

# مقایسه کارکرد شبکه‌های عصبی مرسوم برای برآورد تخلخل در یکی از

## میدان‌های نفتی جنوب خاوری ایران

فرشاد توفیقی، گروه مهندسی نفت و معدن، دانشگاه بین‌المللی امام خمینی، قزوین

پرویز آرمانی\*، گروه زمین‌شناسی، دانشگاه بین‌المللی امام خمینی، قزوین

علی چهارزی، مدیریت طرح‌های اکتشافی، شرکت نفت فلات قاره ایران، تهران

اندیشه علیمرادی، گروه مهندسی نفت و معدن، دانشگاه بین‌المللی امام خمینی، قزوین

armani@sci.ikiu.ac.ir

### چکیده

در صنعت نفت از هوش مصنوعی برای شناسایی روابط، بهینه‌سازی، برآورد و رده‌بندی تخلخل بهره‌گیری می‌شود. یکی از مهم‌ترین مراحل ارزیابی پارامترهای پتروفیزیکی مخزن، شناسایی ویژگی‌های تخلخل است. هدف اصلی این پژوهش مقایسه درستی و تعمیم‌پذیری سه شبکه عصبی چند لایه پیش‌خور (MLFN)، شبکه تابع شعاع مبنا (RBFN) و شبکه عصبی احتمالی (PNN) برای برآورد تخلخل با بهره‌گیری از ویژگی‌های لرزه‌ای است. در این راستا، داده‌های زمین‌شناسی ۷ حلقه چاه یک میدان نفتی فراساحلی هندیجان در شمال باختری حوضه خلیج فارس مورد ارزیابی قرار گرفت. امیدانس آکوستیک با بهره‌گیری از روش وارونگی مبتنی بر مدل برآورد شد و سپس شبکه‌های عصبی یاد شده با بهره‌گیری از ویژگی‌های لرزه‌ای بهینه طراحی شده و با روش رگرسیون گام به گام مورد ارزیابی قرار گرفتند. سرانجام مشخص شد که مدل MLFN برای برآورد تخلخل خوب عمل نمی‌کند. PNN از بهترین دقت کارکرد در درون‌یابی تخلخل برخوردار است، اما تعمیم‌پذیری RBFN بهتر است.

**واژه‌های کلیدی:** برآورد تخلخل، بازگردانی لرزه‌ای، MLFN، RBFN، PNN

### پیشگفتار

هوش مصنوعی یک ابزار ریاضیاتی بر پایه پردازش موازی است که امروزه، بهره‌گیری از آن در صنعت نفت برای شناخت روابط غیرخطی، بهینه‌سازی، برآورد پارامترهای کمی و همچنین، دسته‌بندی پارامترهای کیفی نیز رواج بسیاری یافته است [۵، ۹، ۱۵]. بهره‌گیری از این روش باعث افزایش دقت کار و کاهش هزینه و زمان می‌شود [۱].

تخلخل یکی از مهم‌ترین ویژگی‌های پتروفیزیکی سنگ مخزن است، چرا که در محاسبات حجمی نفت موجود در مخزن [۳]، محاسبات اشباع سیالات، توصیف مخزن [۸]، شناسایی واحدهای جریان در محیط‌های ناهمگن [۱۲]، بررسی‌های اقتصادی پروژه [۷]، به‌عنوان یکی از مهم‌ترین پارامترهای مخزنی در نرم‌افزارهای شبیه‌ساز [۲۶]، مشخص کردن فشار نقاط مختلف مخزن به منظور کاهش خطر حفاری [۱۳] و همچنین، تعیین الگوهای جریان هیدروکربن‌های مختلف [۱۰ و ۱۸] کاربرد دارد. در آغاز تخلخل از راه بررسی مستقیم مغزه تهیه‌شده در آزمایشگاه‌ها مانند وزن کردن مستقیم نمونه، قوطه‌وری، روش‌های نوری، اسکن توموگرافی کامپیوتری<sup>۱</sup> و روش انبساط گازی به‌دست می‌آیند که اگرچه این روش‌ها دقیق‌ترین و قابل اعتمادترین روش‌ها هستند اما نیازمند صرف زمان و هزینه بسیار بوده و از طرفی، اطلاعات به‌دست آمده از این روش‌ها گسسته می‌باشند. از این‌رو، از روش‌های چاه‌نگاری استفاده کردند. در این روش، از نمودارهای چگالی، صوتی، نوترون و در مراحل پیشرفته‌تر نیز از نمودارهای رزونانس مغناطیسی هسته‌ای<sup>۲</sup> استفاده می‌شود که چون روش غیرمستقیم است، نسبت به روش مستقیم دقت کمتری دارد اما دارای پیوستگی اطلاعات است. اما نکته‌ای که در مورد روش‌های یادشده باید توجه داشت این است که این روش‌ها نیازمند صرف زمان و هزینه بسیار برای حفر چاه است [۱۷]. از این‌رو، امروزه استفاده از هوش مصنوعی برای افزایش دقت کاوش‌های سطحی بدون نیاز به حفر چاه گسترش یافته است. از برتری‌های روش پیشنهاد شده نیز می‌توان به پیوسته‌بودن داده‌های به‌دست آمده اشاره کرد. البته داده‌های به‌دست آمده تنها در محل چاه و پیرامون آن درست است [۸]. امروزه برای مدل‌سازی سه‌بعدی، افزون بر داده‌های چاه‌نگاری، از داده‌های لرزه‌ای سه‌بعدی نیز بهره‌گیری می‌شود. داده‌های لرزه‌ای، سری‌های زمانی سه‌بعدی می‌باشند که زمان عبور موج در هر بخش از سازند را نشان می‌دهند [۴]. در هنگام برداشت‌های لرزه‌ای امواجی با فرکانس بالا میرا می‌شوند که در مدل‌سازی سه‌بعدی کوشش می‌شود با بهره‌گیری از داده‌های چاه‌نگاری، از جمله نمودار صوتی، این داده‌های لرزه‌ای احیا و شبیه‌سازی شوند و سپس با بهره‌گیری از موجک استخراج شده به مدل‌سازی بازگردانی<sup>۳</sup> ویژگی‌های پتروفیزیکی زیرسطحی از جمله سرعت موج برشی<sup>۴</sup>، سرعت موج فشردگی<sup>۵</sup> و امپدانس صوتی ویژه (که توسط ضرب چگالی در سرعت امواج لرزه‌ای نیز به‌دست می‌آید) نیز پرداخته می‌شود [۲۲].

