مجاورند که فقط از آب یا نفت اشباع شده اند.

بنابراین از آن به بعد این نشانگر لرزه ای در حکم شاخصی از وجود گاز در لرزه نگاری به کار رفت و به دنبال آن محققان نشانگرهای بسیاری (چندصد نشانگر) را کشف کردند و مورد استفاده قرار دادند. چوپرا و مارفورت (۲۰۰۵) تاریخچه جمعی از توسعه نشانگرهای لرزه ای به همراه توصیف اغلب نشانگرهای لرزه ای اصلی را کرده اند.

استفاده از نشانگرهای لرزه ای از دهه ۱۹۷۰ میلادی آغاز شد و نشانگرهای لرزه ای متعددی توسط محققان معرفی شده و مورد استفاده قرار گرفته است که هر کدام از آنها برای توصیف یکی از مشخصه های فیزیکی یا زمین شناختی لایه های زیر سطحی به کار می روند. چن و سیدنی (۱۹۹۷) فهرست جامعی از این نشانگرها به همراه روش تولید و کاربرد آنها را ارائه داده اند. اکثر نشانگرها مشتقات غیرخطی از تریس های لرزه ای هستند. این غیرخطی بودن می تواند آن دسته از خصوصیات مخزنی و زمین شناسی را که نمی توان در داده های لرزه ای خام دید، مشخص کند. رابطه غیرخطی بین نشانگرها و خصوصیات نگاره ها، توانایی روش های خطی را برای برآورد کردن پارامترها محدود می کند، بنابراین می بایست روش های غیرخطی (مانند استفاده از شبکه های عصبی) برای برآورد پارامترها را جستجو کرد.

در این تحقیق سعی می شود با استفاده هم زمان از مقاطع لرزه نگاری سه بعدی و نگاره های تخلخل مؤثر چاه ها در مخزن میشریف، که یکی از لایه های مخزنی اصلی در خلیج فارس است (شکل ۱)، تخلخل مؤثر را برآورد کرد. برای عملی ساختن این کار یک شبکه عصبی احتمالاتی (Probabilistic neural network; PNN طراحی شد.

## ۲ نشانگرهای لرزه ای

در تعریف جامع از نشانگرهای لرزه ای می توان گفت که نشانگرهای لرزه ای اندازه گیری های هندسی، سینماتیک، دینامیک و ویژگی های آماری از داده های لرزه ای هستند. از یک دیدگاه کلی، تعریف نشانگرهای لرزه ای همه کمیت های به دست آمده از داده های لرزه ای را در بر می گیرد. این تعریف می تواند شامل یک رابطه ساده ریاضی مانند مشتق تریس لرزه ای و یا رابطه پیچیده ای مانند سرعت های بازه ای، مقاومت صوتی به دست آمده از



شکل ۱. نقشه پایه منطقه مورد تحقیق در خلیج فارس (گزارش‌های فنی شرکت نفت فلات قاره).

## ۲-۲ استفاده هم‌زمان از چند نشانه‌گر لرزه‌ای

با افزایش تعداد نشانه‌گرها در دهه ۱۹۸۰، تنوع نشانه‌گرهای در دسترس لرزه‌شناسان برای بررسی خصوصیات زمین‌شناسی مخزن افزایش یافت. آزمایش تک‌تک این نشانه‌گرها به‌منظور به‌دست آوردن نشانه‌گری که ارتباط معنی‌دار و مناسبی با خصوصیت مورد نظر مخزن داشته باشد، وقت‌گیر و خسته‌کننده بود. به‌همین دلیل بررسی‌هایی به‌منظور انتخاب نشانه‌گرها به‌صورت خودکار صورت گرفت که در آن با بررسی رایانه‌ای داده‌ها سعی در به‌دست آوردن الگوی مناسب از نشانه‌گرهای لرزه‌ای شد (دیفیگورودو، ۱۹۸۲).

از اواخر دهه ۱۹۹۰ میلادی استفاده هم‌زمان از چند نشانه‌گر (تحلیل چندنشانه‌گری) آغاز شد. تحقیقات روشن ساخت که ممکن است چندین نشانه‌گر به یک خصوصیت مخزن حساس باشند و استفاده هم‌زمان از این نشانه‌گرها می‌تواند کیفیت برآورد را افزایش دهد. فکر استفاده از چند نشانه‌گر را اولین بار شولتز و همکاران (۱۹۹۴ a, b) پیشنهاد کردند. آنها با استفاده از شبکه‌های عصبی سعی در


برآورد کردن خودکار خصوصیات مخزن داشتند. در این روش ارتباط نشانه‌گرها با خصوصیات مخزن در محل چاه‌ها، درحکم نمونه‌های آموزشی در نظر گرفته و شبکه با این نمونه‌ها آموزش داده می‌شد. سپس از این شبکه برای برآورد خصوصیات مخزن در مکان‌های دیگر استفاده می‌شد.

در سال‌های بعد و با توجه به افزایش تعداد نشانه‌گرهای قابل تولید، روش‌های متفاوتی برای انتخاب بهترین نشانه‌گرها به‌منظور برآورد کردن بهینه خصوصیات مخزن ابداع شد. همپسون و همکاران (۲۰۰۱) از روش برازش گام‌به‌گام خطی چندنشانه‌گری برای انتخاب بهترین ترکیب از نشانه‌گرها استفاده کردند. اخیراً نیز از روش‌های بهینه‌سازی عمومی برای انتخاب بهترین ترکیب از نشانه‌گرها استفاده شده است. دورینگتون و لینک (۲۰۰۴) با استفاده از الگوریتم ژنتیک بهترین نشانه‌گرها را برای برآورد کردن تخلخل بدست آوردند. همچنین پرامنیک و همکاران (۲۰۰۴) به مقایسه روش چندنشانه‌گری با دیگر فنون موجود برای برآورد کردن تخلخل مؤثر پرداختند.

### ۳ شبکه‌های عصبی

شبکه‌های عصبی مصنوعی ابزارهای محاسباتی موازی‌اند که شامل تعداد زیادی پردازشگرهای ساده متصل به هم هستند. هر پردازشگر در یک شبکه فقط با سیگنال‌هایی که متناوباً دریافت و به پردازشگرهای دیگر ارسال می‌کند سروکار دارد. این پردازشگرهای ساده موضعی هنگامی که در یک شبکه بزرگ موزون قرار می‌گیرند، توانایی به انجام رساندن کارهای پیچیده را پیدا می‌کنند.

