



<https://jssr.ui.ac.ir/?lang=en>

Journal of Stratigraphy and Sedimentology Researches  
E-ISSN: 2423-8007  
Vol. 39, Issue 2, No. 91, Summer 2023, pp 45-58  
Received: 16.03.2023 Accepted: 17.10.2023

#### Research Paper

### Comparison of the function of ELM and RBF models for estimating the porosity of the Asmari Formation, in one of the offshore fields of the northwest Persian Gulf

**Farshad Tofighi**

MSc student, Department of Mining, Faculty of Engineering, Imam Khomeini International University, Qazvin, Iran  
farshadtfg@gmail.com

**Parviz Armani** \* 

Associate professor, Department of Geology, Faculty of Sciences, Imam Khomeini International University, Qazvin, Iran  
armani@sci.ikiu.ac.ir

**Ali Chehrazi**

PhD of geology, Iranian Offshore Oil Company, Tehran, Iran  
chehrazi2001@yahoo.com

**Andisheh Alimoradi**

Assistant professor, Department of Mining, Faculty of Engineering, Imam Khomeini International University, Qazvin, Iran  
alimoradi@eng.ikiu.ac.ir

#### Abstract

Nowadays, the use of artificial intelligence is common to increase the accuracy of the study and, close to reality, is used in the oil industry to increase the accuracy of studying and understanding the relationship between various parameters. The main purpose of this study is to compare the performance of the two methods of Extreme Learning Machine (ELM) and Radial Basis Function (RBF) in porosity estimation, which is static oil modeling. The data from seven wells in the offshore field (Hendijan Oilfield) of the northwestern Persian Gulf were examined. In this regard, post-stack seismic attributes which have a significant relationship with porosity and porosity log for each well were used to compare the performance of the ELM and RBF networks under the same conditions. Eventually, it reveals that ELM is quite sensitive to the data set and needs more data points to prepare a map (quantitatively), but is better than RBF in terms of classification (qualitative). On the other hand, RBF is one of the most powerful algorithms in mapping, especially in low numbers of data points, which can be challenging for others.

**Keywords:** ELM, RBF, Porosity, Seismic Attributes, Hendijan Field

#### Introduction

Today, the use of artificial intelligence to increase the accuracy of work and predict close to reality has caused great progress in various industries. In the oil industry, artificial intelligence is used to increase work accuracy and identify the relationship between different parameters. One of the most important processes in the oil industry is reservoir rock characterization, in which porosity plays a very important role (Ezekwe, 2003). The target succession is the Asmari Formation, one of the most important oil reservoirs in Iran and the Middle East, which constitutes the oil reserves of 62 oilfields in southwest Iran and the Persian Gulf. Among such fields, 14 fields have been categorized as mega and 12 as huge

fields in the world ranking. Both types of carbonate and siliciclastic rocks exist in this formation, which can be challenging for predictive networks. This research has tried to compare the performance of two networks, ELM and RBF, in the accuracy and generalizability of estimating the porosity of existing wells in the Hendijan Oilfield by using seismic attributes.

#### Materials & Methods

This is data-based research that includes data from 7 wells located in the Hendijan oil field situated in the northwest of the Persian Gulf.

Hampson\_Rusell software is used to work with seismic

\*Corresponding author

Tofighi F. Armani P. Chehrazi A. and Alimoradi A. (2023). Comparison of the function of ELM and RBF models for estimating the porosity of the Asmari Formation, in one of the offshore fields of the northwest Persian Gulf. Journal of Stratigraphy and Sedimentology Researches, 39(2):45-58.



2423-8007 / © 2023 University of Isfahan

This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/jssr.2023.137083.1256>

and well-log data, such as making the connection and modeling of the RBF network. Petrel software is utilized for 3D simulation of the layers and specifying the desired horizons. MATLAB software is applied to create and evaluate the ELM network. Well-log data (e.g. Porosity and P wave velocity logs), post-stack 3D seismic data as well as check shot correction to collaborate well log data and seismic data are used. Seismic attributes are driven by stepwise regression. The final multi-attributes list contains only attributes that have a meaningful relationship with porosity and have no relationships with others.

#### **Discussion of Results & Conclusions**

Both networks are designed with the same multi-attributes list and desire the highest accuracy and the lowest error. Therefore, the correlation coefficient and Root Mean Square


Error (RMSE) represent identifier trend and accuracy, respectively. Overall, the RBF network, which is representative of common neural networks, has better performance than the ELM network. It depends on the mathematical structure and the number of data points that are used. The ELM network is a single-layer feedforward neural network that does not have deep learning capabilities compared to multi-layer models. Thus, it requires a much higher number of data points than using a training dataset. One of the main features of the ELM network is the high speed of data processing, which proves the need for a large number of data points. On the other hand, the ELM network has more flexibility than the RBF network because different activation functions are used in it, while in the RBF model, only the base radius activation function is used.

مقاله پژوهشی

## مقایسه کارکرد مدل‌های ELM و RBF برای برآورد تخلخل سازند آسماری، در یکی از میدان‌های فراکرانه‌ای شمال باختری خلیج فارس

فرشاد توفیقی، کارشناس ارشد گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی، قزوین، ایران

farshadtfg@gmail.com

پرویز آرمانی\* , دانشیار گروه زمین‌شناسی، دانشکده علوم، دانشگاه بین‌المللی امام خمینی، قزوین، ایران

armani@sci.ikiu.ac.ir

علی چهارزی، مدیر طرح‌های اکتشافی، شرکت فلات قاره، تهران، ایران

achehrazi@iooc.co.ir

اندیشه علیمرادی، استادیار گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی، قزوین، ایران

alimoradi@eng.ikiu.ac.ir

### چکیده

امروزه بهره‌گیری از هوش مصنوعی برای افزایش دقت مطالعه و نزدیک‌بودن به واقعیت، بسیار متداول است و در صنعت نفت، برای افزایش دقت بررسی و شناخت رابطه میان پارامترهای گوناگون به کار می‌رود. هدف اصلی این پژوهش، مقایسه کارکرد دو روش ماشین یادگیری حدی (ELM) و شبکه عصبی شعاع مینا (RBF) در مدل‌سازی ایستایی نفت، تخلخل است. داده‌های ۷ حلقه چاه میدان فراکرانه‌ای هنديجان، واقع در کرانه شمال باختری خلیج فارس بررسی شد. در این راستا، با بهره‌گیری از نشانگرهای لرزه‌ای پس از برانبارش، که رابطه معنی‌داری با تخلخل دارند، و نمودار تخلخل هر چاه، کارکرد شبکه‌های ELM و RBF در شرایط یکسان تنظیم و مقایسه شد. سرانجام آشکار شد که ELM کاملاً به مجموعه داده‌ها حساس است و برای تهیه نقشه (کمی) به نقاط داده بیشتری نیاز دارد، اما از نظر رده‌بندی (کیفی) از RBF بهتر است. از سوی دیگر، RBF یکی از تواناترین الگوریتم‌ها در نقشه‌برداری است، به‌ویژه در شمار کم داده‌ها و برای دیگران چالش‌برانگیز است.

**کلیدواژه:** ELM، RBF، تخلخل، نشانگرهای لرزه‌ای، میدان فراکرانه‌ای!

\*نویسنده مسئول

توفیقی، ف؛ آرمانی، پ؛ چهارزی، ع. و علی‌مرادی، ا. (۱۴۰۲). مقایسه کارکرد مدل‌های ELM و RBF برای برآورد تخلخل سازند آسماری، در یکی از میدان‌های فراکرانه‌ای شمال باختری خلیج فارس. پژوهش‌های چینه‌نگاری و رسوب‌شناسی، ۳۹(۲): ۴۵-۵۸.