امپدانس صوتی یکی از مهم‌ترین نشان‌گرهای لرزه‌ای است که با ویژگی‌های پتروفیزیکی به ویژه تخلخل رابطه‌ای معنادار دارد و به‌صورت پل ارتباطی میان ویژگی‌های پتروفیزیکی و ویژگی‌های کشسان<sup>۶</sup> است [۱۴ و ۱۸]. نشان‌گرهای لرزه‌ای اطلاعات لرزه‌ای هستند که به‌صورت مستقیم و غیرمستقیم از راه انجام روابط ریاضیاتی پیچیده بر روی داده لرزه‌ای ایجاد می‌شوند [۲۳]. در نتیجه استخراج داده‌ها از نشان‌گرهای لرزه‌ای کمک شایانی در برآورد ویژگی‌های فیزیکی مخزن‌ها می‌کند [۶]. همچنین، لازم به یادآوری است که در بسیاری از مواقع به‌دلیل ناهمگن بودن منطقه، چه به‌صورت عمودی و

---

<sup>۱</sup>Computerized Tomography Scan (CT Scan)

<sup>۲</sup>Nuclear Magnetic Resonance (NMR)

<sup>۳</sup>Inversion

<sup>۴</sup>Shear Wave Velocity (VS)

<sup>۵</sup>Pressure Wave Velocity (VP)

<sup>۶</sup>Elastic

چه به صورت افقی، ایجاد رابطه‌ای عددی میان امپدانس صوتی و تخلخل با روش‌های مرسوم آماری و بدون بهره‌گیری از هیچ‌گونه تابعی نیز امکان‌پذیر ناست. بنابراین، برای برآورد تخلخل نیاز به یک مدل سطح بالا و هوشمند است [۲].

پرکاربردترین زمینه مطالعاتی هوش مصنوعی با بهره‌گیری از امپدانس صوتی، برآورد و ارزیابی ویژگی‌های پتروفیزیکی مانند تخلخل، تراوایی، اشباع آب، حجم شیل، میزان آب موجود و در نتیجه، شناسایی واحدهای جریان‌ی در محیط‌های ناهمگن است [۱۱]. هدف اصلی از این پژوهش مقایسه دقت و تعمیم‌پذیری سه مدل مرسوم شبکه عصبی، یعنی شبکه عصبی پیش‌خور چند لایه<sup>۱</sup>، شبکه تابع شعاع مینا<sup>۲</sup> و شبکه عصبی احتمالی<sup>۳</sup> در برآورد تخلخل با بهره‌گیری از امپدانس صوتی و سایر نشان‌گرهای لرزه‌ای به دست آمده از برازش گام‌به‌گام در سازند آسماری است.

## روش کار

این پژوهش، یک پژوهش داده محور است که شامل داده‌های زمین‌شناسی ۷ چاه موجود در یکی از میدان‌های نفتی ایران واقع در شمال باختری خلیج فارس است (شکل ۱). این میدان از نظر ساختاری یک تاقدیس کوچک با روند شمالی-جنوبی است [۲۴]. دو چاه HD\_1 و HD\_6 بر پایه جایگاه جغرافیایی آن‌ها به عنوان داده‌های ناشناخته در نظر گرفته شده‌اند (شکل ۲). هدف از بهره‌گیری از چاه‌های HD\_1 و HD\_6 نیز به ترتیب شناسایی دقت و قدرت تعمیم‌پذیری مدل‌های مورد نظر است. در این پژوهش، سازند آسماری مورد بررسی قرار گرفت. شمار نقاط اطلاعاتی از ۲۵ تا ۳۰ عدد بود.




شکل ۱ جایگاه میدان نفتی مورد بررسی [۲۷]

<sup>۱</sup>Flow Units

<sup>۲</sup>Multi-layer Feed Forward Neural Network (MLFN)

<sup>۳</sup>Radial Basis Function Network (RBFN)

<sup>۴</sup>Probabilistic Neural Network (PNN)

