

## طبقه‌بندی رخساره‌های سنگی با استفاده از چاهنگاری و بررسی تاثیر نگار صوتی بر آن به کمک شبکه عصبی مصنوعی در یکی از مخازن هیدروکربوری

محمدامین دزفولیان<sup>۱</sup>، مجید نبی‌بیدهندی<sup>۲\*</sup> و یوسف بیرقدار<sup>۳</sup>

<sup>۱</sup>دانشجوی دکتری مهندسی معدن، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران، ایران

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

<sup>۳</sup>دانش آموخته کارشناسی ارشد، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

dezfoolian@rocketmail.com, mnbhendi@ut.ac.ir, beiraghdar301@gmail.com

(تاریخ دریافت: ۱۳۸۷/۹/۲۰، تاریخ پذیرش: ۱۳۸۹/۳/۲۶)

### چکیده

یک مخزن هیدروکربوری، از سنگ‌های رسوبی لایه‌ای تشکیل شده است که در طی یک دوران طولانی رسوب‌گذاری شده و با گذشت میلیون‌ها سال تحولات دیاژنزی، دچار تغییرات ساختاری شده‌اند. این فرایندها، با تغییرات دائمی خواص فیزیکی مخزن در طول دوران‌های زمین‌شناسی همراه هستند. شناخت رخساره یکی از مهم‌ترین این خواص است که به مهندسان نفت توانایی طراحی و مدیریت مؤثر برای شناخت دقیق تر و توسعه میدان‌های نفت و گاز را می‌دهد. این مقاله، به طبقه‌بندی رخساره‌های سنگی (Lithofacies) سنگ مخزن هیدروکربوری با به کارگیری فن شبکه عصبی مصنوعی با الگوریتم پس انتشار خطاطا (BP) و الگوریتم آموزش لونبرگ-مارکوارت از روی داده‌های نگاره‌ای پرتوگاما، چگالی، نوترون، صوتی و اثر فتوالکتریک (PEF) می‌پردازد. همچنین، میزان تاثیر نگار صوتی در برآورد رخساره‌ها نیز در اینجا ارزیابی شده است. با توجه به اینکه تعیین رخساره سنگ مخزن با آزمایش‌های مغزه پرهزینه است با به کارگیری روش می‌توان هزینه‌های مربوط به شناسایی رخساره را از راه کاهش نیاز به عملیات مغزه‌گیری، تقلیل داد.

داده‌های مربوط به چهار چاه در یکی از مخازن هیدروکربوری مورد استفاده قرار گرفت، به این صورت که شبکه، ابتدا در یکی از چاه‌های مخزن که دارای آنالیز مغزه بود، آموزش داده شد و در چاه دیگری که داده‌های آن در آموزش شبکه سهمی نداشت، آزمایش شد و پس از حصول اطمینان از کارآیی آن، از شبکه به منظور برآورد رخساره‌ها در ۲ چاه دیگر (چاه A1 و A2) استفاده شد. مقدار MSE این روش در صورتی که فقط از نگاره‌ای پرتوگاما، چگالی، نوترون و اثر فتوالکتریک استفاده شود، برای چاه A1، ۰.۰۶۸ و برای چاه A2، ۰.۰۷۴ و در صورتی که از نگار صوتی نیز به همراه نگاره‌ای پرتوگاما، چگالی، نوترون و اثر فتوالکتریک استفاده شود مقدار MSE به ۰.۰۵۲ برای چاه A1 و ۰.۰۶۰ برای چاه A2 می‌رسد، که نشان از بهتر شدن برآورد دارد.

**واژه‌های کلیدی:** رخساره سنگی، هوش مصنوعی، شبکه عصبی پس انتشار خطاطا، مغزه، میدان نفتی

### Lithofacies classification using logging and sonic log effects assessment by taking the advantage of artificial neural network in a hydrocarbon reservoir

Mohammad Amin Dezfoolian<sup>1</sup>, Majid Nabi-Bidhendi<sup>2\*</sup>, and Yousef Beiraghdar<sup>2</sup>

<sup>1</sup>Department of Mining Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

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

(Received: 10 December 2008, accepted: 16 June 2010)

\*Corresponding author:

mnbhendi@ut.ac.ir

\*نگارنده رابطه:

## Summary

The classification of lithofacies and their accurate representation in a 3D cellular geologic model is critical to understanding the field characteristics because permeability and fluid saturations for a given porosity and elevation above free water vary considerably among lithofacies. The best source of lithofacies information is the reservoir rock core samples from wells; however, cores are not commonly taken due to excessive expense. Since the availability of core samples is limited compared to the number of wells in the field, developing a method for estimating lithofacies in wells without cores is necessary. In this study, core lithofacies are extrapolated from cored wells (training wells) to uncored wells through the comparison of physical rock properties measured by wire-line logs. Associating well log data with lithofacies can be difficult due to the heterogeneous nature of rocks, especially carbonate rocks. Lithofacies can be defined using any set of rock properties; however, only lithofacies defined by variations in properties that affect well log response can be identified using well log data. Moreover, some useful rock properties, such as porosity and permeability, affect well log response. Artificial Neural Networks (ANNs) are computational models inspired by brain structure mechanisms and functions. The system employs a set of nonlinear and linear activation functions that do not require a priori selection of a mathematical model. Recent applications of ANN to geological studies have demonstrated its effectiveness in prediction, estimation and characterization. Neural networks have been developed and utilized for the solution of a variety of pattern recognition, classification, and signal identification and prediction problems. Neural networks utilized for the prediction of parameters and pattern classification are trained based on data-sets that contain a number of training patterns. Each training pattern is presented as a pair of two components: the input data and the respective classification outcome. After the neural network is trained, it may be applied to a new data-set which contains only the values of input parameters. The goal of this study is to establish a method for lithofacies classification utilizing well data and taking advantage of artificial neural network. Additionally, sonic log efficiency in improving of prediction of reservoir lithofacies is discussed.

In this paper, the main goal is the classification of hydrocarbon reservoir lithofacies, applying an artificial neural network technique, specially back propagation (BP) and Levenberg- Marquardt training algorithms, on gamma-ray , density, neutron, sonic, and photo electric effect (PEF) logs. Moreover, in this research, the efficiency of sonic log data in lithofacies estimation has been investigated. Paying attention to the fact that lithofacies determination from core experiments can be costly, in this approach, lithofacies identification expenses are reduced by eliminating the need to perform a coring operation.

Data from four wellbores in a hydrocarbon reservoir was used. The network was trained primarily on one of the wells in which the core analysis was available and was subsequently tested in another well that did not play any role in the training phase. After achieving efficiency reliability, the network was applied in lithofacies estimation in two other wells (A1 and A2). The amount of MSE (mean squares error) in this method using only gamma-ray, density, neutron and photoelectric effect logs was 0.068 and 0.074 for wells A1 for A2, respectively.

In the case of using a sonic log in addition to previous inputs, the MSE decreases to 0.052 for well A1 and 0.060 for well A2, which implies an estimation improvement.