## مقدمه

(et al. 2014; Obeida et al. 2005, Jafarizadeh et al. 2022).

پیش‌بینی خصوصیات پتروفیزیکی، به‌خصوص ویژگی تراوایی و مقایسه کارکرد شبکه‌های مختلف بسیار مرسوم است؛ از جمله این پژوهش‌ها به بررسی و مقایسه عملکرد شبکه‌های عصبی Cascade Forward<sup>۵</sup>، ماشین بردار پشتیبانی حداقل مربعات<sup>۶</sup>، پرسپترون چند لایه<sup>۷</sup>، شبکه عصبی رگرسیون تعمیم‌یافته<sup>۸</sup> با بهینه‌کننده‌های الگوریتم لونبرگ مارکواریت<sup>۹</sup> و الگوریتم جست‌وجوی گرانشی<sup>۱۰</sup> Mahdaviara و همکاران و همچنین مقایسه عملکرد شبکه‌های روش گروهی پردازش داده‌ها<sup>۱۱</sup>، رگرسیون چند جمله‌ای<sup>۱۲</sup>، رگرسیون بردار پشتیبان<sup>۱۳</sup> و درخت تصمیم‌گیری<sup>۱۴</sup> Kamali و همکاران اشاره می‌شود (Mahdaviara et al. 2022, Kamali et al. 2022). شایان ذکر است که در دو مطالعه Mahdaviara و همکاران و همچنین Kamali و همکاران، از داده‌های چاه‌نگاری برای برآورد خصوصیات پتروفیزیکی تخلخل، مساحت سطح حفره و اشباع آب کاهش‌نیافتنی بهره‌گیری شده است. همچنین در صنعت اکتشاف نفت و زمین‌شناسی، از هوش مصنوعی برای برآورد پارامترهای پایه‌ای ژئوفیزیک، از جمله سرعت موج برشی<sup>۱۵</sup> استفاده می‌شود که در طی مطالعه‌ای با بهره‌گیری از شبکه‌های عصبی مرسوم<sup>۱۶</sup>، ماشین یادگیری حدی چند لایه<sup>۱۷</sup>، ماشین بردار پشتیبان حداقل مربعات<sup>۱۸</sup> و استفاده از داده‌های چاه‌نگاری، تلاش شده است تا سرعت موج برشی پیش‌بینی شود (Mehrad et al. 2022). مقایسه‌ای میان کارکرد شبکه‌های

امروزه بهره‌گیری از هوش مصنوعی<sup>۱</sup> به‌منظور افزایش دقت کار و پیش‌بینی نزدیک به واقعیت، باعث پیشرفت شگرفی در صنایع گوناگون شده است. در صنعت نفت، از هوش مصنوعی برای افزایش دقت کار و شناسایی ارتباط میان پارامترهای مختلف استفاده می‌شود. شناخت سنگ مخزن، یکی از مهم‌ترین فرآیندها در صنعت نفت است که تخلخل نقش بسیار مهمی در آن دارد (Ezekwe 2003). تخلخل در محاسبه حجم و میزان اشباع سیال، شناسایی واحدهای جریان و بررسی اقتصادی پروژه‌ها نقش بسزایی دارد (Aghajariyan et al. 2012; Asoodeh and Bagheripour 2013; ) (Gholami and Ansari 2017; Nelson 1994). در بسیاری از بررسی‌های زمین‌شناسی، از هوش مصنوعی بهره‌گیری شده است؛ از جمله شناسایی گسل<sup>۲</sup> (Lawrence 1998)، شناسایی رخساره‌های سنگی و توصیف مخزن (Edalat and Siyahkoochi 2007; Raeisi 2008; Reddy et al. 2004; Siripitayananon et al. 2001)، شناسایی واحدهای جریانی (Aghajariyan et al. 2012)، با بهره‌گیری از داده‌های لرزه‌ای، داده‌های چاه‌نگاری و امپدانس صوتی، پیش‌بینی و مشخص کردن نهشته‌های کربناته با بهره‌گیری از شبکه ترکیبی نوروفازی<sup>۳</sup> (Malami et al. 2021) و داده‌های چاه‌نگاری، پیش‌بینی پارامترهای ناهمسانگرد با بهره‌گیری از شبکه ترکیبی ماشین یادگیری حدی هسته‌مندی عمیق چندگانه که به‌وسیله الگوریتم گرده‌افشانی گل<sup>۴</sup> (Wu et al. 2023) بهینه شده است. امروزه از هوش مصنوعی، بیشتر برای برآورد ویژگی‌های پتروفیزیکی، مانند تخلخل، تراوایی، اشباع و نوع سیال سازند، فشار منفذی و همچنین میرایی موج با بهره‌گیری از داده‌های چاه‌نگاری، نشانگرهای لرزه‌ای و داده‌های مغزه بهره‌گیری می‌شود (Heydari Gholanlo et al. 2016; Hosseini et al. 2011; Iturraran\_Viveros and Para 2014; Khoshdel and Riahi 2011; Malvic and Prskalo 2007; Na'imi

<sup>5</sup> Cascade Forward Neural Network (CFNN)

<sup>6</sup> Least Square Support Vector Machine (LSSVM)

<sup>7</sup> Multilayer Perceptron (MLP)

<sup>8</sup> Generalized Regression Neural Network (GRNN)

<sup>9</sup> Levenberg Marquardt Algorithm (LMA)

<sup>10</sup> Gravitational Search Algorithm (GSA)

<sup>11</sup> Group Method of Data Handling (GMDH)

<sup>12</sup> Polynomial Regression (PR)

<sup>13</sup> Support Vector Regression (SVR)

<sup>14</sup> Decision Tree (DT)

<sup>15</sup> Shear wave

<sup>16</sup> Conventional Neural Network (CNN)

<sup>17</sup> Multilayer Extreme Learning Machine (MELM)

<sup>18</sup> Least-Squares Support-Vector Machine (LSSVM)

<sup>1</sup> Artificial Intelligence

<sup>2</sup> Fault Detection

<sup>3</sup> Hybrid Neuro-Fuzzy

<sup>4</sup> FPA-D-MK-ELM

HD\_1 و HD\_6 داده‌های ناشناخته و بر پایه جایگاه جغرافیایی در نظر گرفته شدند (شکل ۱). چاه HD\_1 برای شناسایی دقت کارکرد مدل و چاه HD\_6 برای شناسایی تعمیم‌پذیری مدل به کار گرفته شدند. نمودارهای تخلخل و سرعت موج فشاری<sup>۱۱</sup> در تمامی چاه‌ها موجود است. شمار نقاط اطلاعات کلی به دست آمده از هفت چاه، ۱۸۵ عدد است. شایان ذکر است که ورودی‌های شبکه عصبی، از نشانگرهای به دست آمده از داده‌های سه بعدی لرزه‌ای است که در شکل ۲، مقطع لرزه‌ای در چاه HD\_5 مشاهده می‌شود. سازند مدنظر در این پژوهش، سازند آسماری است؛ زیرا این سازند یکی از مهم‌ترین سازندهای نفتی ایران و خاورمیانه است که ذخایر نفتی ۶۲ میدان نفتی را تأمین می‌کند، از میان آنها ۱۴ ابرمیدان و ۱۲ میدان عظیم در رده‌بندی جهانی طبقه‌بندی شده‌اند و از طرفی هر دو لیتولوژی کربناته و ماسه‌سنگی را دارند و برای شبکه‌های پیش‌بینی‌کننده، چالش‌برانگیزند.