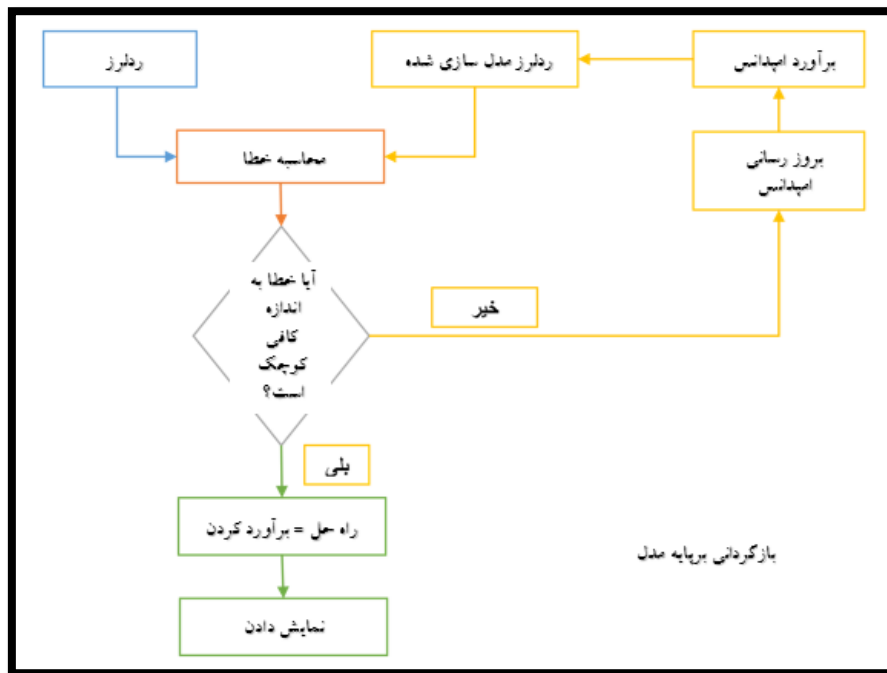


شکل ۲ جایگاه چاه‌های نفتی مورد بررسی

این پژوهش بر کاربرد تکنیک شبکه عصبی مصنوعی در برآورد تخلخل سازند آسماری با بهره‌گیری از نشان‌گرهای لرزه‌ای پس از برانبارش و داده‌های چاه‌نگاری استوار است. نمودارهای تخلخل، صوتی و چگالی برای همه چاه‌ها و داده‌های تصحیح برداشت آنها در چاه‌های HD\_6 و HD\_7 موجود بود.

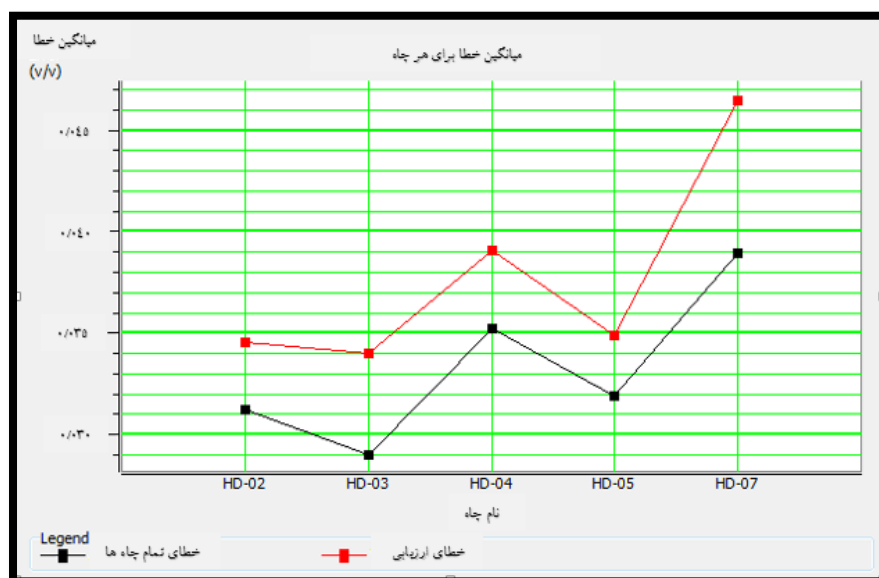
نخستین گام برای آماده‌سازی داده‌های ورودی هم حوزه نمودن آنها بود، چرا که داده‌های چاه‌نگاری ماهیت مکانی و داده‌های لرزه‌ای ماهیت زمانی دارند. بدین منظور با بهره‌گیری از داده‌های تصحیح برداشت به‌عنوان یک تابع زمان-عمق، تمامی داده‌های چاه‌نگاری به حیطه زمان منتقل شد. پس از آن با بهره‌گیری از فرآیند همبستگی (تطابق) دستی، سعی در افزایش همبستگی به منظور قرار گرفتن ضرایب بازتاب‌در محل درست خود و همچنین، استخراج موجک میانگین برای ساخت ردلرزه‌های مصنوعی در محل چاه‌ها انجام گرفت. باید خاطر نشان شد که در تطابق دستی کوشش شده است که در ابتدا با جابه‌جایی و سپس با ایجاد کشیدگی و فشردگی در داده‌های جدید ایجاد شده بیشترین تطابق انجام گیرد.

در این پژوهش از روش بازگردانی برپایه مدل<sup>۳</sup> برای مدل‌سازی بازگردانی امپدانس صوتی در کل پیکره سه‌بعدی سازند آسماری بهره‌گیری شد. در بازگردانی بر پایه مدل کوشش می‌شود که در آغاز یک مدل زمین‌شناسی، به‌عنوان مدل اولیه، ساخته و سپس به مقایسه آن با داده‌های لرزه‌ای واقعی پرداخته شود. شکل ۳ اساس نظریه بازگردانی بر پایه مدل به‌صورت شمای عملیاتی را نشان داده شد.



شکل ۳ شمایی عملیاتی از نظریه بازگردانی بر پایه مدل [۲۲]

در آغاز پیش از انتخاب نشان‌گرهای چندگانه بهینه، باید داده‌های ورودی را نسبت به هر چاه مورد بررسی و ارزیابی قرار داد. از اینرو از تکنیک "پنهان کردن" بهره‌گیری شد. این روش به این صورت است که چاه مورد نظر (در پژوهش‌های آینده نشان‌گرها و نقاط اطلاعاتی) نیز نادیده گرفته می‌شود و با بهره‌گیری از دیگر چاه‌ها به برآورد آن چاه پرداخته می‌شود. هر چه دقت کار کمتر و یا به عبارت دیگر، خطای بررسی بیشتر باشد، چاه مورد نظر باعث ناپایداری مدل‌سازی می‌شود. پس همان‌گونه که در شکل ۴ نشان داده شد، داده‌های چاه HD\_7 باعث ناپایداری مدل‌سازی می‌شود، بنابراین داده‌های این چاه از دسته داده‌های آموزشی نیز حذف شد.