**Key words:** Lithofacies, artificial intelligence, neural network back propagation, core, oil field

بود. از دیگر کاربردهای شبکه عصبی و منطق فازی می‌توان به آنالیز چاههای تولیدی و انتخاب شرایط مناسب حفاری زیر تعادلی (Under Balanced Drilling; UBD) اشاره کرد (الیمونتی و همکاران، ۲۰۰۴؛ گروچ و لبایدی، ۲۰۰۳).

با آنکه به طور معمول از آنالیز مغزه برای به دست آوردن رخساره یک سازند استفاده می‌شود، لکن برداشت داده‌هایی از این نوع به علت هزینه‌های زیاد، اغلب در تعداد محدودی از چاههای یک میدان صورت می‌گیرد (دابوسیا، ۲۰۰۷). به همین دلیل در پژوهه‌های مهندسی نفت، اغلب کمبود داده‌های ضروری، مثل مغزه‌ها به علت هزینه‌های زیاد، احساس می‌شود. اما تقریباً از همه چاههای یک میدان هیدروکربوری، در حین حفاری یا بعد از آن، نگاربرداری صورت می‌گیرد و اطلاعات زیادی از نگارهای گوناگون چاه در اختیار مهندسان و محققان قرار می‌گیرد (بورسارو و همکاران، ۲۰۰۶).

نگارهای چاه‌پیمایی معمولاً نمایی بهتری از وضعیت بر جای یک واحد چینه‌ای نسبت به آنالیزهای آزمایشگاهی دارند، چراکه آن‌ها از حجم بزرگ‌تری از سنگ‌های اطراف چاه نمونه برداری می‌کنند و ثبت پیوست‌های عرضه می‌کنند (چنگ و همکاران، ۲۰۰۲). بنابراین امروزه با استفاده از روش‌هایی که قادر به برآورد مشخصات سنگ مخزن از روی نگارهای چاه‌پیمایی باشند، می‌توان طرح توسعه یک میدان نفتی را تا میزان زیادی بهبود داد و از هزینه‌ها کاست (امینیان و آمری، ۲۰۰۵).

هدف از این تحقیق طبقه‌بندی رخسارهای سنگی Wackestone، Packstone، Grainstone، Boundstone و Mudstone با استفاده از داده‌های حاصل از چاه به کمک شبکه عصبی مصنوعی است. همچنین تاثیر نگار صوتی در جهت بهبود برآورد رخسارهای سنگ مخزن مورد بحث قرار می‌گیرد.

## ۱ مقدمه

با توجه به هزینه‌های سنگین حفاری و نیز نیاز روزافرون به منابع انرژی از جمله نفت و گاز، حفر چاه فقط به منظور اجرای عملیات اکتشافی (که قاعدتاً باید در محدوده‌ای کوچک‌تر و با حفر تعداد بیشتری چاه صورت گیرد) خیلی مقرر به صرفه به نظر نمی‌رسد. لذا در سال‌های اخیر سعی بر آن بوده که با استفاده از روش‌های غیر مستقیم بتوان به خصوصیات مخزنی در میدان‌های نفتی پی برد. روش‌های متعددی برای این منظور به کار گرفته شده که مهم‌ترین آن‌ها منطق فازی و شبکه عصبی مصنوعی است. اونز شبکه عصبی و منطق فازی را برای تعیین خواص مخزن ترک‌دار به کار برد و به مقایسه این دو و ارزیابی دقیق آن‌ها در تعیین خواص مخزنی پرداخت (اونز، ۲۰۰۰). ملاه و نشاوی (۲۰۰۵) از شبکه عصبی به منظور برآورد گرادیان شکاف مربوط به یک میدان نفتی، استفاده کردند. شیوی و همکاران (۲۰۰۸) شبکه عصبی را برای برآورد ضخامت مخزن نفتی مورد استفاده قرار دادند آن‌ها از شبکه پس انتشار خطاب را برای این برآورد بهره جستند. از سامانه‌های هوشمند در پیش‌بینی سرعت امواج برشی با استفاده از داده‌های پتروفیزیکی در یک مخزن ماسه‌سنگی در منطقه کارنارون استفاده کردند آن‌ها به منظور آموزش دادن شبکه، از نگارهای پرتو گاما، مقاومت، چگالی و نوترن استفاده کردند. الگوریتم مورد استفاده آنان نیز پس انتشار خطاب بود (رضایی و همکاران، ۲۰۰۷). طاهری منطق فازی را برای طراحی مدل اکتشافی در مورد داده‌های دورسنجی در اکتشاف نفت به کار برد (طاهری، ۲۰۰۶). هله و همکاران (۲۰۰۱) به منظور پیش‌بینی تخلخل و تراوایی مخزن با استفاده از چاه‌نگاری از شبکه عصبی مصنوعی بهره جستند. آن‌ها برای پیش‌بینی تخلخل نگارهای صوتی، چگالی و مقاومت و برای پیش‌بینی تراوایی نگارهای صوتی، چگالی و پرتو گاما را به کار برندند شبکه طراحی شده آنان نیز پس انتشار خطاب

## ۲ شبکه‌های عصبی مصنوعی

یکی از الهام‌هایی که در مورد شبکه‌های عصبی از مغز انسان گرفته شده این است که مغز برای محاسبات خود از ساختاری کاملاً مغایر با ساختار زیانه‌ها استفاده می‌کند؛ بدین معنی که مغز از مجموعه‌های از عناصر اصلی به نام نرون(neuron) تشکیل یافته است که عملکرد این نرون‌ها و پاسخ آن‌ها به صورت جمعی، بستگی به ذخیره‌سازی و حفظ اطلاعات در تک‌تک نرون‌ها و نحوه ارتباط بین آن‌ها دارد (منهاج، ۱۳۸۴).

در نرم افزارهایی که در آن‌ها از شبکه‌های عصبی استفاده شده است، نرون‌های شبکه را المان پردازنده (processing element) در نظر می‌گیرند (غضنفری، ۱۳۸۳). در یک مدل شبکه عصبی، ورودی‌ها در نخستین گام، در ضریب وزنی (weighting factor) متضایر خود ضرب می‌شوند. در مرحله بعد، ورودی‌هایی که تغییر مقیاس داده‌اند وارد واحدی می‌شوند که در آن سیگنال‌های ورودی با هم ترکیب می‌شوند. به طور معمول عمل ترکیب در این واحد، ورودی را به روش دیگری علاوه بر عمل جمع معمولی نیز با یکدیگر ترکیب کرد. مثلاً می‌توان به جای عمل جمع از عمل متوسط گیری، انتخاب بزرگ‌ترین، انتخاب کوچک‌ترین، عمل "OR" با "AND" منطقی هم استفاده کرد (مهری‌زاده، ۱۳۸۳).

پس از آنکه ورودی‌ها با یکدیگر ترکیب شدند، سیگنال حاصل به واحد دیگری که در آن تابع انتقال (Transfer function) به سیگنال اعمال می‌شود، هدایت می‌شود که خروجی این بخش، سیگنال‌های حقیقی خواهد بود (منهاج، ۱۳۸۴).