پس‌انتشار<sup>۱</sup>، ماشین بردار پشتیبان<sup>۲</sup>، ماشین یادگیری حدی<sup>۳</sup> و ماشین یادگیری حدی بهینه‌شده<sup>۴</sup> برای برآورد تخلخل و تراوایی مخزن ماسه‌سنگی انجام شد. یافته‌ها نشان داد OP-ELM بالاترین دقت و کمترین زمان محاسبه را دارد. از سوی دیگر، مدل‌های SVR و BP به ترتیب در رده‌های بعدی قرار گرفته‌اند (Cao et al. 2015). همچنین هوش مصنوعی در دیگر شاخه‌های نفتی نیز کاربرد گسترده‌ای دارد، به‌گونه‌ای که در یکی از مطالعات سعی شده است تا با بهره‌گیری از داده‌های چاه‌نگاری و شبکه‌های هوش مصنوعی، MELM, LSSVM, الگوریتم ژنتیک<sup>۵</sup> و ازدحام ذرات<sup>۶</sup>، وزن مناسب گل برای تعیین پنجره ایمن وزن گلی<sup>۷</sup> پیش‌بینی شود. در پایان مشخص شد شبکه ترکیبی ELM-PSO سرعت و دقت کارکرد بالایی نسبت به دیگر شبکه‌ها دارد (Beheshtain et al. 2022).

در این پژوهش کوشش شده است تا با بهره‌گیری از داده‌های لرزه‌ای پس از برانبارش، شماری نشانگر لرزه‌ای استخراج شوند که ارتباط معناداری با تخلخل دارند و پس از آن با بهره‌گیری از مدل‌های ELM و تابع شعاع مینا<sup>۸</sup>، تخلخل برآورد و کارکرد آنها در داده‌های نادیده یا ناشناخته<sup>۹</sup>، مقایسه شود. در واقع منظور از داده‌های ناشناخته، داده‌هایی‌اند که در آموزش شبکه به کار نرفته‌اند و از آنها برای ارزیابی شبکه طراحی شده استفاده می‌شود.

### زمین‌شناسی میدان نفتی

این یک پژوهش بر پایه داده<sup>۱۰</sup> است و شامل داده‌های حاصل از هفت چاه واقع در میدان نفتی هندیدجان، در شمال باختری حوزه خلیج فارس است. از هفت چاه این میدان، دو چاه

<sup>1</sup> Back Propagation (BP)

<sup>2</sup> Support Vector Machine (SVM)

<sup>3</sup> Extreme Learning Machine (ELM)

<sup>4</sup> Optimized Extreme Learning Machine (OP-ELM)

<sup>5</sup> Genetic Algorithm (GA)

<sup>6</sup> particle swarm (PSO)

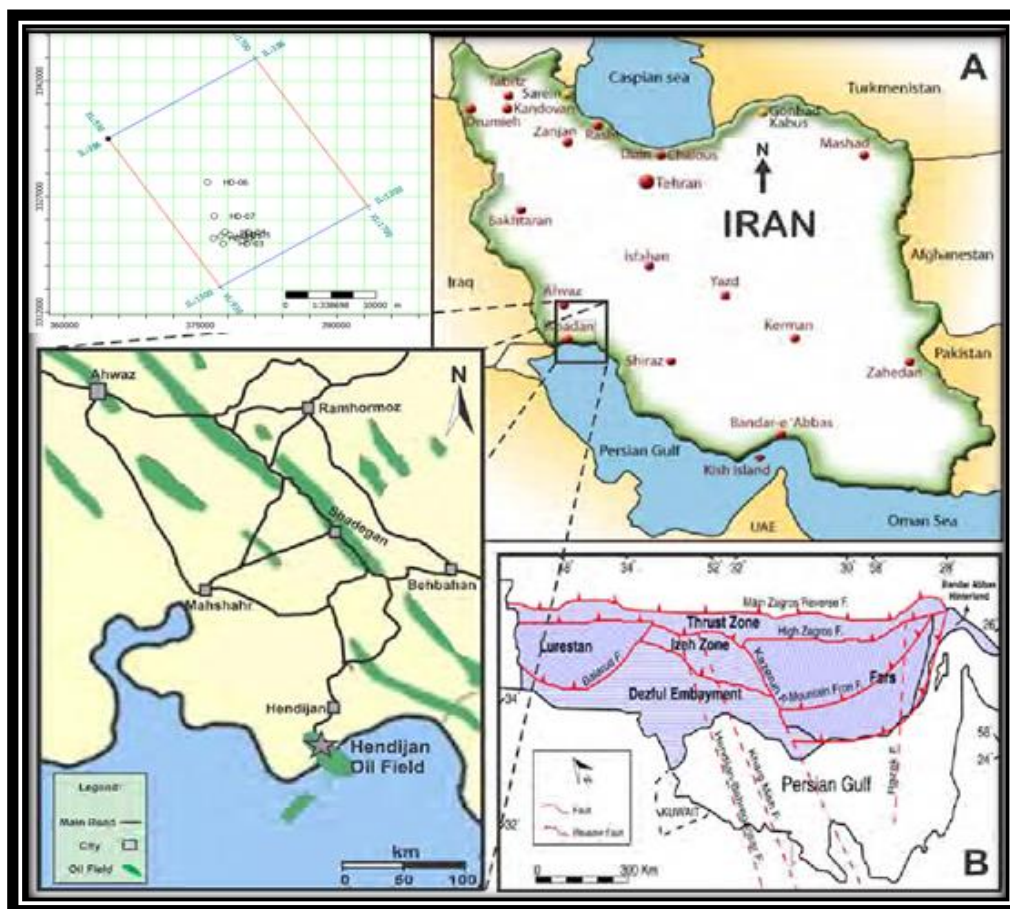
<sup>7</sup> safe mud weight window (SMWW)

<sup>8</sup> Radial Basis Function (RBF)