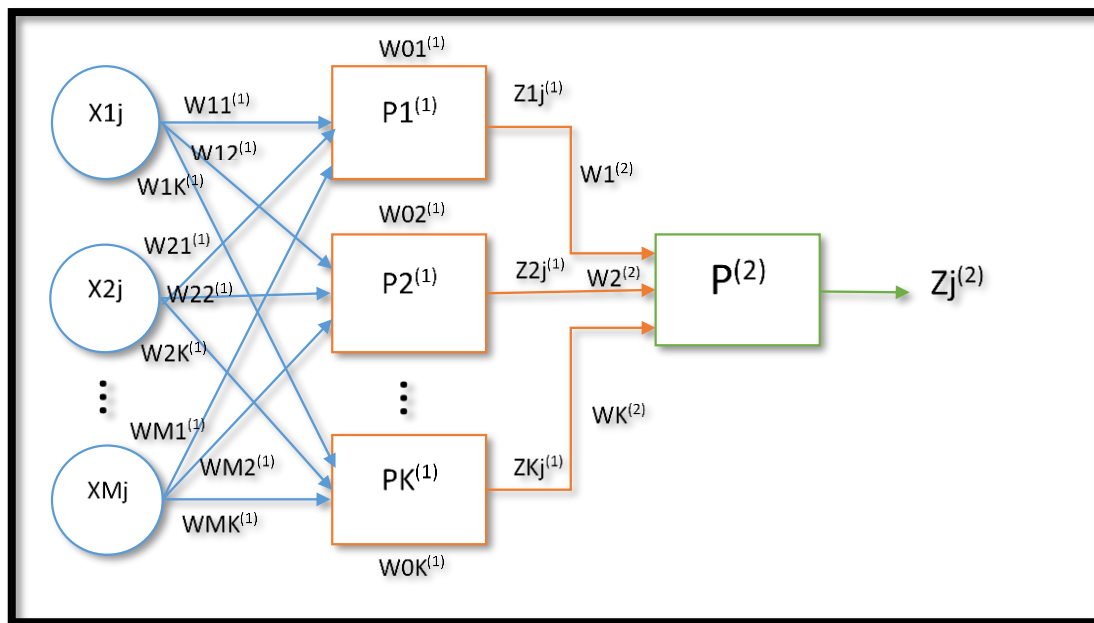


شکل ۴ نتیجه ارزیابی داده‌ها بر پایه چاه‌ها

در این پژوهش از روش برازش گام به گام برای انتخاب تعداد بهینه نشان‌گرهای چندگانه بر پایه نشان‌گرهای تکی، بهره‌گیری شد. در این روش ابتدا تک نشان‌گری که دارای کمترین خطای برآورد تخلخل است انتخاب شده و سپس کوشش شد با بهره‌گیری از روش آزمون و خطا به جست و جو جفت نشان‌گری که دارای کمترین خطای برآورد باشد، پرداخته شود. این فرآیند تا رسیدن به بیشترین تعداد نشان‌گرها نیز ادامه می‌یابد. برتری این روش، سرعت بالا در پردازش است که البته از کاستی‌های این روش می‌توان به از دست دادن بهترین جفت نشان‌گرهایی که ممکن است دارای خطای بالا در برآورد تخلخل به صورت تکی می‌باشند نیز اشاره کرد. نیاز به یادآوری است که منظور از خطا در این بخش، خطای جذر میانگین مربعات است و شمار ۱۶۰ نشان‌گر مورد بررسی قرار گرفت.

### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی و یا سیستم پیوندگرا، یک سیستم محاسباتی مبهم است که از شبکه عصبی زیستی الگوبرداری شده است. به علت مبهم بودن کارکرد و محاسبات انجام گرفته در آن، این سیستم را به اصطلاح جعبه سیاه می‌نامند [۱۶]. شبکه عصبی پیش‌خور چندلایه یا MLFN، یک شبکه عصبی کلاسیک بوده که به عنوان یک شبکه چندلایه ادراکی نیز نام برده می‌شود. این مدل قابلیت حل مشکلات غیرخطی را دارد که البته از کاستی‌های آن نیز می‌توان وابستگی بیش از حد جواب پایانی به حدس اولیه وزن‌های تنظیم شده اشاره کرد. در شکل ۵ نیز ساختار شبکه چند لایه با  $M$  ورودی و  $K$  تا  $K^3$  نیز نشان داده شد.