شبکه‌های عصبی عموماً از سه لایه (ورودی، مخفی و خروجی) تشکیل شده‌اند. هر لایه در شبکه عصبی از مجموعه‌ای از چندین واحد یا نرون (Neuron) تشکیل شده است که مطابق الگوهای به هم متصل‌اند. این الگوها امکان ارتباط و عبور اطلاعات بین واحدها را تعیین می‌کنند. واحدها، پردازشگرهای ساده‌ای هستند که توانایی محاسباتی آنها معمولاً محدود شده است به قاعده‌ای برای ترکیب سیگنال‌های ورودی و یک قاعده برانگیزش که ورودی‌های ترکیب شده را می‌گیرد و یک سیگنال خروجی محاسبه می‌کند. سیگنال‌های خروجی از راه اتصال‌هایی که وزن نامیده می‌شوند، به واحدهای دیگر ارسال می‌شوند. شکل ۲ ساختار شبکه‌های عصبی را به‌طور اجمالی نشان می‌دهد. توصیف کاملی از شبکه‌های عصبی و انواع گوناگون آنها را می‌توان در کتابهایی مانند مسترز، ۱۹۹۴؛ کروس و همکاران، ۱۹۹۶ یافت.



شکل ۲. ساختار اجمالی یک شبکه عصبی شامل لایه ورودی، لایه مخفی و لایه خروجی.

دو نوع شبکه عصبی برای مسائل برآورد کردن مناسب هستند: شبکه عصبی احتمالاتی (PNN) و شبکه عصبی پیشرو چندلایه (Multi layer feedforward neural networks; MLFN). یادگیری در شبکه‌های PNN خیلی سریع‌تر از شبکه‌های عصبی MLFN صورت می‌گیرد. هنگامی که تعداد نمونه‌ها خیلی کم است (کمتر از ۱۰۰ نمونه) شبکه‌های PNN بهتر از شبکه‌های MLFN عمل می‌کنند. از طرفی تحقیقات اخیر نشان داده است که شبکه‌های عصبی احتمالاتی موفقیت بیشتری در برآورد کردن تخلخل با استفاده از نشانگرهای لرزه‌ای داشته‌اند (همپسون و همکاران، ۲۰۰۱؛ دورینگتون و لینکز، ۲۰۰۴). با توجه باینکه در این تحقیق تعداد نمونه‌های آموزشی کم (۵۷ نمونه) است، طراحی یک شبکه PNN در دستور کار قرار گرفت. بنابراین در اینجا به تشریح این نوع شبکه عصبی اکتفا می‌کنیم.

### ۳-۱ شبکه عصبی احتمالاتی

شبکه عصبی احتمالاتی (PNN) یک شبکه پیش‌خور و تحت‌نظارت ماست که از یک تابع انتقال نمایی استفاده می‌کند. مزیت اصلی این شبکه بر شبکه‌های پسرانتشار این است که زمان آموزش آن خیلی کوتاه‌تر است. مزیت‌های دیگر آن عبارت‌اند از اینکه این شبکه با داده‌های پراکنده با موفقیت آموزش می‌بیند و الگوهای جدید را می‌توان در هنگام آموزش بر روی الگوی قبلی بازنویسی کرد. این شبکه هر الگوی آموزشی را ذخیره می‌کند و بنابراین برای گستره‌های خیلی بزرگ کارایی ندارد. در مورد مسائلی که در آنها زمان آموزش خیلی حساس است و یا مجموعه داده‌های آموزشی در دسترس کوچک است، این شبکه می‌تواند جایگزینی خوب برای پسرانتشار باشد (اسپکت، ۱۹۹۰، ۱۹۹۱؛ مسترز، ۱۹۹۵).

داده‌هایی که در PNN استفاده می‌شوند شامل مجموعه‌ای از مثال‌های آموزشی هستند. هر مثال آموزشی

اعتبارسنجی برای  $m$ مین نمونه هدف به شکل زیر تعریف می شود:

$$\hat{L}_m(x_m) = \frac{\sum_{i \neq m} L_i \exp(-D(x_m, x_i))}{\sum_{i \neq m} \exp(-D(x_m, x_i))} \quad (3)$$

این یک مقدار برآورد شده برای  $m$ مین نمونه هدف است هنگامی که آن نمونه از داده های آموزشی کنار گذاشته شده باشد. چون مقدار این نمونه را می دانیم، می توان خطای برآورد را برای آنها محاسبه کرد. این رویه برای همه نمونه های آموزشی صورت می گیرد. در نهایت خطای برآورد کردن کل برای داده های آموزشی به صورت زیر تعریف می شود:

$$E_v(\sigma_1, \sigma_2, \sigma_3) = \sum_{i=1}^N (L_i - \hat{L}_i)^2 \quad (4)$$

توجه کنید که خطای برآورد کردن بستگی به انتخاب پارامترهای  $\sigma$  دارد. این مقدار با استفاده از یک الگوریتم گرادینان مزدوج غیرخطی که مسترز (۱۹۹۵) آن را توصیف کرده است، مینیمم می شود.

شبکه PNN به خوبی شبکه MLFN از روند داده ها پیروی می کند. همچنین این شبکه نسبت به شبکه MLFN، ناپایداری کمتری در مرز محدوده داده ها دارد. بزرگ ترین مشکل این شبکه این است که چون همه داده های آموزشی را در حافظه خود نگه می دارد و نمونه های خروجی را با آنها مقایسه می کند، هنگامی که تعداد نمونه ها زیاد است سرعت کار پایین خواهد بود.

#### ۴ زمین شناسی مخزن مورد بررسی

کرتاسه میانی در محدوده خلیج فارس شامل دو سازند کژدمی و سروک است. سازند کژدمی غالباً از شیل تشکیل شده است در صورتی که سازند سروک غالباً از سنگ آهک تشکیل شده است. مخزن مورد بررسی بخش

شامل مقادیر ورودی ها و خروجی متناظر با آنها است. برای نمونه برای  $n$  مثال آموزشی با سه ورودی و یک خروجی داریم:

$$\begin{aligned} &\{A_{11}, A_{21}, A_{31}, L_1\} \\ &\{A_{12}, A_{22}, A_{32}, L_2\} \\ &\{A_{13}, A_{23}, A_{33}, L_3\} \\ &\vdots \\ &\{A_{1n}, A_{2n}, A_{3n}, L_n\}, \end{aligned}$$

مقادیر  $L_i$  همان مقادیر هدف اندازه گیری شده (خروجی مطلوب) هستند. برای هر مجموعه آموزشی، PNN فرض می کند که هر مقدار خروجی جدید را می توان به صورت ترکیب خطی از مقادیر ورودی در داده های آموزشی نوشت. برای یک نمونه داده جدید  $x = \{A_{1j}, A_{2j}, A_{3j}\}$  مقدار خروجی برآورده شده برابر خواهد بود با:

$$\hat{L}(x) = \frac{\sum_{i=1}^n L_i \exp(-D(x, x_i))}{\sum_{i=1}^n \exp(-D(x, x_i))} \quad (1)$$

که در آن:

$$D(x, x_i) = \sum_{j=1}^n \left( \frac{x_j - x_{ij}}{\sigma_j} \right)^2 \quad (2)$$

مقدار  $D(x, x_i)$  برابر است با فاصله بین نقطه ورودی و هر کدام از نقاط آموزشی  $x_i$ . این فاصله در فضای چندبعدی که ورودی ها آن را تعریف کنند، اندازه گیری و با مقدار  $\sigma$  مدرج (مقیاس) می شود که ممکن است برای ورودی های گوناگون متفاوت باشد.