<sup>9</sup> Unseen data

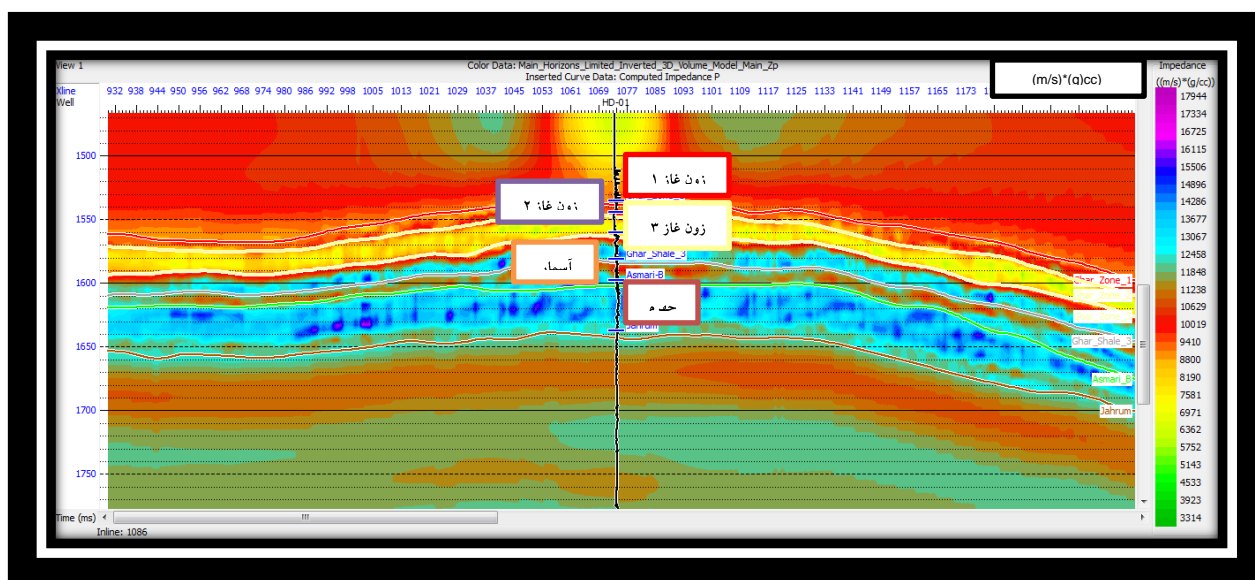
<sup>10</sup> Data base

<sup>11</sup> P Wave



شکل ۱- جایگاه جغرافیایی میدان و چاه‌های استفاده شده

Fig 1- Geographical location of used wells



شکل ۲- مقطع لرزه‌ای در چاه HD\_5

Fig 2- Seismic section in HD\_5 well

## روش پژوهش

هدف اصلی این پژوهش، بررسی توان و دقت شبکه ELM نسبت به شبکه مرسوم RBF در کارهای نفتی است. برای این منظور، همان‌طور که بیان شده است، از داده‌های لرزه‌ای پس از برانبارش برای استخراج نشانگرهای لرزه‌ای بهره‌گیری می‌شود و پس از ارزیابی آنها، از نشانگرهایی در طراحی شبکه عصبی مدنظر بهره‌گیری می‌شود که از یکدیگر مستقل‌اند و ارتباط معناداری با تخلخل دارند. به‌طور کلی نشانگرهای لرزه‌ای، اطلاعات لرزه‌ای اند که به صورت مستقیم و غیرمستقیم از طریق انجام روابط ریاضیاتی پیچیده بر داده لرزه‌ای ایجاد می‌شوند (Russell 2004). به ترتیب، نشانگرهای مشتق‌شده از زمان، دامنه و فرکانس، شامل داده‌های ساختمانی، داده‌های چینه‌شناسی - مخزنی و داده‌های مربوط به ویژگی‌های مخزنی‌اند (Avseth et al. 2010; Chopra and Marfurt 2005). جذب انرژی یکی از مهم‌ترین نشانگرهای به کار رفته است که اطلاعاتی مربوط به حضور سیال و تراوایی دارد (Cao et al. 2015). در این پژوهش از نرم‌افزار Hampson\_Rusell برای کار با داده‌های لرزه‌ای و چاه‌نگاری، از قبیل ایجاد ارتباط و مدل‌سازی شبکه RBF، از نرم‌افزار Petrel برای شبیه‌سازی سه بعدی لایه‌ها و مشخص کردن افق‌های مطالعه‌شده و از نرم‌افزار Matlab برای ایجاد و ارزیابی شبکه ELM طراحی شده استفاده شده است. از نگارهای تخلخل، سرعت موج P به‌عنوان سرعت موج صوتی، چکش‌ها برای هم حوزه کردن داده‌های چاه‌نگاری، لرزه‌ای از داده‌های چاه‌نگاری و داده‌های سه بعدی لرزه‌ای پس از برانبارش نیز، بهره گرفته شده است.

ELM یک شبکه پیش‌خور تک لایه<sup>۱</sup> است که برای رده‌بندی، برآورد و دسته‌بندی داده‌ها به کار رفته است (Huang et al. 2006). تک‌لایه‌بودن مدل ELM باعث شده است تا سرعت بسیار بالایی در واکاوی و محاسبات داشته باشد. با به‌کارگیری این مدل، هر تابعی با دقت بسیار مناسبی برآورد

می‌شود (Azarshab 2017). تک‌لایه‌بودن مدل باعث شده است تا لایه نهان بسیار آسان‌تر تنظیم شود و کارکرد دقیق‌تر و تأثیرگذارتری در روند عملیاتی شبکه داشته باشد. همچنین در ارزیابی و تعمیم شبکه ELM، یکی از مهم‌ترین عوامل تعمیم، نوع تابع فعال‌سازی<sup>۲</sup> و شمار نورون‌هاست (Huang et al. 2006). در این مدل میزان اولیه<sup>۳</sup> و مقدار وزن ورودی نورون‌ها به صورت تصادفی انتخاب می‌شود و تا پایان کار، ثابت باقی می‌ماند. سیستم تنها وزن بین نورون و لایه خروجی را به صورت خطی و با هدف کاهش خطا و داشتن کارکرد نزدیک به واقعیت تغییر می‌دهد.

تابع RBF را در سال ۱۹۸۷ Powell معرفی کرد؛ اما اولین بار توسط Schultz و همکارانش در سال ۱۹۹۴ در یک شبکه پیش‌خور از آن استفاده کردند که در آن نمودار زنگوله‌ای مانند گاوسی به عنوان تابع تحریک به کار گرفته شده است. این تابع می‌کوشد یک رابطه ویژه بین نشانگرهای لرزه‌ای و داده آموزشی ایجاد کند و همچنین در فضای M-بعدی عمل می‌کند. در شبکه RBF، اوزان از قبل محاسبه و سپس اعمال می‌شوند. پارامتر سیگما برای RBF، یک پارامتر کلیدی و هموارساز<sup>۴</sup> است که باعث یکنواخت شدن عملکرد شبکه می‌شود و از نتایجی جلوگیری می‌کند که خارج از محدوده طبیعی است و به عنوان نوفه شناخته می‌شود. به عبارت دیگر، نتایج شبکه طراحی شده را به واقعیت نزدیک می‌کند. با کاهش پارامتر سیگما، اوزان به مقادیر آموزش همگرا و با افزایش آن، شکل نمودار عملگر هموارتر می‌شود. این پارامتر از راه اعتبارسنجی متقابل مقدار بهینه آن شناسایی می‌شود.

برای انتخاب مجموعه نشانگرهای مناسب، از روش رگرسیون گام به گام هوشمند<sup>۵</sup> بهره‌گیری شد. در این روش در آغاز، تک‌نشانگری انتخاب می‌شود که کمترین خطا را در برآورد تخلخل دارد. در مرحله بعد کوشش شد تا جفت

<sup>2</sup> Activation Function

<sup>3</sup> Bias

<sup>4</sup> Smoothing Factor

<sup>5</sup> Step wise Regression

<sup>1</sup> SLFN

در این مرحله ارتباط نشانگرهای انتخاب‌شده با یکدیگر بررسی می‌شود؛ از این رو همان‌گونه که در جدول ۲ نشان داده شده است، نشانگرهای فیلتر ۱۵/۲۰-۵/۱۰، جهت‌یافتگی ظاهری<sup>۲</sup> و پوش دامنه<sup>۳</sup> باهم ارتباط دارند. پس با توجه به رابطه<sup>۱</sup> (۱)، ارزیابی ارتباط نشانگرهای یادشده با دیگر نشانگرهای باقی‌مانده بر پایه پارامتر ضریب تورم واریانس<sup>۴</sup> انجام می‌گیرد که نتایج آن در جدول ۳ نشان داده شده است. گفتنی است که ضریب R در رابطه<sup>۱</sup> (۱) نشان‌دهنده همبستگی پارامتر وابسته به پارامترهای مستقل است. به عبارت دیگر، نسبت تغییرات متغیر وابسته از متغیرهای مستقل پیش‌بینی‌شدنی است.