شکل ۵ شمای عملیاتی از شبکه MLFN با  $M$  ورودی و  $K$  گره [۲۱]

Black Box  
Multi-layer Perceptron (MLP)  
Neuron

همواره نخستین لایه در MLFN نیز لایه ورودی و آخرین لایه نیز لایه خروجی نامیده می‌شود. لایه‌های موجود در بین لایه‌های ورودی و خروجی نیز لایه‌های نهان نامیده می‌شوند که شمار آن‌ها می‌تواند از یک تا هر مقداری باشد که یک عدد لایه نهان با تعداد بهینه گره وجود دارد. در بیشتر مواقع، برای بررسی موارد مطالعاتی با تعداد محدود نقاط اطلاعاتی و یا برای روابطی که دارای ویژگی‌های محدود و نامحدود می‌باشند، مدل سه لایه‌ای نیز پاسخ‌گو است [۲۰]. ورودی‌های شبکه MLP نیز برداری با  $M$  نشان‌گر است که مقدار آن به صورت  $x^T_j = [x_{1j}, x_{2j}, \dots, x_{Mj}]$  است که در آن  $j = 1, \dots, N$  و  $z_j = 1$  یا به دیگر سخن، تعداد نمونه‌های لرزه‌ای است. خروجی حاصل از لایه اول با اعمال وزن به ورودی به صورت رابطه ۱ نوشته می‌شود.

$$y^{(1)}_k = \sum_{i=0}^M W^{(1)}_{ki} \cdot x_{ij} = W^{(1)T} \cdot x_j, k = 1, 2, \dots, K \quad (1)$$

$$y^{(2)}_j = \sum_{k=0}^K w^{(2)}_{kj} \cdot z^{(1)}_k = w^{(2)T} \cdot z^{(1)}, j = 1, 2, \dots, N$$

همچنین، ورودی لایه نهان یک مدل سه لایه‌ای نیز به صورت رابطه ۲ نوشته می‌شود:

$$y^{(2)}_j = \sum_{k=0}^K w^{(2)}_{kj} \cdot z^{(1)}_k = w^{(2)T} \cdot z^{(1)}, j = 1, 2, \dots, N \quad (2)$$

که در رابطه ۲ نیز  $z^{(1)}_k$  نیز خروجی حاصل از لایه اول است. در شبکه‌های MLP یکی از پر کاربردترین توابع تحریک<sup>۱</sup> نیز تابع Logistic است که خروجی آن را بین  $+1$  و  $-1$  نیز محدود می‌کند. رابطه ریاضیاتی آن در رابطه ۳ نشان داده شده است:

$$f(x) = \text{Logist}(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

خروجی پایانی شبکه MLP با دو لایه را که در شکل ۴ نمایش داده است نیز می‌توان به صورت رابطه ۴ نوشت:

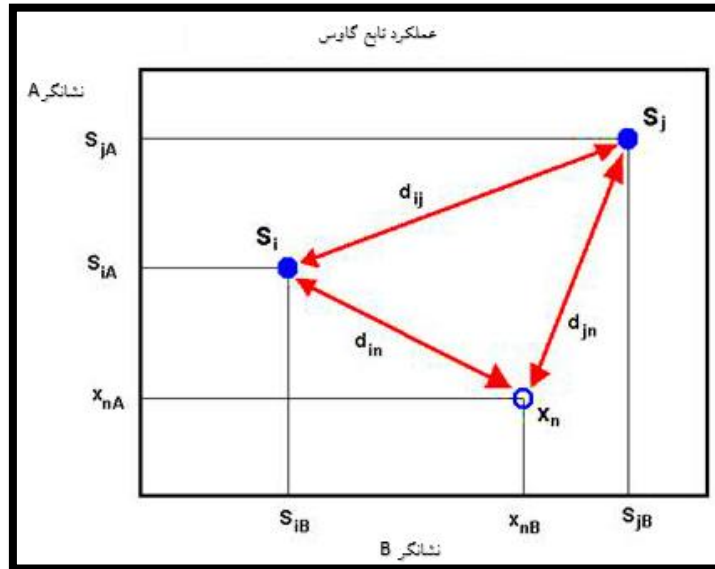
$$z^{(2)}_j = f^2(w^{(2)T} \cdot f^{(1)}(w^{(1)T} \cdot x_j)) \quad (4)$$

وزن شبکه براساس خطای پسا انتشاری که توسط الگوریتم محاسبه می‌شود، تعیین می‌شود. به  $f^2(w^{(2)T} \cdot f^{(1)}(w^{(1)T} \cdot x_j))$  نیز  $z^{(2)}_j$  در صورت که با افزایش و کاهش اوزان مختلف کوشش می‌شود که خطای برآورد به کمترین مقدار خود برسد [۲۱].

شبکه شعاع مبنا (RBF) برای درون‌یابی دسته داده‌هایی در فضای غیرخطی طراحی شده است [۲۰]. در مدل‌سازی ریاضیاتی، شبکه تابع شعاع مبنا نیز یک شبکه عصبی مصنوعی پیش‌خور<sup>۲</sup> با تابع تحریک شعاع مبنا است که بر پایه تئوری منظم‌سازی<sup>۳</sup>

<sup>۱</sup>Activation Function  
<sup>۲</sup>Feed Forward  
<sup>۳</sup>Regularization

و از تابع گاوسی<sup>۱</sup> به عنوان تابع تحریک اصلی نیز بهره‌گیری می‌کند که در آن از فواصل به عنوان "نشان‌گر فضایی" بهره‌برداری می‌شود [۱۹]. فرض کنید دو نمونه  $S_i$  و  $S_j$  وجود داشته باشد، می‌توان آن‌ها را به یک نمونه ناشناخته  $X_n$  مرتبط کرد به طوری که  $X_n$  به صورت شکل ۶ تعریف شده باشد.