معادله های (۱) و (۲) کاربرد PNN را توصیف می کنند. آموزش شبکه شامل به دست آوردن مجموعه بهینه ای از پارامترهای نرم کننده  $\sigma$  است. قاعده به دست آوردن این پارامترها این است که شبکه حاصل می بایست دارای کمترین خطای اعتبارسنجی باشد. نتیجه

(Rudist) مربوط به محیط‌های دریایی باز تا کم عمق تشکیل شده است. این محیط رسوب گذاری باعث به وجود آمدن رسوب‌های متفاوت از سنگ آهک‌های میکریتی فسیل دار تا سنگ آهک‌های رس دار شده است.

خطیا: این رخساره معادل قسمت میانی تا پایینی سازند سروک است و وکستون، پکستون و گل سنگ (Mudstone) چگال با تخلخل خیلی کم را در بر گرفته است.

ماودود: این بخش از وکستون، پکستون و سنگدانه‌های (Grainstone) چگال با تخلخل کم تشکیل

میشریف از سازند سروک در یکی از میدین نفتی جنوب است. شکل ۳ ستون چینه‌شناسی را در منطقه مورد بررسی نشان می‌دهد.

همان‌طور که در این شکل نشان داده شده است، سازند سروک در منطقه مورد بررسی از سه بخش آهکی میشریف، خطیا و ماودود تشکیل شده است (جیمز و ویند، ۱۹۶۵؛ ستوده نیا، ۱۹۷۲):

میشریف: معادل فوقانی ترین رسوبات سازند سروک در منطقه است و از وکستون (Wackestone) و پکستون‌های (Packstone) آب‌های کم عمق، همراه با قطعات رودیستی

Era	System / Period		Series	Formation		
Cenozoic	Quaternary			Bakhtiari		
	Tertiary	Neogene		Agha Jari		
				Mishan		
				Guri Member		
				Gachsaran		
				Asmari		
		Paleogene	Eocene Paleocene	Dammam	Jahrum	
	Rus			Pabdeh		
	Mesozoic	Cretaceous		Upper	Radhuma	Gurpi
					Simsima	
Shargi						
Malul					Ilam	
Middle				Laffan	Sarvak	
				Mishrif		
				Khatiyah		
				Maudud	Kazhdumi	
				Nahr UMR		
				Lower	Shuaiba	Dariyan
Hawar	Cadvan					
Kharaib						
Yamama	Fahliyan					
		Sulaiy				

~ Unconformity

شکل ۳. ستون چینه‌شناسی منطقه مورد بررسی از کرتاسه تا کواترنری (گزارش‌های فنی شرکت نفت فلات قاره).

فرسایش نشان‌دهنده کاهش در نرخ رسوب گذاری است. بخش میشریف در منطقه مورد بررسی از دو زون مخزنی

شده است. در قسمت بالایی ماودود تراکم‌های موضعی از رودیست‌های اسکلتی وجود دارد. همچنین وجود سطوح



داده‌های سرعت چک‌شات (Check shot) هستند. همچنین در این چاه‌ها لرزه‌نگاشت مصنوعی تهیه و سپس با داده‌های لرزه‌ای کالیبره شد. برای تولید نشانگرهای لرزه‌ای، تریس‌های لرزه‌ای موجود در محل چاه‌ها استخراج شده‌اند. در این تحقیق از نگاره‌های تخلخل موثر این چاه‌ها و نشانگرهای لرزه‌ای متناظر با آنها در حکم داده‌های آموزشی استفاده شده است.

#### ۵-۱ تبدیل نگاره تخلخل موثر به نگاره زمانی

با توجه به اینکه داده‌های لرزه‌ای برحسب زمان هستند، قبل از هر کاری ابتدا می‌بایست رابطه‌ای برای تبدیل محور عمق به زمان در نگاره‌های موجود در هر چاه به دست آورد که این رابطه با استفاده از چک‌شات و نگاره صوتی به دست آمد. سپس محور قائم نگاره‌ها با استفاده از این رابطه به زمان تبدیل شد. در مرحله بعد این داده‌ها با فیلتر پایین‌گذر به بسامد قطع برابر ۱۲۵Hz (بسامد نایکوئیست داده‌های لرزه‌ای) فیلتر شدند و در نهایت با فاصله نمونه‌برداری زمانی (۴ms) از آنها نمونه برداری شد. به منظور عملی شدن این کار از نرم افزار EasyTrace استفاده شد. مراحل به انجام رسیدن این کار عبارت‌اند از:

- تهیه رابطه زمان - عمق در چاه‌ها با استفاده از چک‌شات و نگاره صوتی

۲. تبدیل نگاره‌های عمقی به نگاره‌های زمانی

۳. نمونه برداری منظم از نگاره‌های زمانی با فاصله نمونه برداری کم (۰/۱ms)

۴. اعمال فیلتر پایین‌گذر ۱۲۵Hz بر نگاره‌ها به منظور حذف بسامدهای بالاتر از بسامد نایکوئیست

۵. نمونه برداری مجدد از نگاره‌ها با فاصله نمونه‌برداری زمانی مشابه داده‌های لرزه‌ای (۴ms)

با توجه به اینکه داده‌های نگاره تخلخل موثر فقط در محدوده مخزن موجود بود، اعمال فیلتر بسامدی باعث شد که نگاره فیلتر شده در ابتدای نگاره از روند آن پیروی

تشکیل شده است (الشهران و نایرن، ۱۹۹۷). زون پایینی با دارا بودن محتوای رسی بیشتر از زون فوقانی متمایز می‌شود. لایه‌های آهکی این زون که به سمت پایین به لایه‌های مارلی با میان‌لایه‌های شیلی تبدیل می‌شوند عموماً دارای تخلخل متوسط تا ضعیف و آغشتگی کم هستند. به‌طور کلی می‌توان گفت که کیفیت مخزن در این زون به سمت پایین با افزایش میزان کانی‌های رسی کاهش می‌یابد. زون بالایی شامل سنگ آهک‌های تمیز با خصوصیات مخزنی مناسب‌تری است و می‌توان آن‌را به دو زیرزون تقسیم کرد. زیرزون بالایی از سنگ‌های آهکی فسیل‌دار با تخلخل خوب تشکیل شده است، درحالی‌که زیرزون پایینی از سنگ‌های آهکی فسیل‌دار و میکربیتی تا سنگ‌های آهکی رس‌دار با تخلخل نسبتاً خوب تشکیل شده است.