نشانگری انتخاب شود که با نشانگر قبلی کمترین خطای برآورد را دارد و این فرآیند تا مرحله‌ای ادامه پیدا می‌کند که به تعداد نشانگر مدنظر برسد. پس از آن، شمار بهینه نشانگرها بر پایه کاهش خطا و افزایش دقت برآورد انتخاب و سپس پارامترهای مرتبط با یکدیگر حذف می‌شود. در مرحله پایانی باید معناداربودن ارتباط نشانگر انتخاب‌شده با تداخل بررسی و از ارتباط صرفاً عددی بی‌معنی جلوگیری شود که Kalkomey از آن با عنوان «تفسیر بی‌فکر»<sup>۱</sup> یاد می‌کند (Kalkomey 1997). پس از انتخاب بهینه نشانگرها، اطلاعات چاه‌های استفاده‌شده از نظر پایداری و در محدوده مناسب بودن آن ارزیابی می‌شود تا اطلاعاتی به کار گرفته نشوند که باعث کاهش دقت عملکرد شبکه می‌شوند.

#### یافته‌ها

#### آماده‌سازی داده‌ها و واکاوی آنها

بر پایه توضیحات بیان‌شده، جدول ۱، پارامترهای بهینه نشانگرهای چندگانه را نشان می‌دهد که از روش سعی و خطا به دست آمده‌اند.

جدول ۱- پارامترهای بهینه‌شده چندنشانگر

Table 1- Multi Attributes' optimized parameters

Maximum Number of Attributes	۱۲
Operator Length	۶
Pre-Whitening	۰/۰۶
Operator Lag From Center	۴

براساس شکل ۳، آشکار شد که تعداد بهینه نشانگرهای بهره‌گیری‌شده ۶ عدد است؛ زیرا در بیش از این تعداد، نشانگر به قدری پیچیده می‌شود که تنها توانایی پیش‌بینی نوفه را دارد؛ از این رو شش نشانگر اولیه همان‌طور که در شکل ۴ نشان داده شده است، به‌عنوان نشانگرهای چندگانه انتخاب شدند.

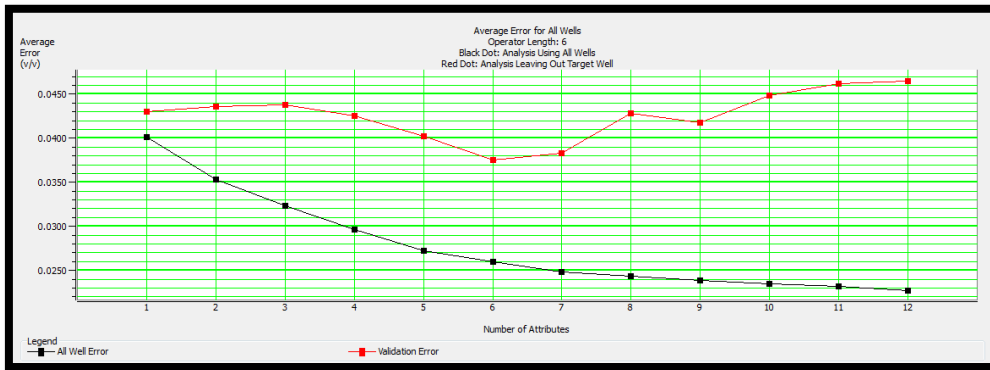
<sup>2</sup> Apparent Polarity

<sup>3</sup> Amplitude Envelope

<sup>4</sup> VIF (Variance Inflation Factor)

<sup>1</sup> Mindless Interpretation





شکل ۳- اعتبارسنجی چندنشانگر  
Fig 3- Multi attributes' validation

Final Attribute	Training Error	Validation Error
1 Filter 5/10-15/20	0.040267	0.043101
2 Integrate	0.035371	0.043717
3 Apparent Polarity	0.032444	0.043899
4 Amplitude Envelope	0.029706	0.042663
5 Raw Seismic	0.027294	0.040369
6 Y-Coordinate	0.026039	0.037584
7 Amplitude Weighted Frequency	0.024964	0.038367
8 Second Derivative Instantaneous Amplitude	0.024425	0.042914
9 Filter 45/50-55/60	0.023974	0.041909
10 Instantaneous Phase	0.023561	0.044988
11 Quadrature Trace	0.023306	0.046331

شکل ۴- سیاهه برگزیده چندنشانگر  
Fig 4- Multi attributes' list

جدول ۲- یافته‌های بررسی رابطه نشانگرها

Table 2- Results of attributes' investigation

	Porosity_Emerge	Filter_5-10_15-20	Integrate	Apparent_Polarity	Amplitude_Envelope	Raw_Seismic	Y_Cordinate
Porosity_Emerge	1						
Filter_5-10_15-20	0.226116794	1					
Integrate	0.698969779	-0.083577494	1				
Apparent_Polarity	0.217391618	0.788214912	0.009199894	1			
Amplitude_Envelope	0.452269511	0.559717451	0.27154519	0.640653823	1		
Raw_Seismic	0.170748206	-0.278566205	0.25702387	-0.26932401	-0.202469002	1	
Y_Cordinate	0.22200383	0.050075534	0.007777422	0.120111372	0.1233879	0.054740797	1

$$VIF = \frac{1}{1-R^2} \quad (1)$$

جدول ۳- VIF برای نشانگرهای وابسته

Table 3- VIF for dependent indicators

Attribute's Name	VIF
Amplitude Envelope	۲,۰۴۶۰۰۱۶۸۶
Filter 5/10-15/20	۲,۸۱۵۷۰۶۳۳۸
Apparent Polarity	۳,۱۶۳۲۸۸۸۴۴

**مرحله اول) تعیین مقدار مناسب تخصیص داده:** با توجه به تعداد کم داده‌های آموزشی، تلاش می‌شود که مقدار بهینه تخصیص داده شده بر پایه توجه به پایدار بودن روند کارکرد شبکه و کمترین خطای جذر میانگین مربعات<sup>۲</sup> در آموزش و آزمایش شبکه تعیین شود. شایان ذکر است که نقاط اطلاعاتی رسم شده، میانگین ۲۵ بار تکرار کارکرد شبکه در آن شرایط است؛

**مرحله دوم) تعیین تعداد نورون بهینه:** تعیین تعداد نورون بهینه بر پایه کاهش RMSE و افزایش ضریب رگرسیون<sup>۳</sup> است که در بخش آموزش و آزمایش انجام می‌گیرد. همواره افزایش شمار نورون باعث کاهش RMSE و افزایش R در قسمت آموزش می‌شود؛ اما از یک تعدادی نورون بیشتر در بخش آزمایش RMSE، افزایش و R نیز کاهش پیدا می‌کند که این نشان‌دهنده پدیده بیش‌برازش<sup>۴</sup> است. نزدیک‌ترین نقطه قبل از رخ دادن فرآیند بیش‌برازش نیز مدنظر است. شایان ذکر است که نتایج به کار رفته شده برای مقایسه کارکرد شبکه در شرایط مختلف، با میانگین ۱۵۰ بار تکرار به دست آمد.

پس از تنظیم و بهینه‌سازی شبکه ELM، باید عملکرد توابع فعال‌ساز مختلف بررسی شود. هرچه میزان خطای عملکرد شبکه کمتر باشد، دقت کارکرد شبکه بالاتر است، باید توجه داشت که هرچه بازه خطای کارکرد شبکه کوچک‌تر باشد، اعتمادپذیری آن نیز بیشتر است، به عبارت دیگر عملکرد شبکه پایدارتر است؛ از این رو تابع تحریک سینوسی به دلیل گستره خطایی کمتر و خطای برآورد کم، تابع فعال‌ساز پایانی انتخاب می‌شود. در جدول ۱۰ کارکرد شبکه ELM با بهره‌گیری از توابع فعال‌سازی سینوسی در دو چاه HD\_1 و HD\_6 نیز دیده می‌شود.