شکل ۶ برآورد نمونه ناشناخته  $X_n$  توسط دو نمونه  $S_i$  و  $S_j$  [۲۱]

RBF نیز همانند شبکه عصبی احتمالی برای هر داده آموزشی یک وزن شناسایی می‌کند که تمامی وزن‌ها توسط تابع گاوس در نشان‌گرهای فاصله ضرب می‌شوند. بنابراین خواهیم داشت:

$$y = \sum_{i=1}^n W_i \cdot \phi_i \quad (5)$$

در رابطه ۵، باید توجه داشت که در برخی از منابع از  $g$  به جای  $\phi$  استفاده می‌شود. توابع غیرخطی  $\phi_j$  نیز توابع "پایه" نامیده می‌شوند. از نظر ریاضیاتی، تابع پایه عبارت است از:

$$\phi_{jk} = \exp\left[-\frac{d_{jn}^2}{\sigma^2}\right], d_{jn} = [X_n - s_j] \quad (6)$$

که در رابطه ۶ نیز  $\sigma$ ، پارامتر سیگما و یا به عبارت دیگر، پارامتر هموارسازی<sup>۳</sup> است. باید توجه شود که  $\frac{d_{jn}^2}{\sigma^2}$  نیز فاصله مقیاسی بین نمونه‌ای مجهول یعنی  $X_n$  و نقطه اطلاعاتی معلوم  $S_j$  است. پس برخلاف مدل PNN، پارامتر هموارکننده بر مقیاس تأثیرگذار است. پس تابع شعاع مبنا یک تابعی است که با فاصله گرفتن از مرکز، یکنواختی پاسخ آن کاهش می‌یابد.

<sup>۱</sup>Gaussian Function  
<sup>۲</sup>Basis  
<sup>۳</sup>Smoothing



[۲۵]. خروجی شبکه، یک ترکیب خطی توابع شعاع مبنا ورودی و پارامترهای نورون است که محاسبات برآورد پارامتر مورد نظر نیز به صورت زیر نوشته می شود:

$$y(Xa) = \sum_{j=1}^n W_j \cdot \phi_n j, n = 1, 2, \dots, M \quad (7)$$

که در رابطه ۷،  $X_n$  تعریف نشده و  $M$  نیز شمار پارامترهای تعریف نشده است. از این رو،  $W_j$  یک وزن بر پایه فاصله بین نقطه مورد نظر و نقاط آموزشی است.

شبکه عصبی احتمالی در اختصار PNN یک شبکه عصبی است که با اعمال پنجره پارزن<sup>۱</sup> بر داده‌ها نیز عمل می کند. از شبکه PNN همواره می توان برای برآورد داده‌های پیوسته و یا گسسته و همچنین برای مشخص کردن رابطه میان داده‌های ورودی و خروجی، به عنوان یک روش سریع و مطمئن بهره گیری کرد. اگر بردار  $x_i$  به عنوان ورودی شبکه PNN تعریف شده باشد در آن صورت خروجی  $On(x_i)$  نیز از طریق جمع خطی  $n$  نقطه اطلاعاتی در بخش آموزش بر پایه رابطه ۸ نیز به دست می آید.

$$On(x_i) = \frac{\sum_{i=1}^n On_i \cdot \exp(-D(x, P_{xi}))}{\sum_{i=1}^n \exp(-D(x, x_i))} \quad (8)$$

که در رابطه ۸،  $D(x, x_i)$  فاصله بین داده ورودی  $x$  با هر یک از داده‌های آموزشی آن است که از طریق رابطه ۹ نیز به دست می آید.

$$D(x, x_i) = \sum_{j=1}^k \left( \frac{x_j - x_{ij}}{p_j} \right)^2 \quad (9)$$

که در رابطه ۹،  $k$  تعداد نقاط اطلاعاتی ورودی است و همچنین،  $p_j$  فاکتور مقیاس فاصله<sup>۲</sup> برای هر یک از نشان‌گرهای ورودی است که تنها پارامتر PNN است که نیاز به تنظیم شدن دارد. این شبکه در مقایسه با دیگر شبکه‌های عصبی مصنوعی، مانند MLP که دارای پارامترهای بسیاری برای تنظیم شدن هستند، بسیار راحت تر، سریع تر و مؤثرتر تنظیم می شود [۲۱]. مقدار بهینه  $p_j$  در شرایط کمترین مقدار خطا نیز به دست می آید که در این حالت، نمونه مورد نظر خارج شده و کوشش می شود که با بهره گیری از دیگر نمونه‌ها به برآورد نمونه مورد نظر پرداخته شود و سپس با تکرار این فرآیند برای دیگر