رأس میشریف منطبق با سطح ناپیوستگی ترونین میانی (Middle Turonian unconformity) است و با سازند شیلی لافان پوشیده شده است. چنین به نظر می‌آید که در اثر عمل انحلال همراه با فرسایش ناشی از تشکیل ناپیوستگی ترونین، میزان تخلخل و تراوایی در بخش بالایی میشریف افزایش یافته است. با توجه به افزایش ضخامت لایه میشریف از جنوب به شمال، اثرات فرسایش ذکر شده در قسمت‌های جنوبی بیش از نواحی شمالی بوده است.

#### ۵ آماده سازی داده‌ها

داده‌های لرزه‌ای استفاده شده در این تحقیق شامل مکعب داده‌های لرزه‌ای سه‌بعدی مهاجرت یافته‌اند که اندازه بلوک آنها  $12/5 \times 12/5$  متر است. فاصله نمونه برداری زمانی این داده‌ها ۴ میلی ثانیه و طول تریس‌های لرزه‌ای دو ثانیه است. پنج چاه قائم نیز در منطقه مورد بررسی حفر شده‌اند که دارای مجموعه کاملی از نگاره‌های صوتی (DT)، چگالی (RHOB)، تخلخل موثر (PHIE) و

می‌شود که از یک شبکه با پیچیدگی کم استفاده شود. منظور از پیچیدگی شبکه، تعداد لایه‌های مخفی و همچنین عناصر پردازشی آنها (نرونها) است. اگر یک شبکه کوچک بتواند مسئله ما را با موفقیت حل کند، شبکه بزرگ تر نه فقط نیاز به آموزش بیشتر خواهد داشت، بلکه ممکن است بر روی داده‌های جدید بدتر جواب بدهد. این یک مشکل تعمیم است: شبکه عصبی بزرگ تر می‌بایست پارامترهای آزاد بیشتری برای حل مسئله داشته باشد. پارامترهای آزاد زیاد ممکن است باعث تطابق زیاد با داده‌ها شود که این مسئله باعث می‌شود که شبکه، داده‌های آموزشی را حفظ کند و به این داده‌ها اختصاص یابد. وقتی چنین اتفاقی بیفتد، کارایی داده‌های آموزشی خیلی بهتر از داده‌های اعتبارسنجی متقابل و آزمایشی خواهد بود. بنابراین می‌بایست طراحی شبکه حتی الامکان با شبکه‌ای با پیچیدگی کم شروع شود و در صورت نیاز، پیچیدگی شبکه را بالاتر برد. همچنین باید توجه داشت که شبکه‌هایی با پیچیدگی متوسط یا زیاد نیاز به تعداد زیادی نمونه آموزشی برای آموزش مناسب دارند.

طراحی و به‌کارگیری شبکه عصبی یک رویه دینامیکی با مولفه‌های متنوع است. ولی تجربه ما در این تحقیق روشن ساخت که توجه به نکات زیر می‌تواند بهبود قابل توجهی در کارایی شبکه بدهد:

۱. شناخت داده‌ها: حتی در بهترین حالت، از شبکه عصبی نمی‌توان به‌صورت یک جعبه سیاه استفاده کرد. برای طراحی مناسب یک شبکه عصبی می‌بایست از داده‌هایی که قرار است روی آنها کار کرد شناخت کافی داشت. هیچ روش مدونی برای شناخت داده‌ها وجود ندارد و تنها راه شناخت داده‌ها، کاوش آنها با روش‌های گوناگون (مانند سعی در درک رویه فیزیکی تولید داده‌ها و یا بررسی آماری آنها) است.

۲. پردازش داده‌ها: حذف مولفه‌های ورودی غیرضروری و استفاده از تحلیل مولفه‌های اصلی (PCA) و فنون دیگر

نکند. بدین منظور به‌جای اعمال فیلتر پایین‌گذر ۱۲۵Hz (مرحله ۴) روی نگاره‌های زمانی با فاصله نمونه برداری ۰/۱ms، فیلترهای گوناگونی روی این نگاره‌ها اعمال و نتایج با یکدیگر مقایسه شدند. در نهایت مشخص شد که فیلتر هنینگ (Hanning) با طول ۴ms بهترین نتیجه را می‌دهد. شکل ۴ مقایسه دو نوع فیلتر اعمال شده بر نگاره‌های زمانی تخلخل موثر (که دارای فاصله نمونه برداری ۰/۱ms مهستند) را نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، نگاره تخلخل موثر پس از اعمال فیلتر هنینگ به‌خوبی از روند داده‌ها پیروی می‌کند. پس از تبدیل نگاره‌های تخلخل به نگاره‌های زمانی و اعمال فیلتر بر آنها، از این نگاره‌ها با فاصله نمونه برداری ۴ms نمونه برداری شد.

## ۲-۵ تهیه نشانگرهای لرزه‌ای

به‌منظور ساخت نشانگرهای لرزه‌ای از نرم‌افزار HRS استفاده شد. بدین منظور تریس‌های لرزه‌ای که در محل چاه‌ها استخراج شده بودند، با نرم افزار پیش‌گفته قرائت شدند و با استفاده از آنها شانزده نشانگر لحظه‌ای مرتبط با تخلخل تولید شد. از قسمتی از نشانگرهای تولیدشده که در محدوده زمانی مخزن قرار می‌گیرند، برای آموزش شبکه عصبی استفاده خواهد شد. شکل ۵ نشانگرهای تولید شده در محل یکی از چاه‌ها را نشان می‌دهد.