تنظیمات شبکه RBF همانند شبکه ELM بر پایه کاهش RMSE و افزایش R در قسمت آموزش و آزمایش است که از طریق روش سعی و خطا و به صورت پارامتر به پارامتر در نرم‌افزار Hampson\_Rusell تنظیم شده است. در جدول ۴ تمامی پارامترهای شبکه پایانی RBF مشاهده می‌شود.

از این رو، دو نشانگر فیلتر ۱۵/۲۰-۵/۱۰ و جهت‌یافتگی ظاهری به دلیل داشتن ارتباط بیشتر با دیگر نشانگرهای باقی‌مانده، حذف می‌شوند. در مرحله بعد از پدیده «تفسیر بی‌فکر» جلوگیری و به معنای نشانگرها توجه می‌شود؛ بنابراین نشانگرهای باقی‌مانده عبارت‌اند از:

- انتگرال داده لرزه‌ای: این نشانگر برای افزایش میزان فرکانس‌های کم و چرخش ۹۰- درجه‌ای فاز آن به کار می‌رود. باید توجه داشت که بهره‌گیری از این نشانگر برای شناسایی یک عارضه خاص، باعث کاهش وضوح داده‌ها می‌شود؛

- پوش دامنه لحظه‌ای: دامنه رد لرزه‌های پیچیده که با انجام تبدیل‌گر هیلبرت<sup>۱</sup> ایجاد می‌شود؛

- ستون داده لرزه‌ای: در واقع همان داده لرزه‌ای اصلی در محل چاه است؛

- مختصات عرض از مبدأ چاه: این نشانگر در واقع یک پارامتر ترسیمی و همان عرض از مبدأ، محل حفر چاه است.

با توجه به توضیحات گفته‌شده، انتگرال داده لرزه‌ای، پوش دامنه لحظه‌ای و ستون داده لرزه‌ای با تداخل رابطه معناداری دارد؛ زیرا سه نشانگر یادشده، نشان‌دهنده دامنه انرژی در مقابل تداخل است و از طرفی تداخل با میزان انرژی موجب در هر نقطه، رابطه معکوس دارد. اما نشانگر مختصات عرض از مبدأ، یک پارامتر ترسیمی است و هیچ رابطه معناداری با داده لرزه‌ای و تداخل ندارد؛ از این رو نشانگر یادشده حذف شد. در نتیجه نشانگرهای باقی‌مانده پس از ارزیابی نهایی عبارت‌اند از: انتگرال داده لرزه‌ای، پوش دامنه لحظه‌ای و ستون داده لرزه‌ای. در مرحله بعد، چاه‌ها باید تمام نقاط آموزش داده شده را واکاوی کنند. بر پایه نتیجه ارزیابی داده‌های آموزشی از نظر چاه، که نتایج آن در شکل ۵ آورده شده است، چاه HD\_7 به دلیل ناهمگنی موجود در آن، باعث افزایش ناپایداری در شبکه می‌شود؛ زیرا نتایج ارزیابی آن خطایی در حدود ۰/۰۵۵ دارد که نسبت به خطای دیگر چاه‌ها زیاده‌تر است؛ از این رو داده‌های چاه HD\_7 از مجموعه داده‌های آموزشی حذف شد.

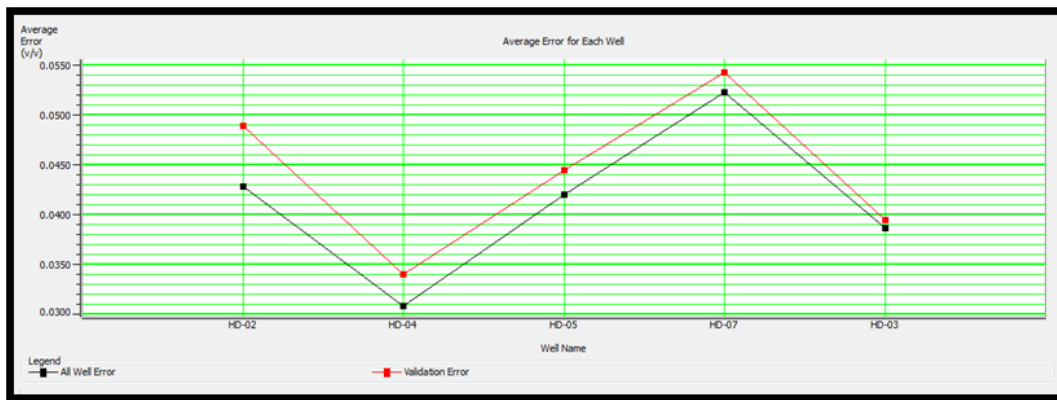
تنظیم شبکه ELM در دو مرحله انجام می‌گیرد:

<sup>2</sup> Root Mean Square Error (RMSE)

<sup>3</sup> Regression Coefficient (R)

<sup>4</sup> Over Fitting or Over Training

<sup>1</sup> Hilbert Transform



شکل ۵- یافته‌های ارزیابی داده‌های چاه  
Fig 5- Results of data well evaluation

تخلخل چاه HD\_6 در جدول ۶ نشان داده شده است. در این دو جدول، R نمایانگر همبستگی و RMSE نمایانگر خطای برآوردی است که ارزیابی شبکه‌ها با استفاده از ضریب رگرسیون و خطای RMSE انجام می‌گیرد، به این صورت که با بهره‌گیری از ضریب رگرسیون به توان شناسایی روند تغییرات پارامتر مدنظر و با بهره‌گیری از RMSE، به دقت و توان برآورد شبکه پی برده می‌شود. همان‌گونه که در جدول ۵ نشان داده شد، شبکه RBF نسبت به شبکه ELM، توان بیشتری در شناسایی روند تغییرات تخلخل دارد. همچنین، شبکه RBF نسبت به شبکه ELM توان و دقت بسیار بهتری در برآورد تخلخل دارد؛ زیرا خطای برآورد شبکه RBF بسیار کمتر از شبکه ELM در چاه HD\_1 است. از سوی دیگر، بر پایه جدول ۶، شبکه ELM نسبت به شبکه RBF، توان بیشتری در شناسایی روند تغییرات تخلخل در چاه HD\_6 دارد؛ اما توان برآورد شبکه RBF نسبت به شبکه ELM بسیار بیشتر است؛ از این رو نتیجه‌گیری می‌شود که شبکه ELM توزیع‌پذیری خوب و کارکردی مناسب در دسته‌بندی داده‌ها دارد، ولی شبکه RBF، توان بهتری در برآورد پارامترها دارد.