## ۳ قانون الگوریتم پس انتشار خطای BP

### (Back Propagation)

از قانون پس انتشار خطای BP (Back Propagation) برای آموزش شبکه‌های عصبی چندلایه پیش‌خور (feed Multilayer Perceptron forward) که عموماً شبکه‌های MLP) هم نامیده می‌شوند استفاده می‌کنند. قانون پس انتشار خطای BP از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت موسوم است که در این مسیر، بردار ورودی به شبکه اعمال می‌شود و تاثیراتش از راه لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شوند. مسیر دوم به مسیر برگشت موسوم است. در این مسیر، بر عکس مسیر رفت، پارامترهای شبکه تغییر می‌یابند و تنظیم می‌شوند. این تنظیم مطابق با قانون اصلاح خطای صورت می‌گیرد و سیگنال خطای BP، در لایه خروجی شبکه تشکیل می‌شود.

به منظور توقف تکرار الگوریتم BP از شاخص میانگین مربعات خطای BP (mean squares error) MSE استفاده شده است؛ به این صورت که اگر میانگین مربعات خطای در هر سیکل، کمتر از مقدار از پیش تعیین شده‌ای باشد و یا اینکه تغییرات در پارامترهای شبکه پس از هر سیکل، خیلی کوچک باشد، تکرار الگوریتم متوقف می‌شود. یعنی در صورتی که با افزایش سیکل، تغییرات بسیار کمی در شبکه ایجاد شود، تکرار متوقف می‌شود چرا که از اینجا به بعد دیگر تغییرات محسوسی در شبکه ایجاد نخواهد شد. برای متوقف ساختن تکرار الگوریتم می‌توان SSE; از شاخص‌های دیگری چون مجموع مربعات خطای (MAE; sum squared error) و یا میانگین خطای مطلق (mean absolute error) نیز بهره جست اما MSE نسبت به

اینکه در حین عملیات نگاربرداری از چاه، کابل به علت طول زیاد و در نتیجه وزن زیاد آن ممکن کشیده شده باشد، لذا باید این تصحیح در مورد عمق نگار صورت گیرد و نگار و داده‌های مغزه نسبت به عمق برداشت شده، منطبق شوند. این کار با تطبیق مغزه و خرده‌های حفاری گرفته شده و نگار برداشت شده در قسنت‌های گوناگون چاه صورت می‌گیرد تا مشخص شود که مغزه و خرده‌های حفاری، منطبق با عمقی است که از آن نگاربرداری صورت می‌گیرد. در مرحله آماده سازی داده‌ها، ابتدا می‌بایست داده‌های Null (مقادیر ۲۵/۹۹۹) در داده‌های رقومی نمودارهای چاه‌پیمایی) و Bad Hole (فواصلی که تفاوت مقادیر نمودار کالپیر (caliper) و Flag قطر سرمه در آن‌ها بیشتر از ۱/۵ اینچ است، که این فواصل نشان‌دهنده نواحی ریزشی در دیواره چاه‌اند) حذف شود. سپس به منظور پردازش داده‌ها، ابتدا عمل تطابق عمق بین نمودارها (Depth Shifting) و همچنین (Depth Matching) تطابق عمق بین نمودارها و مغزه (Matching) صورت گیرد و در ادامه با یافتن عمق‌های متناظر مغزه از روی داده‌های نمودار و قرار دادن آن‌ها در مقابل مقادیر مغزه، عمل پردازش داده‌ها صورت گیرد.

در صورتی که در گزارش‌های مربوط به مغزه، قید شده باشد که شرایط گرفن مغزه ناستاندارد بوده است و تغییرات ثانوی‌های حین عملیات مغزه گیری و انتقال ایجاد شده است (مثلاً شکستگی مغزه حین عملیات)، داده‌ی مربوطه کنار گذاشته می‌شود (نیکروش و امین‌زاده، ۲۰۰۱؛ محقق و همکاران، ۲۰۰۴). ممکن است به دلایلی مثل ریزش دیواره چاه، در قسمت‌هایی از چاه، یکی یا تعدادی از نگارها را نداشته باشیم که این داده‌ها نیز حذف می‌شوند (نیکروش، ۲۰۰۴).

برای هر کدام از رخساره‌های مورد بحث که از مغزه به دست آمده، یک کد در نظر گرفته و هر رخساره با یک عدد نشان داده می‌شود. این اعداد در حین آموزش به منزله

سایر شاخص‌ها حساس‌تر است و کوچک‌ترین تغییری در خط رانیز با وضوح بیشتری مشخص می‌کند.

#### ۴ زمین‌شناسی منطقه

داده‌های مورد استفاده در این مقاله، متعلق به چاه‌های حفاری شده در سازندهای کربناته کنگان و دلان مربوط به یکی از مخازن هیدرولکربوری جنوب ایران است. این سازندها با سن تریاپس-پرمین در بخش‌های وسیعی از خلیج فارس به صورت سازندهای مخزنی شناخته شده‌اند. سازند دلان شامل دولومیت‌های دلان‌پایینی، واحد ایندریتی نار، شیل‌های سبز تا سبز خاکستری، آهک‌های دولومیتی تا دولومیت‌های دلان‌بالایی است. در این بین، دلان‌بالایی دارای خصوصیات مخزنی است. سازند کنگان با سن تریاپس زیرین در مقاطع تحت‌الارضی به دو واحد در پایین و بالا تقسیم‌بندی می‌شود. واحد پایینی این سازند، با توجه به گسترش رخساره‌های اوولیتی و تخلخل قالبی دارای خواص مخزنی (تخلخل و تراوایی) خوبی است. اما واحد بالایی که دارای ضخامت بیشتری است، معمولاً خواص مخزنی خوبی ندارد.

#### ۵ جمع‌آوری و آماده‌سازی داده‌ها برای آموزش شبکه

داده‌های نگارهای پرتو گاما، چگالی، نوترون، صوتی و اثر فتوالکتریک به همراه آنالیز و توصیف مغزه (core description) مربوط به سازند مخزنی تهیه شد. بدون شک یکی از مهم‌ترین بخش‌های مربوط به ایجاد و توسعه شبکه‌های عصبی، انتخاب داده‌ها است. نخستین مسئله بررسی صحت داده‌های انتخاب شده براساس گزارش‌ها است. قبل از هر عملی باید دقت شود که نگارهای موجود، کاملاً واسنجی (کالیبره) و نسبت به محیط، تصحیح شده باشند و هم نگار و هم داده‌های مغزه به طور صحیح نسبت به عمق، منطبق شده باشند. با توجه به