## ۶ طراحی و کاربرد شبکه عصبی

### ۱-۶ طراحی شبکه عصبی

طراحی شبکه و انتخاب نوع آن بستگی به مسئله‌ای دارد که می‌بایست حل شود. مسئله مورد بررسی در این تحقیق از نوع مسائل پیش‌بینی است. هدف این‌گونه مسائل به‌دست آوردن یک خروجی با استفاده از مجموعه‌ای از ورودی‌ها و سابقه گذشته آنها است.

وقتی تعداد نمونه‌های آموزشی کم است توصیه


و این شبکه‌ها آموزش داده می‌شوند. به مجرد دست یافتن به یک آموزش موفقیت‌آمیز، تعداد واحدها به تدریج کاهش داده می‌شود و هر بار آموزش تکرار می‌شود تا به کوچک‌ترین شبکه‌ای که توانایی حل موفقیت‌آمیز مسئله را دارد برسیم. در مورد مسئله ما تعداد بهینه واحدها در لایه مخفی برابر چهار به دست آمد.

تنظیم وزن‌ها در خلال آموزش صورت می‌گیرد. مسئله برآورد کردن وزن‌ها را می‌توان در حکم یک مسئله بهینه‌سازی غیرخطی در نظر گرفت که هدف آن مینیم کردن خطای میانگین مربعی بین مقادیر حقیقی نگاره هدف و مقادیر پیش‌بینی شده آن با شبکه است. به منظور تنظیم وزن‌ها از روش پسانتشار خطا استفاده می‌شود (پارکر، ۱۹۸۵). در این روش که نوعی از گرادیان کاهش می‌باشد، در خلال هر تکرار وزن‌ها با انتشار به عقب سیگنال‌های خطا (تفاوت بین مقدار واقعی و مقدار پیش‌بینی شده) درون شبکه تغییر می‌یابند و یک گرادیان کاهش در سطح خطا به وجود می‌آید. در نتیجه پس از چند تکرار، وزن‌ها به صورتی تنظیم می‌شوند که خطای بین مقدار پیش‌بینی شده و مقدار واقعی به میزان قابل قبولی کاهش یابد. در سامانه‌هایی که دقیق‌اند و اعداد در آنها معنی ریاضی و فیزیکی مشخصی دارند، به عبارتی دیگر در سامانه‌هایی که در آن‌ها اهمیت هر نمونه زیاد است، می‌توانیم گرادیان کاهش در خلال آموزش را به طور تمام و کمال تاثیر بدهیم. اما در سامانه‌هایی که اعداد دارای خطای زیاد هستند و اهمیت نمونه‌ها کم است حتماً باید تاثیر گرادیان را کاهش دهیم، در غیر این صورت شبکه از یک نمونه به نمونه دیگر دچار تنش و تغییر شدید می‌شود و هرگز همگرا نمی‌شود. به این منظور پارامتری به نام نرخ آموزش (Learning rate) تعریف و در گرادیان ضرب می‌شود که متناسب با اهمیت هر نمونه است. اگر اهمیت هر نمونه زیاد باشد این پارامتر باید نزدیک به یک باشد.


برای تبدیل داده‌ها به حالت فشرده‌تر در مواردی که تعداد مولفه‌های ورودی زیاد است.

۳. پیدا کردن کمترین تعداد عناصر پردازشی برای شبکه به صورتی که شبکه همچنان قادر به یادگیری مسئله باشد. تعداد سلول‌ها در لایه ورودی برابر با تعداد ورودی‌ها است. در عمل سعی بر این است که همه پارامترهایی که در پاسخ تاثیر دارند در نظر گرفته شوند؛ البته باید در نظر گرفت که اطلاعات ورودی بی‌استفاده، کار شبکه را مشکل‌تر می‌کنند، زیرا اگر چه شبکه عصبی به نطفه (داده‌های دارای خطا) مقاوم است اما در هر صورت اگر میزان نطفه بیش از حد زیاد باشد، ممکن است شبکه نتواند همگرا شود. تعداد واحدها در لایه خروجی بسته به پیشگویی مورد نظر ما دارد. در مورد مسئله برآورد کردن تخلخل، یک واحد در لایه خروجی کافی است. تعداد لایه‌های مخفی و تعداد واحدها در هر لایه مخفی از پارامترهایی است که از سوی کاربر قابل تنظیم است. زیاد بودن لایه‌ها دقت عددی پیشگویی را کم می‌کند و ممکن است مانع همگرا شدن شبکه شود. در این تحقیق شبکه‌هایی با یک، دو و سه لایه مخفی طراحی و کارایی آنها بررسی شد. در نهایت مشخص شد که شبکه‌ای با یک لایه مخفی به خوبی توانایی پیشگویی دارد و افزایش تعداد لایه‌های مخفی شدیداً کارایی شبکه را کاهش می‌دهد.

نکته دیگر تعداد واحدها در هر لایه مخفی است. به طور برآورد شده، تعداد مناسب واحدهای لایه‌های مخفی بین نصف تا یک و نیم برابر تعداد واحدهای لایه ورودی (یعنی تعداد ورودی‌های سامانه) است. کم بودن مفرط تعداد واحدها قدرت تجزیه و تحلیل (و به دنبال آن دقت عددی پیشگویی) را کاهش می‌دهد. از سوی زیاد بودن مفرط این تعداد منجر می‌شود که سامانه به جای تجزیه و تحلیل داده‌ها، آنها را حفظ کند. معمولاً تعداد واحدها در لایه مخفی در خلال آموزش تعیین می‌شود. ابتدا شبکه‌هایی با تعداد واحدهای متفاوت طراحی می‌شود



شکل ۴. مقایسه دو فیلتر اعمال شده بر نگاره تخلخل موثر چاه شماره چهار. پس از تبدیل محور قائم نگاره تخلخل موثر به زمان، داده‌ها با فاصله نمونه‌برداری ۰/۱ میلی ثانیه نمونه‌برداری شدند (منحنی‌های سبز رنگ). منحنی سرخ‌رنگ در تصویر فوقانی نگاره تخلخل موثر را پس از اعمال فیلتر بسامدی پایین‌گذر ۱۲۵ هرتز نشان می‌دهد و منحنی سرخ‌رنگ در تصویر پایینی نگاره تخلخل موثر را پس از اعمال فیلتر هنینگ با طول پنجره چهار میلی‌ثانیه نشان می‌دهد. خروجی فیلتر بسامدی از روند تغییرات نگاره در ابتدای نگاره پیروی نمی‌کند ولی خروجی فیلتر هنینگ تطابق خوب بین نگاره اولیه و نگاره فیلتر شده نشان می‌دهد.



شکل ۵. نشانگرهای تولید شده از تریس لرزه‌ای استخراج شده در محل یکی از چاه‌های موجود.