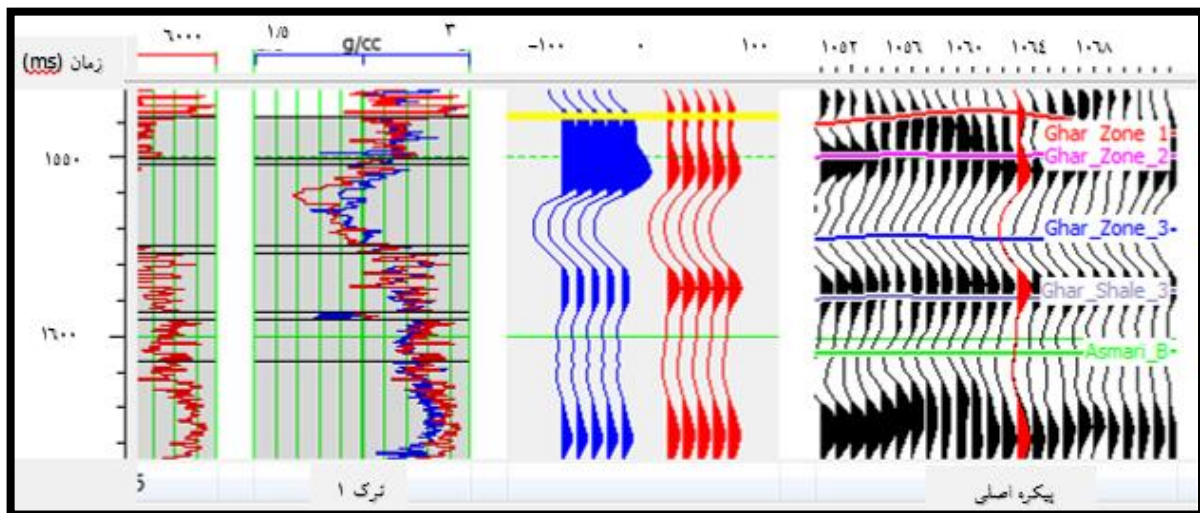
---

<sup>۱</sup>Parzen Window  
<sup>۲</sup>Distance Scale Factor

نمونه‌ها، به تعیین خطا به وسیله میانگین‌گیری از خطاها پرداخته می‌شود [۲۳] که البته لازم به یادآوری است که در این پژوهش از روش ارزیابی چاه‌به‌چاه بهره‌گیری شد.

## یافته‌ها و گفتگو

همان‌گونه که در بخش پیشین گفته شد، نخستین گام، همبستگی داده‌های چاه‌نگاری با داده لرزه‌ای است. پس از ایجاد همبستگی، موجک میانگین تهیه شد که در شکل ۷ تطابق موجک میانگین با چاه HD\_3 و در جدول ۱ همبستگی پایانی هر چاه با بهره‌گیری از موجک میانگین نشان داده شد. به این فرآیند تطبیق داده‌های چاه با داده‌های لرزه‌ای گفته می‌شود. در مرحله بعدی، کوشش شد بر پایه سرسازندهای چاه، بر روی داده‌های لرزه‌ای، افق‌های مورد نظر مشخص شوند که از این رو می‌توان در شکل ۸، مدل نهایی از افق‌های سه‌بعدی مشخص شده را دید. پس از ایجاد همبستگی مناسب، استخراج موجک میانگین، ایجاد افق‌های مورد نظر بر روی داده‌های لرزه‌ای، آماده آغاز فرآیند بازگردانی برای شناسایی امپدانس صوتی در کل پیکره سازند آسماری است.




شکل ۷ تطابق موجک میانگین با چاه HD\_3

جدول ۱ همبستگی پایانی برای هر چاه با بهره‌گیری از موجک میانگین

چاه	همبستگی
HD_1	۸۱/۴٪
HD_2	۷۴/۵٪
HD_3	۸۸/۳٪
HD_4	۸۵/۱٪
HD_5	۸۸/۳٪
HD_6	۸۲/۲٪

HD_7	۷۰/۹ %
------	--------



شکل ۸ افق‌های پایانی سه‌بعدی مشخص شده در کل پیکره سازند آسماری

همان طور که گفته شد، روش بازگردانی مورد استفاده در این پژوهش، بازگردانی بر پایه مدل است که می‌توان پارامترهای پایانی مدل‌سازی بازگردانی در جدول ۲ را دید. همچنین می‌توان نتیجه ارزیابی داده‌های مدل‌سازی شده نسبت به داده‌های واقعی، در محل هر چاه را در جدول ۳، نتیجه ارزیابی و بررسی امیدانس صوتی ایجاد شده با امیدانس صوتی واقعی موجود در چاه HD\_3 را در شکل ۹ و نمایی از برش امیدانس صوتی مدل‌سازی شده در محل چاه HD\_5 را در شکل ۱۰ دید.

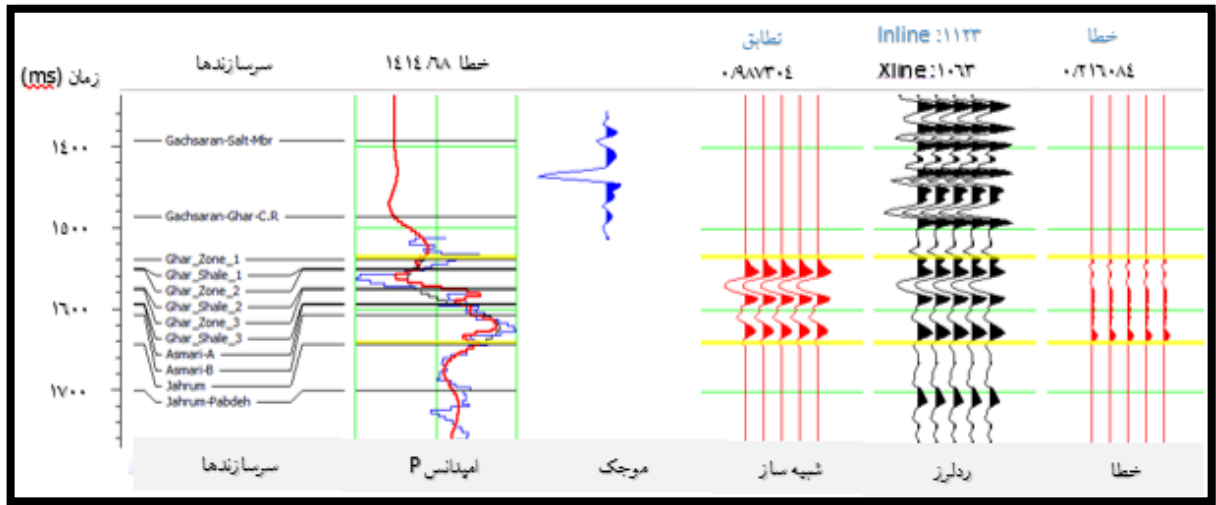
جدول ۲ پارامترهای بهینه مدل‌سازی پایانی بازگردانی

پارامتر	مقدار
حدود مدل	۰/۰۰۰۴
اندازه میانگین بلوک	۲ ms
مقدار اولیه	۱٪
بیشینه شمار تکرار	۸ بار