جدول ۵- مقایسه اجرای ELM و RBF در چاه HD\_1  
Table 5- Comparison of ELM and RBF operation in HD\_1

Network	RMSE	R
ELM	۰,۱۳۳	۰,۷۴۸
RBF	۰,۰۲۸	۰,۷۷۲

جدول ۶- مقایسه اجرای ELM و RBF در چاه HD\_6  
Table 6- Comparison of ELM and RBF operation in HD\_6

Network	RMSE	R
ELM	۰,۱۵۷	۰,۷۳۶
RBF	۰,۰۵۲	۰,۶۰۸

جدول ۴- پارامترهای پایانی RBF

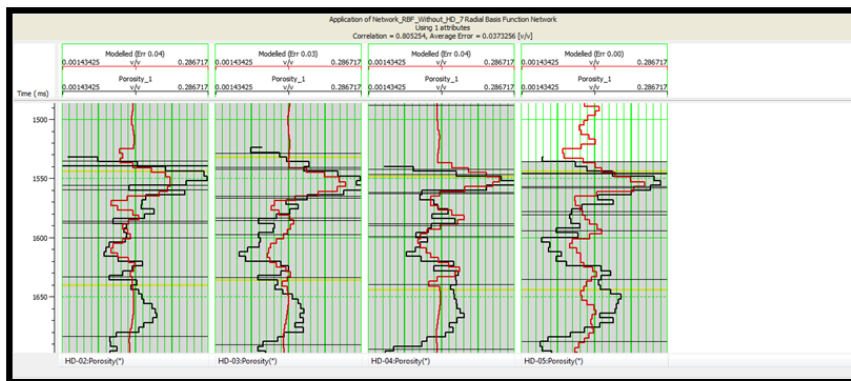
Table 4- Final parameters of RBF

Do you wish cascade with trend?	Yes
Smoothing Parameter	۵۹
Calculation of Sigma Parameter	Auto
Pre-Whitening	%۴۹
Do you want to use clustering?	No

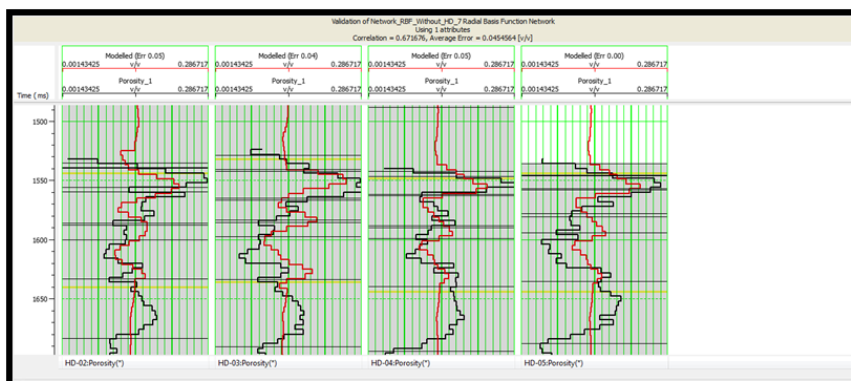
اعتبارسنجی شبکه RBF تنظیم شده بر پایه روش برکناری<sup>۱</sup>، از زیرشاخه‌های اعتبارسنجی متقابل<sup>۲</sup> است. این روش از اعتبارسنجی به صورت چاه به چاه انجام می‌شود، به این صورت که برای ارزیابی یک چاه، از دیگر چاه‌ها برای برآورد چاه مدنظر بهره‌گیری می‌شود؛ در نتیجه شبکه RBF طراحی شده دارای همبستگی ۰/۸۰ و خطای RMSE ۰/۰۳۷ در قسمت آموزش دسته داده‌های آموزشی (شکل ۶) و دارای همبستگی ۰/۶۷ و خطای RMSE ۰/۰۴۵ در قسمت اعتبارسنجی دسته داده‌های آموزشی است (شکل ۷)؛ از این رو شبکه RBF در بخش آموزش شبکه در دسته داده‌های آموزشی، روند و دقت برآورد بسیار خوبی دارد و از طرفی در بخش اعتبارسنجی، روند و خطای برآورد دقت پذیرفتنی دارد. همچنین شبکه RBF در برآورد تخلخل چاه HD\_1 دارای همبستگی ۰/۷۷ و خطای RMSE ۰/۰۲۸ (شکل ۸) و دارای همبستگی ۰/۶۱ و خطای RMSE ۰/۰۵۲ در برآورد تخلخل چاه HD\_6 است (شکل ۹). با توجه به نتایج به دست آمده، شبکه RBF طراحی شده توانایی مناسبی در شناسایی روند و برآورد تخلخل HD\_6 و HD\_1 دارد.

از این رو به صورت خلاصه، کارکرد دو مدل ELM و RBF در برآورد تخلخل چاه HD\_1 در جدول ۵ و برآورد

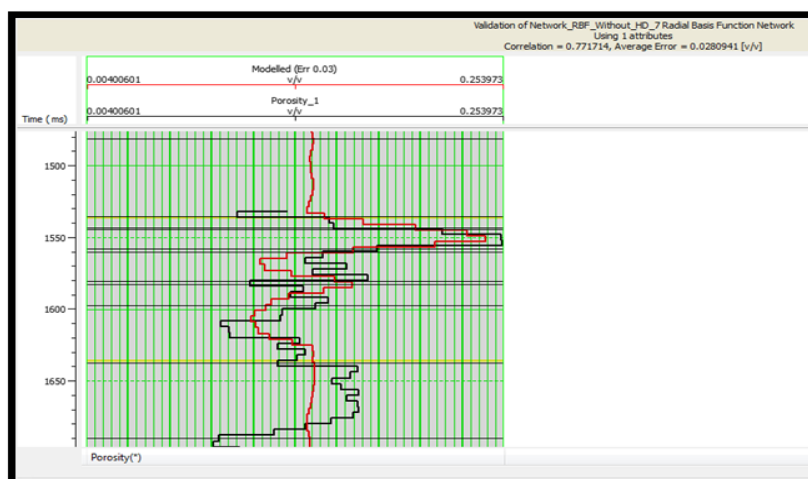
<sup>1</sup> Hold out  
<sup>2</sup> Cross Validation




شکل ۶- اجرای پایانی RBF در آموزش مجموعه داده‌ها  
**Fig 6- Final operation of RBF in Training dataset**



شکل ۷- اعتبارسنجی پایانی RBF در آزمایش مجموعه داده‌ها  
**Fig 7- Validation of Final RBF in Testing dataset**



شکل ۸- اجرای پایانی RBF در چاه HD-1  
**Fig 8- Operation of Final RBF in HD\_1**



شکل ۹- اجرای پایانی RBF در چاه HD-6

Fig 9- Operation of final RBF in HD\_6

طراحی شده دقت عملکردی بیشتری در برآورد تخلخل چاه HD\_1 نسبت به چاه HD\_6 دارند.

#### References

- Aghajariyan M. Kamali M.R. Kadkhodayi A. Fatho'lahi S. 2012. Estimation of effective permeability and porosity and determining hydraulic flow units using artificial neural network in Maron oil field: 15th conference of the Geological Society of Iran, Geotechnical Geology (Applied Geology), 8(3): 193-202. [In Persian]
- Asoodeh M. and Bagheripour P. 2013. Core porosity estimation through different training approaches for neural network: back-propagation learning vs. genetic algorithm. International Journal of Computer Applications, 63: 11-15.
- Avseth P. Mukerji T. Mavko G. and Dvorkin J. 2010. Rock-physics diagnostics of depositional texture, diagenetic alterations, and reservoir heterogeneity in high-porosity siliciclastic sediments and rocks— A review of selected models and suggested work flows. Society of Exploration Geophysicists, Geophysics Journal, 75: 75A31-75A47.
- Azarshab S. 2017. Reserve estimation of Kahang copper deposit using geophysical exploration data and extreme learning machine algorithm (ELM): Master Thesis, Imam Khomeini International University, Iran, 124. (In Persian)
- Beheshtian S. Rajabi M. Davoodi SH. Wood D.A. Ghorbani H. Mohamadian N. Ahmadi Alvar M. Band SH.S. 2022. Robust computational approach to determine the safe mud weight window using well-log data from a large gas reservoir. Marine and Petroleum Geology, 142: 105772.
- Brown A.R. 2001. Understanding seismic attributes. Society of Exploration Geophysicists, 66: 47-48.
- Cao J. Yang J. Wang Y. Wang D. and Shi Y. 2015. Extreme Learning Machine for Reservoir Parameter Estimation in Heterogeneous Sandstone Reservoir.