رخساره‌های سنگی با استفاده از چاهنگاری و بررسی تاثیر نگار صوتی بر آن به کمک شبکه عصبی مصنوعی در یکی از مخازن هیدروکربوئدی می‌شود. مشاهده می‌شود که از یک مرحله به بعد، خطای داده‌های اعتبارسنجی ابتدا کاهش می‌یابد و پس از مدتی رو به افزایش می‌گذارد. این بدان معنا است که شبکه قدرت تعیین خود را رفته‌رفته از دست می‌دهد و در واقع بدون آنکه قادر به دریافت ارتباط صحیح بین داده‌های ورودی و خروجی باشد، به حفظ کردن داده‌های آموزشی می‌پردازد. لذا بعد از آنکه شبکه بعد از چند نوبت متوالی، خطای اعتبارسنجی بیشتری تولید کرد، فرایند آموزش می‌بایست متوقف شود و وزن‌های مرتبط با کمترین خطای اعتبارسنجی، به منزله بهترین نتیجه مربوط به آموزش در نظر گرفته شود. در صورتی که میزان خطاهای مطلوب نباشد، باید دور جدیدی از آموزش آغاز شود. پس از آنکه خطای مربوط به داده‌های آموزشی و داده‌های اعتبارسنجی به میزان مطلوب رسید، از داده‌های آزمون که هیچ‌گونه استفاده‌ای تا این مرحله از کار نداشته‌اند، برای سنجیدن نهایی قابلیت تعیین شبکه استفاده می‌شود. این دسته از داده‌ها به شبکه آموزش دیده (که ضرایب وزن مطلوب آن تعیین شده است) وارد می‌شوند و خروجی آن‌ها محاسبه و با مقادیر اصلی مقایسه می‌شود. در صورتی که خطای حاصل (خطای داده‌های آزمون) میزان مطلوبی داشته باشد، کار به اتمام رسیده است. حال می‌توان شبکه آموزش دیده را برای پیش‌بینی رخساره در چاههایی که در آنها مغزه گیری صورت نگرفته است و یا قسمت‌هایی از چاه که بنا به هر دلیلی فاقد مغزه است به کار برد.

هر یک از الگوهای ورودی به شبکه به صورت زوج الگوی ورودی-خرجی‌اند. به عبارت دیگر، خوانش‌های مربوط به نگارهای پرتو گاما، نوترون، چگالی، صوتی و اثر فتوکتریک به منزله داده‌های ورودی خام و رخساره‌های به دست آمده از مغزه‌ها که به صورت کد در نظر گرفته شده‌اند، در حکم خروجی مطلوب، به طور هم‌زمان وارد شبکه می‌شوند.

خروجی مطلوب به شبکه داده می‌شوند (سیر پیتا یانون، ۲۰۰۱).

#### ۶ توسعه شبکه

در اینجا آموزش شبکه به صورت با ناظر (supervised training) است. در آموزش با ناظر مجموعه‌ای از بردار در حکم ورودی به همراه مقدار یا مقادیر خروجی مطلوب در اختیار شبکه گذاشته می‌شود تا با یک الگوریتم آموزش، مقدار ضرایب وزن تنظیم شود (غضنفری، ۱۳۸۳).

شبکه می‌بایست هم در پیش‌بینی مقادیری که در آموزش به کار برده شده است و هم در پیش‌بینی مقادیری که در آموزش از آن استفاده نشده است، موفق عمل کند. لذا داده‌ها به سه دسته تقسیم می‌شوند: داده‌های آموزش (validation data)، داده‌های اعتبارسنجی (training data) و داده‌های آزمون (testing data).

از داده‌های آموزش برای تعیین وزن‌ها استفاده می‌شود. داده‌های اعتبارسنجی اگرچه در حین آموزش مورد استفاده قرار می‌گیرند، اما در تعیین وزن‌ها نقش مستقیمی ندارند. وظیفه داده‌های اعتبارسنجی این است که بر قابلیت تعیین (Generalization) شبکه به موازات آموزش شبکه، نظرات داشته باشد (مهدی‌زاده، ۱۳۸۳). بعد از آنکه همه داده‌های آموزش یک دور کامل به شبکه معرفی شد، با استفاده از وزن‌های حاصل، داده‌های اعتبارسنجی وارد شبکه می‌شود و (مقادیر) کدهای مربوط به رخساره‌ها محاسبه می‌شوند. مقادیر رخساره‌های محاسبه شده با شبکه، هم برای داده‌های آموزش و هم برای داده‌های اعتبارسنجی با مقادیر اصلی (کد رخساره‌های واقعی حاصل از مغزه) مقایسه، و مقدار خطای داده‌های آموزش و اعتبارسنجی محاسبه می‌شوند. این خطاهای (خطای داده‌های آموزش و اعتبارسنجی) بعد از هر دور کامل معرفی داده‌های آموزش به شبکه مجدداً محاسبه

در صورتی که تعداد نرون‌های لایه میانی بسیار کم باشد، خطای داده‌های آموزش و آزمون بالا است. با افزایش تعداد نرون‌ها، خطای آموزش و آزمون روند روبه کاهش را نشان می‌دهند اما از مرحله‌ای به بعد، خطای آموزش کاهش می‌یابد اما خطای آزمون روند روبه افزایشی را نشان می‌دهد و مشخص می‌شود که شبکه در حال ازبرکردن داده‌های است. این نقطه، مینیمم خطای آزمون را نشان می‌دهد و تعداد بهینه نرون‌های لایه‌های میانی به دست می‌آید.

لایه خروجی دارای یک نرون است که نوع رخساره تشکیل دهنده سنگ مخزن را بیان می‌کند.

۷ طبقه‌بندی رخساره‌ها با استفاده از شبکه فرایند یادگیری به این شکل صورت می‌گیرد که ابتدا حدس اولیه‌ای برای اوزان و مقادیر بایاس شبکه زده می‌شود. سپس با استفاده از قانون یادگیری پس انتشار خطای این مقادیر تصحیح می‌شود و آنقدر این دفعات تکرار ادامه می‌یابند که اوزان و بایاس‌ها ثابت شوند و یا تفاوت آن‌ها در دفعات به حداقل برسد.

تابع عملکرد انتخاب شده برای داده‌های آموزشی، (mean squares error) MSE است. برای آموزش شبکه از الگوریتم لونبرگ- مارکوآرت یا (Levenberg- LM) (Trainlm Marquardt) با تابع Trainlm استفاده شده است زیرا خطای الگوریتم LM با سرعت بیشتری نسبت به سایر الگوریتم‌ها کاهش می‌یابد.

در این مقاله رخساره‌های دو چاه A1 و A2 مخزن مورد بررسی در یک محدوده ۱۰۰ متری از عمق هر چاه برآورد شده است، به این صورت که شبکه، ابتدا در یک چاه دیگر مخزن (چاه B1) که دارای آنالیز مغزه بود، آموزش دید و سپس در چاه دیگری (چاه B2) که داده‌های آن در ساخت مدل سهمی نداشت، آزمایش شد و

در اینجا دو حالت را با یکدیگر بررسی می‌کنیم:  
حالت(۱): ورودی شبکه، نگارهای پرتو گاما، چگالی، نوترون و اثر فتوالکترونیک (لایه ورودی دارای ۴ نرون) باشد.

حالت(۲): ورودی شبکه، نگارهای پرتو گاما، چگالی، نوترون، اثر فتوالکترونیک و نگار صوتی (لایه ورودی دارای ۵ نرون) باشد.