مجموعه داده‌های آموزشی برای به دست آوردن رابطه تبدیل استفاده می‌شود در صورتی که از مجموعه داده‌های اعتبارسنجی متقابل برای ارزیابی خطای برآورد در حین آموزش استفاده می‌شود. آموزش زیادی با مجموعه داده‌های آموزشی اغلب باعث تطبیق ضعیف‌تر با مجموعه داده‌های اعتبارسنجی متقابل می‌شود. هنگام آموزش شبکه با استفاده از داده‌های آموزشی، کارایی شبکه به طور متناوب با استفاده از مجموعه داده‌های اعتبارسنجی متقابل بررسی می‌شود. در حین این بررسی وزن‌ها آموزش داده نمی‌شوند ولی کارایی شبکه روی مجموعه اعتبارسنجی متقابل به دست می‌آید و با مقدار قبلی آن مقایسه می‌شود. اگر شبکه شروع به آموزش زیاد روی داده‌های آموزشی کند (به جای یادگیری روند کلی تغییرات در داده‌ها، شبکه مثال‌های آموزشی را حفظ کند)، کارایی آن بر روی داده‌های اعتبارسنجی متقابل رو به کاهش می‌گذارد. بدین ترتیب از مجموعه داده‌های اعتبارسنجی متقابل برای به دست آوردن زمانی که شبکه بدون آموزش زیادی تا حد ممکن آموزش دیده است (یعنی بیشترین تعمیم) می‌توان استفاده کرد. گاهی وقت‌ها اتفاق می‌افتد که شبکه مسئله را به درستی یاد نگیرد. در این موارد منحنی‌های خطا به صفر نزدیک نمی‌شوند. معمولاً سه دلیل برای یک آموزش ناموفق وجود دارد:

۱. شبکه توانایی یادگیری مسئله را دارد ولی به اندازه کافی آموزش ندیده است. در این حالت کافی است تعداد دفعات آموزش را افزایش دهیم.
۲. شبکه، توانایی یادگیری مسئله را دارد ولی در یک مینیمم موضعی گرفتار شده است. در این حالت می‌بایست یا وزن‌ها را تغییر داد و آموزش را ادامه داد و یا وزن‌ها را تصادفی کرد و آموزش را از ابتدا تکرار کرد.
۳. شبکه توانایی کافی برای یادگیری مسئله ندارد. اگر متوجه شدیم که مشکل ناشی از دو مورد بالا نیست، در این حالت می‌بایست با افزایش تعداد عناصر پردازشی

اگر اهمیت هر نمونه کم باشد، مقدار این پارامتر باید کمتر باشد. در مورد مسئله ما، با توجه به وجود نوفه در داده‌های لرزه‌ای و همچنین وجود تغییرات غیرمرتبط با تخلخل در سنگ شناسی سنگ مخزن، نرخ آموزش مناسب حدود ۰/۳ است.

در این تحقیق با توجه به وجود نوفه در داده‌های لرزه‌ای، می‌بایست نرخ آموزش کوچکی انتخاب می‌شد. معمولاً در عمل تعیین مقدار مناسب برای نرخ آموزش در مرحله آموزش صورت می‌گیرد، بدین ترتیب که ابتدا یک مقدار برآورد شده برای این پارامتر در نظر گرفته می‌شود و شبکه چندین بار آموزش داده و منحنی‌های خطای شبکه بررسی می‌شود. در هر مرحله از آموزش شبکه حدود ۱۰۰۰ مرتبه با مجموعه نمونه‌های آموزشی، آموزش داده می‌شود تا وزن‌های بهینه به دست آیند. با توجه به نکات اشاره شده در بالا، شبکه عصبی با مشخصات زیر در حکم شبکه مناسب طراحی و مورد استفاده قرار گرفت.

نوع شبکه عصبی: شبکه احتمالاتی (PNN)

تعداد لایه‌های مخفی: ۱

تعداد واحدهای پردازشی در لایه مخفی: ۴

تابع انتقال (برانگیزش) در لایه مخفی: tanh

نرخ آموزش: ۰/۳

## ۲-۶ آموزش شبکه عصبی

یکی از اهداف اصلی در آموزش شبکه عصبی اطمینان از این است که شبکه برای داده‌هایی که قبلاً با آنها آموزش ندیده است به درستی کار کند که به آن تعمیم (Generalization) می‌گویند. روش استاندارد برای اطمینان از توانایی تعمیم خوب شبکه، تقسیم داده‌های آموزشی به چند مجموعه داده است. عمومی‌ترین مجموعه داده‌ها عبارت‌اند از مجموعه داده‌های آموزشی، اعتبارسنجی متقابل (Cross validation) و آزمایشی. از

را نیز به همین ترتیب به دست می‌آوریم. در روش برازش گام به گام، نمی‌توانیم مطمئن باشیم که جواب به دست آمده بهینه است.

به زبان دیگر ممکن است بهترین نشانگر تکی عضو زیرمجموعه بهینه برای برآورد تخلخل نباشد. با وجود این چنین روشی یک روش کاربردی است زیرا از لحاظ عملیاتی نمی‌توان همه حالت‌های ممکن از نشانگرهای لرزه‌ای را بررسی کرد. برای مثال اگر ۲۰ نشانگر لرزه‌ای داشته باشیم، می‌بایست  $1048575 = 1 - 2^{20}$  حالت گوناگون را بررسی کنیم، حالت  $(1 + 19 + 18 + \dots + 20)$  است.

با عملی ساختن روش برازش گام به گام، چهار نشانگر بسامد غالب، دامنه تجمعی مطلق، بسامد وزن دار دامنه و فیلتر میان گذر ۶۰-۴۵ هرتز تریس لرزه‌ای در حکم بهترین نشانگرها انتخاب شدند. افزایش نشانگرهای دیگر به این مجموعه نه فقط باعث بهبود برآورد شبکه نمی‌شود بلکه باعث ناپایداری در جواب‌ها و همچنین افزایش زمان محاسبه‌ها می‌شود.

در نهایت شبکه عصبی با این نشانگرها آموزش داده شد. شکل ۷ منحنی‌های خطای میانگین مربعی نمونه‌های آموزشی و اعتبارسنجی متقابل را نشان می‌دهد. پس از آموزش شبکه، از این شبکه برای برآورد کردن داده‌های آزمایشی (که در آموزش شبکه شرکت نکرده بودند) استفاده شد و داده‌های برآورد شده با داده‌های واقعی مقایسه شدند (شکل ۸). همان‌طور که قبلاً نیز اشاره شد، به دلیل کم بودن تعداد نمونه‌ها و همچنین وجود یک چاه در هر رخساره، امکان کنار گذاشتن همه نمونه‌های یک چاه به منزله نمونه‌های آزمایشی میسر نبود. به همین دلیل نمونه‌های آزمایشی به صورت تصادفی از بین داده‌های همه چاه‌ها انتخاب شدند. نتایج به دست آمده حاکی از همبستگی خوب بین داده‌های واقعی و داده‌های برآورد شده به میزان ۹۲٪ ( $R^2 = 0.85$ ) است که بیانگر

قدرت محاسباتی شبکه را افزایش دهیم.