#### نتیجه

در مجموع، بر پایه یافته‌ها و توضیحات بیان شده، شبکه ELM نسبت به شبکه RBF، که نماینده‌ای از شبکه‌های عصبی معمول است، کارکرد ضعیف‌تری دارد؛ علت آن هم به ساختار ریاضیاتی و شمار نقاط اطلاعاتی به کار رفته شده وابسته است. شبکه ELM یک شبکه تک‌لایه پیش‌خور است که توان یادگیری ژرفی نسبت به مدل‌های چند لایه را ندارد؛ از این رو نسبت به تعداد نقاط اطلاعات به کار رفته شده به‌عنوان داده‌های آموزشی، به شمار نقاط اطلاعاتی بسیار بیشتری نیاز دارد. یکی از ویژگی‌های اصلی شبکه ELM، سرعت بالای پردازش داده‌هاست که خود گواه بر نیاز به شمار تعداد نقاط اطلاعاتی بسیار زیاد است. از طرفی شبکه ELM انعطاف‌پذیری بیشتری نسبت به شبکه RBF دارد؛ زیرا توابع تحریک<sup>۱</sup> مختلفی در آن بهره‌گیری می‌شود، این در حالی است که در مدل RBF تنها از تابع تحریک شعاع مبنای<sup>۲</sup> بهره‌گیری می‌شود.

شایان ذکر است که علت تفاوت در دقت برآورد تخلخل دو چاه، جایگاه جغرافیایی آنها در میدان نفتی است، به این صورت که چاه HD\_1 در مرکز میدان به‌گونه‌ای است که چاه‌های آموزشی در اطراف آن قرار دارند، اما چاه HD\_6 خارج و به دور از چاه‌های آموزشی است. در واقع شبکه‌های

<sup>1</sup> Activation Function

<sup>2</sup> Radial Basis

- using rigorous data-driven techniques. *Journal of Petroleum Science and Engineering*, 208: part D, 109685.
- Malami S.I. Anwar F.H. Abdulrahman S. Haruna S.I. Albrka Ali SH.I. and Abba S.I. 2021. Implementation of hybrid neuro-fuzzy and self-turning predictive model for the prediction of concrete carbonation depth: A soft computing technique. *Results in Engineering*, 10: 100228.
- Malvic T. and Prskalo S. 2007. Some Benefits of the Neural Approach in Porosity Prediction-Case Study from Benicanci Field. *Nafta: exploration, production, processing, petrochemistry*, 58: 455-467.
- Mehrad M. Ramezanzadeh A. Bajolvand M. Hajsaeedi M.R. 2022. Estimating shear wave velocity in carbonate reservoirs from petrophysical logs using intelligent algorithms. *Journal of Petroleum Science and Engineering*, 212: 110254.
- Naimi S.R. Shadizadeh S.R. Riahi M.A. and Mirzakhani M. 2014. Estimation of reservoir porosity and water saturation based on seismic attributes using support vector regression approach. *Journal of Applied Geophysics*, 107: 93-101.
- Nelson P.H. 1994. Permeability-porosity relationships in sedimentary rocks. *Society of Petrophysicists and Well-Log Analysts*, 35: 38-62.
- Obeida T.A. Al-Mehairi Y.S. and Suryanarayana K. 2005. Calculations of Fluid Saturations from Log-Derived J-Functions in Giant Complex Middle-East Carbonate Reservoir. *SPE* 95169.
- Raeisi M. 2008. Application of Artificial Neural Networks in Facies Change Prediction for Hydrocarbon Reservoirs. M.Sc. Thesis, Shahrood University of Technology, Iran, 189 (In Persian).
- Reddy G.V. Kumar P. Naik S.B.R. Murthy G.N. Vandana Kaul S.K. and Bhowmick P.K. 2004. Reservoir characterization using multi seismic attributes in B-172 area of Heera-Panna-Bassein Block of Bombay Offshore Basin, India. 5th Conference & Exposition on Petroleum Geophysics, Hyderabad, 716-721.
- Russell B.H. 2004. The Application of Multivariate Statistics and Neural Networks to the Prediction of Reservoir Parameters Using Seismic Attributes: Ph.D. Thesis, University of Calgary. Canada, 392.
- Siripitayananon P. Chen H.C. and Hart B.S. 2001. A new technique for lithofacies prediction: back-propagation neural network: Proceedings of ACMSE. The 39th Association of Computing and Machinery South Eastern Conference, 31-38.
- Wu F. Li J. Geng W. Tang W. Chen X. and Zhao W. 2023. Predicting anisotropic parameters of strata by deep multiple triangular kernel extreme learning machine optimized by flower pollination algorithm. *Journal of Applied Geophysics*, 209: 104904.
- Yazdanian J. and Noori B. 2007. Geological final report-well HD\_7. Iranian Offshore Oil Company, 57.
- Hindawi Publishing, Article ID: 287816, 10 pages.
- Chopra S. and Marfurt K.J. 2005. Seismic attributes- A historical perspective. *Society of Exploration Geophysicists. Geophysics Journal*, 70: 3SO-28SO.
- Edalat A. and Siyahkoochi H. 2007. Using seismic facies in characterizing one of the Iranian hydrocarbon reservoirs. *Iranian Geophysics Journal*, 1: 37-49.
- Ezekwe J.N. 2003. *Applied Reservoir Management Principles with Case Histories*. SPE 84148, Colorado, October 5-8.
- Gholami A. and Ansari H.R. 2017. Estimation of porosity from seismic attributes using a committee model with bat-inspired optimization algorithm. *Journal of Petroleum Science and Engineering*, 152: 238-249.
- Heydari Gholanlo H. Amirpour M. and Ahmadi S. 2016. Estimation of water saturation by using radial based function artificial neural network in carbonate reservoir: A case study in Sarvak formation. *Petroleum Journal*, 2: 166-170.
- Hosseini A. Ziaei M. Kamkar R.A. Roshandel A. Gholami R. and Hanachi J. 2011. Artificial intelligence for prediction of porosity from seismic attributes: case study in the Persian Gulf. *Iranian Journal Earth Science*, 3: 168-174.
- Huang G.B. Zhu Q.Y. and Siew C.K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70: 489-501.
- Iturrarán-Viveros U. and Parra J.O. 2014. Artificial Neural Networks applied to estimate permeability, porosity and intrinsic attenuation using seismic attributes and well-log data. *Journal of Applied Geophysics*, 107: 45-54.
- Jafarizadeh F. Rajabi M. Tabasi S. Seyedkamali R. Davoodi SH. Ghorbani H. Ahmadi Alvar M. Radwan A.E. Csaba M. 2022. Data driven models to predict pore pressure using drilling and petrophysical data. *Energy Reports*, 8: 6551-6562.
- Kalkomey C.T. 1997. Potential risks when using seismic attributes as predictors of reservoir properties. *The Leading Edge*, 16: 247-251.
- Kamali M.Z. Davoodi SH. Ghorbani H. Wood D.A. Mohamadian N. Lajmorak S. Rukavishnikov V.S. Taherizade F. B. and SH.S. 2022. Permeability prediction of heterogeneous carbonate gas condensate reservoirs applying group method of data handling. *Marine and Petroleum Geology*, 139: 105597.
- Khoshdel H. and Riahi M.A. 2011. Multi attribute transform and neural network in porosity estimation of an offshore oil field — A case study. *Journal of Petroleum Science and Engineering*, 78, 740-747.
- Lawrence P. 1998. Seismic attributes in the characterization of small-scale reservoir faults in Abqaiq Field. *The Leading Edge*, 17: 521-525.
- Mahdaviara M. Larestani A. Amar M.N. and Hemmati-Sarapardeh A.H. 2022. On the evaluation of permeability of heterogeneous carbonate reservoirs