شبکه‌ای با یک لایه مخفی برای تقریب توابع کافی است، اندازه لایه مخفی، به عبارتی روشن‌تر، تعداد نرون‌های مخفی، سؤال اساسی است که عموماً مطرح می‌شود. برای شبکه، برای هر دو حالت در ابتدا تعداد پنج نرون برای لایه میانی در نظر گرفته شد و با افزایش تعداد آن‌ها تا صد و پنجاه نرون و بررسی روند الگوریتم توقف در هر مرحله، حالت بهینه برای هر دو حالت به قرار زیر است:

حالت(۱): تعداد نرون‌های لایه میانی ۲۵ نرون

حالت(۲): تعداد نرون‌های لایه میانی ۳۳ نرون

به‌طور کلی تعداد بیشتر الگوها (ورودی‌ها و خروجی‌های ذکر شده) و تعداد کمتر نرون‌های لایه میانی برای شبکه بهتر است. تعداد خیلی کم الگوها و تعداد خیلی زیاد نرون‌های میانی باعث می‌شود که شبکه به حالت ازبرکردن(Memorize) دست یابد (بریکوا و همکاران، ۲۰۰۲). یعنی شبکه در طول آموزش خوب کار می‌کند ولی در مرحله آزمون، بد کار می‌کند. به‌حال، تعداد لایه‌های میانی بیشتر، بهتر از تعداد کم آن‌ها نیست. در صورتی که تعداد لایه‌های میانی نیز نسبت به حالت بهینه کمتر باشد، شبکه به طور کامل آموزش نمی‌بیند و خطای آموزش آن بالا می‌رود و به همین دلیل قادر به برآورد پارامتر یا پارامترهای مورد نظر با دقت مناسب نیست. با ترسیم مقدار خطای بر حسب تعداد نرون برای داده‌های آموزش و آزمون، می‌توان به حالت بهینه دست یافت.

## ۲-۷ حالت (۲)

در صورتی که از نگارهای پرتو گاما، چگالی، نوترون، اثر فتوالکتریک و نگار صوتی در حکم ورودی شبکه استفاده شود، MSE داده‌های آموزش شبکه برابر  $0.013$  و MSE داده‌های اعتبارسنجی برابر  $0.025$  و MSE داده‌های آزمون برابر  $0.031$  است. در شکل ۵ می‌توان روند دورهای (Epoch) طی شده برای داده‌های آموزش، اعتبارسنجی و آزمون تا رسیدن به شبکه مطلوب را مشاهده کرد. همان‌طور که دیده می‌شود خطای نسبت به حال قبل کاهش یافته است که علت آن تاثیر نگار صوتی بر دقت برآورد است.

همان‌طور که گفته شد در این حالت، نگار صوتی نیز به نگارهای ذکر شده در حالت قبل، اضافه شده است. شکل‌های ۶ و ۷ رخساره‌های واقعی را با آنچه شبکه پیش‌بینی کرده است، مقایسه کرده‌اند. با مقایسه شکل‌های ۶ و ۷ با شکل‌های ۳ و ۴ مشخص می‌شود که در حالت دوم، برآورد بهبود یافته و دقت افزایش پیدا کرده است که این نشان از تاثیر مثبت نگار صوتی بر پیش‌بینی دارد. در حقیقت استفاده از این نگار به همراه نگارهای پرتو گاما، چگالی، نوترون و اثر فتوالکتریک باعث نزدیک تر شدن جواب، به مقدار واقعی شده است. ترکیب کانی‌شناسی و ساختمان اجزای تشکیل دهنده سنگ‌ها و ساخت و بافت آن‌ها با یکدیگر متفاوت است. این ویژگی‌ها بر سرعت امواج در سنگ‌ها تاثیر می‌گذارد. بنابراین در روش صوتی از تفاوت سرعت صوت برای تمایز، جدایش و شناسایی مشخصات سنگی استفاده می‌شود. نحوه آرایش و قرارگیری ذرات و فضای خالی روی سرعت صوت تاثیر دارد. با ثابت بودن تخلخل، سرعت صوت به نحوه تماس ذرات وابسته است. اگر

پس از حصول اطمینان از کارآیی مدل، به منظور برآورد رخساره‌ها در دو چاه A1 و A2 مورد استفاده قرار گرفت. در اینجا پنج رخساره برآورد شده است که عبارت‌اند از: Wackestone، Packstone، grainstone، Boundstone و Mudstone که شکل ۱، کد انتخاب شده شبکه را برای هر یک نشان می‌دهد.

پس از اجرای کد نوشته شده در محیط MATLAB و با در نظر گرفتن روش‌ها و موارد ذکر شده در قسمت‌های قبلی، نتایج به دست آمده به شرح زیرند:

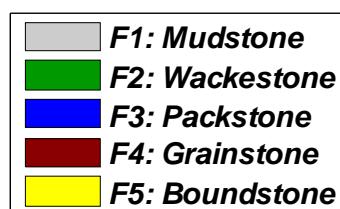
## ۱-۷ حالت (۱)

در صورتی که از نگارهای پرتو گاما، چگالی، نوترون و اثر فتوالکتریک در حکم ورودی شبکه استفاده شود، MSE داده‌های آموزشی شبکه برابر  $0.024$  و MSE داده‌های اعتبارسنجی برابر  $0.055$  و MSE داده‌های آزمون برابر  $0.061$  است. که تغییرات MSE در برابر تعداد تکرارها (Epoch) برای داده‌های آموزش، اعتبارسنجی و آزمون در شکل ۲ نشان داده شده است.

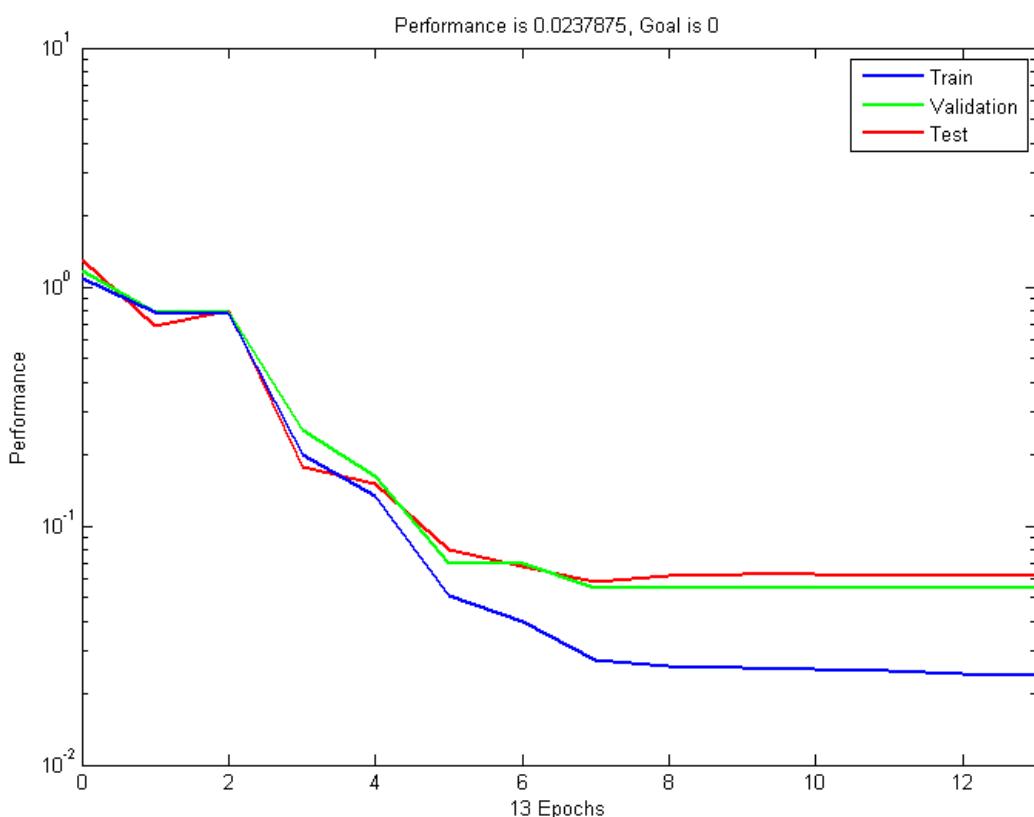
در شکل‌های ۳ و ۴ رخساره‌ای که حاصل از خروجی شبکه است با رخساره حاصل از توصیف مغزه بحسب عمق برای چاه‌های A1 و A2 مقایسه شده است. لازم به ذکر است که رخساره‌ها در این شکل به صورت کدھای ۱، ۲، ۳، ۴ و ۵ مشخص شده‌اند. که به ترتیب بیانگر مادستون، وکستون، پکستون، گرینستون و باندستون‌اند. توضیح کد هریک در شکل ۲ نمایش داده شده است. در این شکل‌ها رخساره واقعی حاصل از مغزه به شکل ضربدر و رخساره پیش‌بینی شده با استفاده از شبکه عصبی به شکل دایره نشان داده شده است. نقاطی که در آن‌ها ضربدرها درون دایره قرار گرفته‌اند، نشان دهنده برآورد درست شبکه هستند.