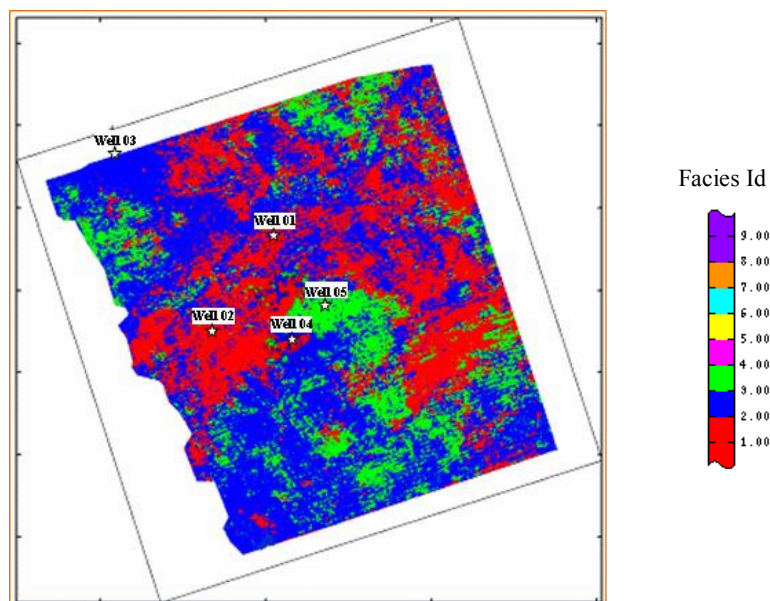
برای رسیدن به یک تعمیم جامع، نمونه‌های آموزشی می‌بایست نماینده همه جامعه مورد بررسی باشند. تحلیل رخساره‌های لرزه‌ای صورت گرفته در تحقیقات قبلی معزن مورد بررسی (شکل ۶) نشان می‌دهد که داده‌های لرزه‌ای را می‌توان به سه رخساره لرزه‌ای تقسیم کرد که در هر رخساره حداقل یک چاه موجود است. بنابراین می‌توان از جامعیت نمونه‌های لرزه‌ای اطمینان داشت.

داده‌های آموزشی در این تحقیق شامل ۵۷ نمونه آموزشی از نگاره‌های تخلخل موثر چاه‌های موجود در منطقه است. این نمونه‌ها به سه بخش آموزشی (۴۱ نمونه)، اعتبارسنجی متقابل (پنج نمونه) و آزمایشی (۱۱ نمونه) تقسیم شدند. در هر نمونه مقادیر نشانگرهای لرزه‌ای ورودی‌های شبکه و مقادیر تخلخل موثر، خروجی مطلوب هستند. همان‌طور که در شکل ۶ دیده می‌شود، در رخساره‌های سبز و آبی فقط یک چاه وجود دارد. با توجه به این مطلب و همچنین تعداد کم نمونه‌ها امکان کنار گذاشتن همه داده‌های یک چاه در حکم داده‌های آزمایشی وجود ندارد. به همین دلیل نمونه‌های آزمایشی به صورت تصادفی از همه چاه‌ها انتخاب شدند.


در مرحله پردازش داده‌ها با توجه به تعداد زیاد نشانگرهای تولید شده، به منظور حذف مولفه‌های ورودی غیرضروری، بهترین نشانگرها برای آموزش شبکه با استفاده از روش برازش گام به گام صورت گرفت (دراپر و اسمیت، ۱۹۶۶). در این روش فرض بر این است که اگر بهترین ترکیب از M نشانگر شناخته شده باشند، بهترین ترکیب از M + 1 نشانگر شامل M نشانگر قبلی خواهد بود. در این روش ابتدا بهترین نشانگر برای برآورد کردن تخلخل را با بررسی همه نشانگرها پیدا می‌کنیم به نحوی که این نشانگر دارای کمترین خطای برآورد باشد. در مرحله بعد بهترین جفت نشانگری را پیدا می‌کنیم که شامل نشانگر قبلی باشد. سپس نشانگر سوم و چهارم و ...

همبستگی بین این داده‌ها برابر ۹۵٪ ( $R^2 = 0.9$ ) است. همان گونه که در شکل ۹ دیده می‌شود، نگاره‌های برآورد شده به خوبی از روند تغییرات نگاره‌های اصلی پیروی می‌کنند. تنها نبود تطابق، مربوط به چاه شماره ۴ است. این چاه در محدوده با فولد کم (Undershooting) قرار گرفته است که تریس‌های مقطع لرزه‌ای در این محدوده کیفیت نازلی دارند. با وجود این در این چاه نیز روند کلی تغییرات به درستی برآورد زده شده است.


توانایی زیاد شبکه عصبی PNN در برآورد داده‌های تخلخل است. پس از اطمینان از کارایی شبکه، این شبکه با استفاده از همه نمونه‌ها آموزش داده شد و سپس از آن برای برآورد کردن نگاره‌های تخلخل موثر در محل چاه‌ها استفاده شد. شکل ۹ نگاره‌های تخلخل موثر واقعی (منحنی‌های سبز) و نگاره‌های تخمینی (منحنی‌های سرخ) چاه‌ها را نشان می‌دهد و جدول ۱ مقادیر واقعی و برآورد شده تخلخل موثر را در این چاه‌ها نشان می‌دهد.



شکل ۶. نقشه رخساره‌های لرزه‌ای مخزن مورد بررسی شامل سه رخساره لرزه‌ای.



شکل ۷. منحنی خطای آزمایشی (سیاه) و خطای اعتبارسنجی متقابل (سرخ). محور قائم خطای میانگین مربعی و محور افقی تعداد دفعات ارائه نمونه‌های آموزشی به شبکه در مرحله آموزش را نشان می‌دهد.



شکل ۸. (چپ) رسم متقابل داده‌های تخلخل مؤثر واقعی و برآوردشده؛ (راست) رسم منحنی‌های تخلخل مؤثر واقعی (سورمه‌ای) و تخلخل مؤثر برآوردشده (سرخ). نمونه‌ها بصورت تصادفی از همه چاهها انتخاب شده‌اند.