موارد که امکان شناسایی میان لایه‌های نازک از خردسنتگ‌ها وجود ندارد، نمودار صوتی، با فراهم آوردن این امکان شناسایی، از خطای احتمالی پیشگیری می‌کند. به همین دلیل در این تحقیق، استفاده از نگار صوتی به همراه نگارهای گام، چکالی، نوترون و اثر فتوالکتریک توانسته است قدرت تشخیص را افزایش دهد.

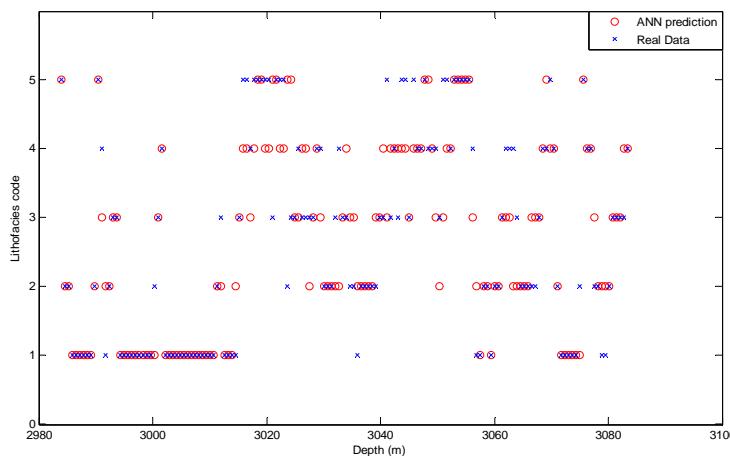
ترکیب کانی‌شناسی سنگ ثابت باشد سرعت امواج به شدت پیرو ساخت و بافت سنگ است. بنابر این از نگار صوتی می‌توان تا حدودی این ویژگی‌ها را برآورد کرد. از سوی دیگر ترکیب این نمودار با دیگر نمودارها می‌تواند به شناسایی ویژگی‌های سنگی کمک بسزایی کند. حساسیت نمودار صوتی در مقابل تغییر سنگ‌شناسی و خصوصیات بافتی سنگ‌ها چشمگیر است. در بسیاری از



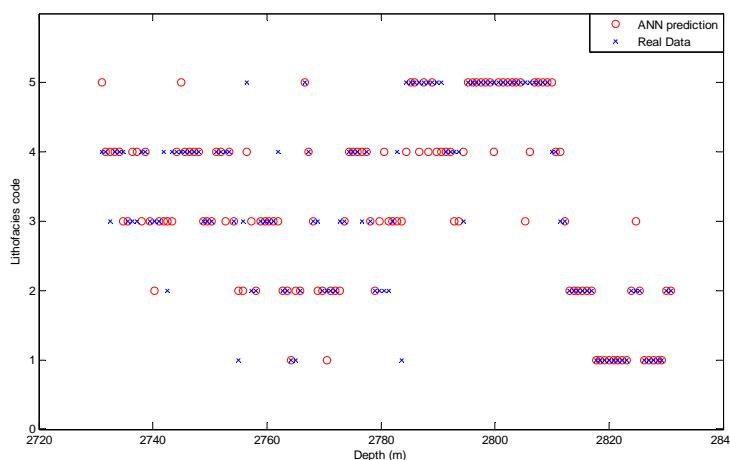
شکل ۱. کد رخساره‌های منطقه مورد بررسی.



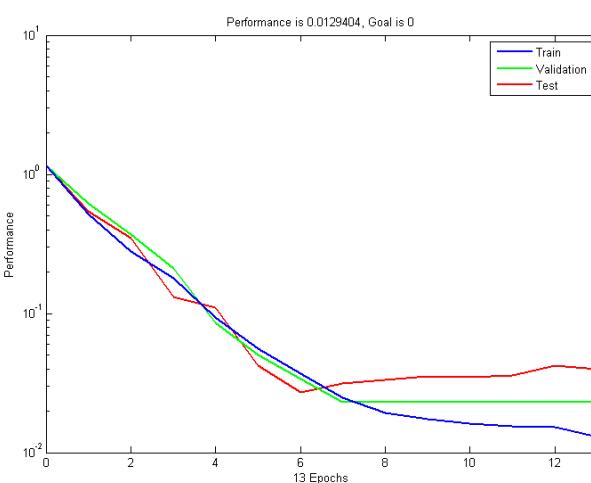
شکل ۲. منحنی تغییرات میانگین مربعات خطأ در برابر تعداد دور صورت گرفته در حالت‌های آموزش، اعتبارسنجی و آزمون برای حالت (۱).



شکل ۳. مقایسه رخساره‌های پیش‌بینی شده با شبکه عصبی (علامت دایره توخالی) با رخساره واقعی حاصل از مغزه (علامت ضربدر) مربوط به چاه A1.



شکل ۴. مقایسه رخساره‌های پیش‌بینی شده با شبکه عصبی (علامت دایره توخالی) با رخساره واقعی حاصل از مغزه (علامت ضربدر) مربوط به چاه A2.



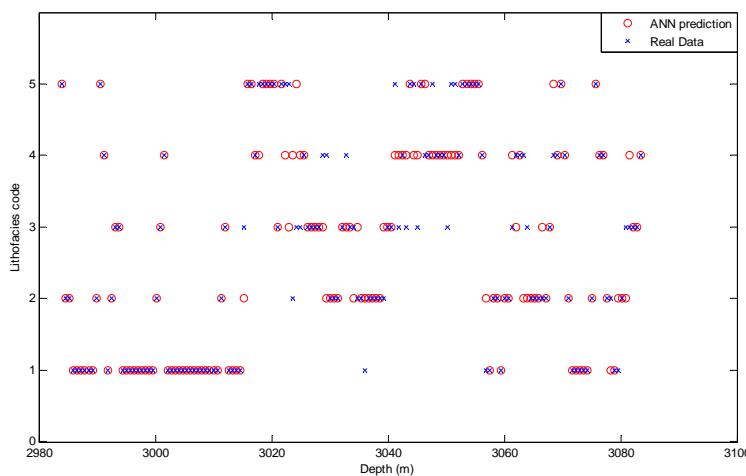
شکل ۵. منحنی تغییرات میانگین مربعات خطأ در برابر تعداد دور صورت گرفته در حالت‌های آموزش، اعتبارسنجی و آزمون برای حالت (۲).

ساخت و یافت سنگ‌ها حساسیت دارد، یکی از بهترین روش‌ها برای شناسایی خصوصیات سنگی است؛ به خصوص آنکه وقتی این نمودار با نمودارهای دیگری در چاه رانده شود، از ترکیب نتایج آن‌ها با قاطعیت و اطمینان بیشتر می‌توان به بررسی ویژگی سنگ‌ها پرداخت. لازم به ذکر است که در مواردی که پیش‌بینی بدون استفاده از نگار صوتی صورت گرفته و فقط با استفاده از نگارهای پرتوگاما، چگالی، نوترон و اثر فتوالکتریک رخساره برآورد شده است، در قسمت‌هایی که پیش‌بینی درست نبوده و خطاباً بوده، اشکال از شبکه طراحی شده نیست بلکه دقیق نگارهای پرتوگاما، چگالی، نوترون و اثر فتوالکتریک در پیش‌بینی رخساره کم بوده است و در حقیقت استفاده از این نگارها برای پیش‌بینی رخساره کافی نیست و نیاز به ورودی یا ورودی‌های دیگری است تا دقیق برآورد به حد قابل قبولی برسد.

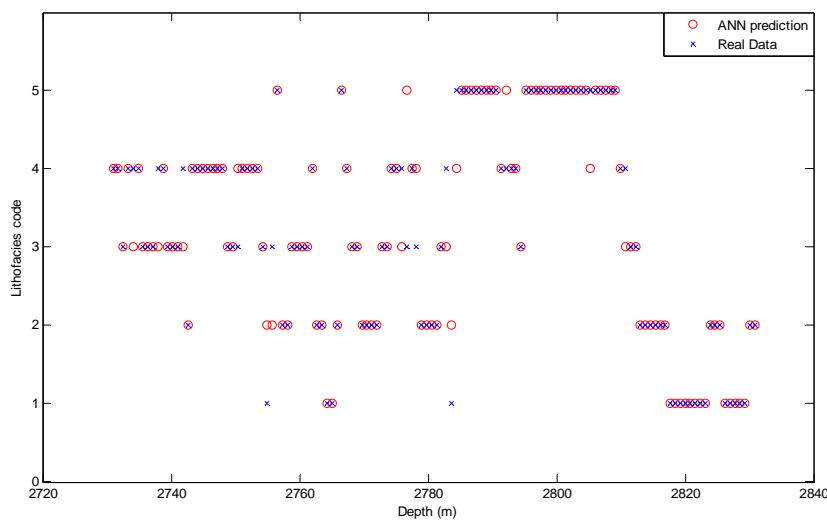
جدول ۱ میانگین مربعات خطای هر دو حالت برای چاه‌های A1 و A2 نشان می‌دهد. با توجه به این جدول، مشاهده می‌شود که با اضافه شدن نگار صوتی به ورودی‌های شبکه، مقدار خطای کاهش یافته است. شکل ۸ رخساره‌های برآورد شده نسبت به رخساره واقعی به دست آمده از مغزه، در هر دو حالت را بر حسب عمق در کنار یکدیگر مقایسه کرده است. این شکل، هر دو چاه A1 و A2 را به طور جداگانه بررسی کرده و همان‌طور که مشهود است، پیش‌بینی شبکه در حالت دوم به رخساره واقعی نزدیک‌تر است و تفکیک رخساره‌ها در این حالت نسبت به حالت اول با دقیق‌تری صورت گرفته است. این امر نشان می‌دهد که اضافه کردن نگار صوتی به ورودی‌های شبکه باعث بهبود تفکیک رخساره‌ها شده است. با توجه به اینکه نمودار صوتی در مقابل کوچک‌ترین تغییر در سنگ‌شناسی و خصوصیات

جدول ۱. میانگین مربعات خطای حالات مورد بررسی به تفکیک چاه‌ها.

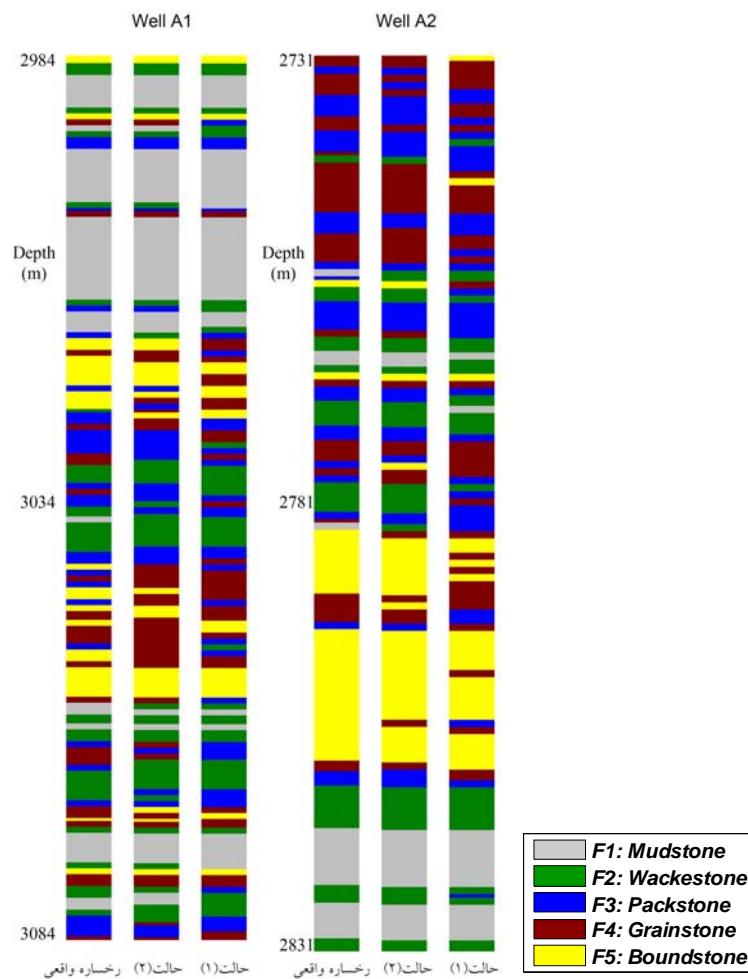
Inputs	Well A1 MSE	Well A2 MSE
GR, RHO, NPHI, PEF	0.068	0.074
GR, RHO, NPHI, PEF, SONIC	0.052	0.060



شکل ۶. مقایسه رخساره‌های پیش‌بینی شده با شبکه عصبی (علامت دایره توخالی) با رخساره واقعی حاصل از مغزه (علامت ضربدر) مربوط به چاه A1.