۷ نتایج  
در این تحقیق یک شبکه عصبی احتمالاتی طراحی شد. این شبکه با نشانگرهای لرزه‌ای مستخرج از تریس‌های لرزه‌ای در محل چاه‌ها (در محدوده مخزن میشریف) و همچنین نگاره‌های تخلخل مؤثر متناظر این چاه‌ها آموزش داده شد. در این تحقیق انتخاب بهترین نشانگرهای لرزه‌ای به منظور آموزش شبکه به روش برازش گام به گام پیشرو صورت گرفت. از شبکه آموزش دیده در برآورد کردن

نگاره تخلخل مؤثر استفاده شد. تحلیل رخساره‌های لرزه‌ای صورت گرفته در تحقیقات پیشین بیانگر این مطلب است که نمونه‌های موجود جامعیت لازم را برای آموزش شبکه دارند. این تحقیق روشن ساخت که از شبکه‌های عصبی احتمالاتی حتی در زمان‌هایی که تعداد نمونه‌های آموزشی کم است، به خوبی می‌توان در برآورد کردن نگاره‌های تخلخل استفاده کرد.

جدول ۱. مقادیر واقعی و برآوردشده تخلخل مؤثر در محل چاه‌ها.

Time (ms)	Well-01		Well-02		Well-03		Well-04		Well-05	
	Real	Predicted	Real	Predicted	Real	Predicted	Real	Predicted	Real	Predicted
772			28.4	28.5						
776	27.8	26.5	26.4	28.3	15.7	17.7				
780	26.0	26.5	28.1	27.8	16.9	16.4				
784	26.3	26.5	27.1	26.7	18.0	15.9	16.1	15.8		
788	26.1	26.4	26.2	25.9	15.0	15.8	14.5	15.1		
792	26.8	26.4	24.9	23.7	17.4	14.8	13.7	18.2	20.8	18.6
796	25.3	26.2	23.4	21.3	13.5	13.9	18.6	18.6	16.9	18.5
800	25.9	26.0	21.4	21.3	9.5	14.1	20.1	18.6	14.8	15.0
804	25.2	25.1	19.0	20.1	15.2	16.3	19.5	18.5	16.8	16.6
808	23.6	23.6	17.5	19.1	22.3	21.5	19.1	18.1	18.5	18.6
812	22.3	21.9	16.6	18.0	19.9	23.6			19.1	18.6
816	18.0	18.0	16.2	16.4	23.4	23.1			17.3	18.8
820	14.3	14.6	15.0	14.7	24.4	22.1				
824	13.1	13.0	14.8	13.2	20.0	19.1				
828	12.6	12.4			17.1	16.9				
832					17.3	15.4				





شکل ۹. منحنی تخلخل مؤثر در چاه‌ها (منحنی‌های سبز) و تخلخل مؤثر برآوردشده با شبکه عصبی (منحنی‌های سرخ).

Chopra, S., and Marfurt, K. J., 2005, Seismic attributes - A historical perspective: *Geophysics*, **70**, 3S0–28S0,  
 de Figueiredo, R. J. P., 1982, Pattern recognition approach to exploration in R. J. P. de Figueiredo, ed., *Concepts and techniques in oil and gas exploration*: SEG, 267–286.  
 Dorrington, K. P., and Linkz, C. A., 2004, Genetic-algorithm/neural-network approach to seismic attribute selection for well-log prediction: *Geophysics*, **69**, 212–221.  
 Draper, N. R., and Smith, H., 1966, *Applied regression analysis*: John Wiley & Sons, Inc.  
 Hampson, D. P., Schuelke, J. S., and Quirein, J. A., 2001, Use of multiattribute transforms to predict log properties from seismic data: *Geophysics*, **66**, 220–236.  
 James, G. A. and Wynd, J. G., 1965, Stratigraphic nomenclature of Iranian oil consortium agreement area: *Am. Assoc. Petrol. Geol. Bull.*, **49**, 2182–2245.

### تشکر و قدردانی

از مدیریت محترم شرکت ملی نفت فلات قاره به‌خاطر دراختیار قراردادن داده‌های مورد نیاز این تحقیق کمال تشکر را داریم. همچنین از مدیریت محترم شرکت مهندسی توسعه نفت (متن) و شرکت مشاوران انرژی تهران به‌خاطر مساعدت در به انجام رساندن این تحقیق کمال تشکر را داریم.

### منابع

Alsharhan, A. S., and Nairn, A. E. M., 1997, *Sedimentary basins and petroleum geology of the Middle East*: Elsevier B. V.  
 Chen, Q., and Sidney, S., 1997, Seismic attribute technology for reservoir forecasting and monitoring: *The Leading Edge*, **16**, 445–456.

- Pramanik, A. G., Singh, V., Vig, R., Srivastava, A. K., and Tiwary, D. N., 2004, Estimation of effective porosity using geostatistics and multiattribute transforms: A case study, *Geophysics*, **69**, 352–372.
- Setudehnia, A., 1972, Iran du Sud-Ouest: Lexique Strat. Internat., Centre Nat. Rech. Scientifique. Paris, III Asie, Fasc. **9b**, 289-376.
- Schultz, P. S., Ronen, S., Hattori, M., and Corbett, C., 1994, Seismic guided estimation of log properties: parts a, and b. *The Leading Edge*, **13**, 305–310, 674–678.
- Specht, D., 1990, Probabilistic neural networks: *Neural Networks*, **3**, 109–118.
- Specht, D., 1991, A general regression neural network: *IEEETrans. Neural Networks*, **2**, 568–576.
- Taner, M. T., Koehler, F., and Sheriff, R. E., 1979, Complex seismic trace analysis: *Geophysics*, **44**, 1041–1063.
- Krose, B., and van der Smagt, P., 1996, An introduction to Neural Networks: University of Amsterdam.
- Leiphart, D. J., and Hart, B. S., 2001, Comparison of linear regression and a probabilistic neural network to predict porosity from 3D seismic attributes in Lower Brushy Canyon channeled sandstones, southeast New Mexico: *Geophysics*, **66**, 1349–1358.
- Masters, T., 1994, Signal and image processing with neural networks: John Wiley & Sons, Inc.
- Masters, T., 1995, Advanced algorithms for neural networks: John Wiley & Sons, Inc.
- Parker, D. B., 1985, Learning-Logic: Technical Report TR-47, Cambridge, MA. Massachusetts Institute of Technology, Center for Computational Research in Economics and Management Science.