شکل ۷. مقایسه رخسارهای پیش‌بینی شده با شبکه عصبی (علامت دایره توخالی) با رخساره واقعی حاصل از مغزه (علامت ضربدر) مربوط به چاه A2.



شکل ۸. مقایسه رخساره پیش‌بینی شده با شبکه عصبی مصنوعی با رخساره واقعی حاصل از مغزه برای هر دو حالت در چاه‌های A1 و A2.

است و در صورتی که از نگار صوتی نیز به همراه دیگر ورودی‌ها استفاده شود، مقدار MSE به  $0.052 \pm 0.060$  برای چاه A2 تقلیل می‌یابد، که نشان از بهتر شدن برآورد دارد و میین آن است که با اضافه شدن نگار صوتی به دیگر ورودی‌ها، رخساره برآورد شده، به رخساره حاصل از آنالیز مغزه نزدیک‌تر شده و تفکیک بهتری بین رخساره‌ها صورت گرفته است.

### تشکر و قدردانی

بدین وسیله لازم می‌داند از آقایان مهندس صدقی پور و مهندس فرخ‌شاد از شرکت نفت و گاز پارس و جناب آقای مهندس خوشبخت از پژوهشگاه صنعت نفت و همچنین، از شرکت نفت و گاز پارس برای در اختیار دادن داده‌های مورد نیاز تشکر و قدردانی به عمل آید.

با توجه به مواردی که در بالا به آن‌ها اشاره شد، برای افزایش دقت برآورد، نگار صوتی انتخاب شد. شاید استفاده از نگارهای دیگری چون مقاومت نیز می‌توانست دقت را افزایش بیشتری دهد اما به علت نبود داده‌های مربوط، از این نگارها استفاده نشد. در اینجا لازم است به این نکته اشاره شود که خطای در برآورد به علت اشکال در نگارهای پرتوگاما، چگالی، نوترون و اثر فتوالکترونیک نیست بلکه این نگارها برای برآورد رخساره تا رسیدن به دقت قابل قبول، کافی نیستند. همان‌طور که مشاهده می‌شود در هر دو چاه A1 و A2، جواب‌ها به این صورت است که با وارد شدن نگار صوتی، دقت پیش‌بینی افزایش پیدا کرده است و این نگار با استفاده از نگارهای قبلی توانسته جواب پیش‌بینی را به واقعیت نزدیک‌تر کند.

### ۸ نتیجه‌گیری

- منابع**
- غضنفری، م.، ارکات، ج.، ۱۳۸۳، شبکه‌های عصبی (اصول و کارکردها): مرکز انتشارات دانشگاه علم و صنعت ایران.
- منهاج، م.، ۱۳۸۴، مبانی شبکه‌های عصبی: مرکز نشر پرفسور حسابی.
- مهندی‌زاده، م.، ۱۳۸۳، شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی: انتشارات عبادی.

Alimonti, C., Rome, U., Sapienza, L., and Falcone, G, 2004, Integration of multiphase flow metering neural network and fuzzy logic in field performance monitoring: SPE 87629-PA.

Aminian, K., and Ameri, S., 2005, Application of artificial neural networks for reservoir characterization with limited data: Journal of Petroleum Science and Engineering, **49**, 212-222.

Borsaru, M., Zhou, B., Aizawa, T., Karashima, H., and Hashimoto, T., 2006, Automated lithology prediction from PGNA and other geophysical logs: Applied Radiation and Isotopes, **64**, 272-282.

این تحقیق نشان می‌دهد که شبکه عصبی پس انتشار خطای (BP)، توانایی برآورد رخساره‌های سنگی سنگ مخزن را با استفاده از داده‌های حاصل از چاه دارد. این طرح همچنین با ملزومات عملیاتی و واقعی نیز همخوانی دارد. چرا که نمودار گیری در بیشتر چاه‌ها صورت می‌گیرد ولی مغزه گیری در تعداد محدودی از چاه‌ها به انجام می‌رسد. همچنین ممکن است به دلایلی، در قسمت‌هایی از چاه مغزه نداشته باشیم و یا تخریب صورت گرفته باشد. لذا با در اختیار داشتن شبکه آموزش دیده مطلوب، می‌توان به برآورد تغییر رخساره در چاه‌هایی که صرفاً دارای نگار هستند اقدام، و رخساره آن چاه و یا قسمت‌های فاقد مغزه را شیوه‌سازی کرد.

استفاده از نگار صوتی برای بهتر برآورد کردن رخساره، مفید واقع شد. مقدار MSE (میانگین مربعات خطای) در صورتی که فقط از نگارهای پرتوگاما، چگالی، نوترون و اثر فتوالکترونیک به منزله ورودی شبکه استفاده شود، برای چاه A1  $0.068 \pm 0.074$  و برای چاه A2

- computational intelligent for reservoir characterization: Expert Systems with Applications, **26**, 19-38.
- Nikravesh, M., Aminzadeh, F., 2001, Mining and fusion of petroleum data with fuzzy logic and neural network agents: Journal of Petroleum Science and Engineering, **29**, 221-238.
- Ounes, A., 2000, Practical application of fuzzy logic and neural networks to fractured reservoir characterization: Computers & Geosciences, **26**, 953-962.
- Rezaee, M. R., Kadkhodaie, A., and Barabadi, A., 2007, Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia: Journal of Petroleum Science and Engineering, **55**, 201-212.
- Shiwei, Y., Kejun, Z., Fengqin, D., 2008, A dynamic all parameter adaptive BP neural networks model and its application on oil reservoir prediction: Applied Mathematics and Computation, **195**, 66-75.
- Siripitayananon, P., Chen, H., and Hart, B. S., 2001, A new technique for lithofacies prediction: Back-Propagation Neural Network: Association for Computing Machinery, Inc.
- Taheri, S. R., 2006, Remote sensing, fuzzy logic and GIS in petroleum exploration: SPE 101040-MS.
- Briqueu, L., Gottlib-Zeh, S., Ramadan, M., and Brulhet, J., 2002, Inferring lithology from downhole measurements using an unsupervised self-organising neural network: study of the Marcoule silty clayish Unit: C. R. Geoscience, **334**, 331-337.
- Chang, H., Kopaska, C., and Chen, H., 2002, Identification of lithofacies using Kohonen self-organizing maps: Computers & Geosciences, **28**, 223-229.
- Duboisa, K., Geoffrey, C., and Bohling, S., 2007, Comparison of four approaches to a rock facies classification problem: Computers & Geosciences, **33**, 599-617.
- Garrouch, A., and Labbabidi, H., 2003, Title using fuzzy logic for UBD candidate selection: SPE 81644-MS.
- Helle, H. B., Bhatt, A., and Ursin, B., 2001, Porosity and permeability prediction from wireline logs using artificial neural networks: a North Sea case study: Geophysical Prospecting, **49**, 431- 444.
- Malallah, A., and Nashawi, I. S., 2005, Estimating the fracture gradient coefficient using neural networks for a field in the Middle East: Journal of Petroleum Science and Engineering, **49**, 193-211.
- Mohaghegh, S. D., Chevron, A., Gaskari, R., and Siegfried, R., 2004, Determining in-situ stress profiles from logs: SPE 90070.
- Nikravesh, M., 2004, Soft computing-based