جدول ۳ نتایج ارزیابی بازگردانی پایانی نسبت به داده‌های موجود در محل چاه

چاه	تطابق ردلرز	خطای مدل‌سازی
HD_1	۰/۹۸۳۶	۰/۲۰۸۰
HD_2	۰/۹۹۴۹	۰/۱۳۷۴
HD_3	۰/۹۸۷۳	۰/۲۱۶۱
HD_4	۰/۹۶۷۴	۰/۲۶۸۷
HD_5	۰/۹۹۱۹	۰/۱۵۳۰
HD_6	۰/۹۷۴۱	۰/۲۵۶۹

HD_7	۰/۹۹۰۴	۰/۲۱۹۳
------	--------	--------



شکل ۹ نتیجه ارزیابی و بررسی امپدانس صوتی ایجاد شده در محل چاه HD\_3



شکل ۱۰ نمایی از بُرش امپدانس صوتی مدل‌سازی شده در چاه HD\_5

پس از اجرای فرآیند بازگردانی، امپدانس صوتی ایجاد شده به‌عنوان یک نشان‌گر لرزه‌ای خارجی نیز به کار می‌رود. در این گام باید در ابتدا داده‌های موجود را نسبت به چاه‌های موجود ارزیابی کرد. در شکل ۱۱ نتیجه ارزیابی داده‌ها نسبت به چاه‌ها آورده شد که بر پایه توضیحات بخش پیشین، چاه HD\_7 باعث ناپایداری مدل‌سازی می‌شود و حذف شد.

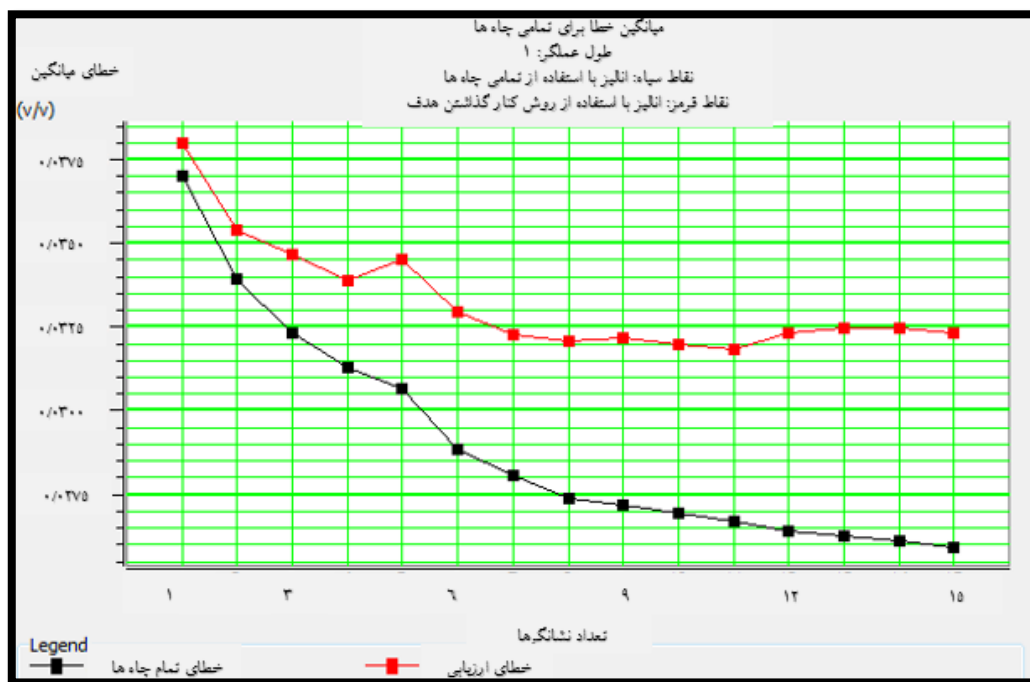


شکل ۱۱ نتیجه ارزیابی داده‌ها بر پایه چاه‌ها

پارامترهای بهینه مدل‌سازی نشان‌گرهای چندگانه در جدول ۴ آورده شد. همچنین بر پایه ارزیابی انجام گرفته بر نشان‌گرهای چندگانه، همان‌طور که در شکل ۱۲ نشان داده شد، ۱۱ نشان‌گر نخست به‌عنوان نشان‌گرهای بهینه انتخاب شد، چرا که خط قرمز نشان‌دهنده آن است که این شمار نشان‌گر باعث کاهش خطای ارزیابی می‌شود و در جدول ۵ نیز لیست نشان‌گرهای پایانی استخراج شده برای برآورد تخلخل آورده شد.

جدول ۴ پارامترهای بهینه مدل‌سازی نشان‌گرهای چندگانه

مقدار	پارامتر
۱۵	بیشینه شمار نشان‌گرها
۱	طول عملگر
۰/۳۵	مقدار اولیه
۰	عملگر انحراف از مرکز



شکل ۱۲ نتایج ارزیابی نشان‌گرهای چندگانه پایانی

جدول ۵ لیست نشان‌گرهای چندگانه پایانی استخراج شده برای برآورد تخلخل

شمار	هدف	نشان‌گر	خطا	تطابق
۱	تخلخل	ریشه دوم امپدانس صوتی	۰/۰۴۰۱۹۱	۰/۷۵۵۴۸۸
۲	تخلخل	لگاریتم امپدانس صوتی	۰/۰۴۰۲۱۹	۰/۷۵۵۰۸۴
۳	تخلخل	امپدانس صوتی	۰/۰۴۰۲۹۱	۰/۷۵۴۰۶۲
۴	ریشه دوم تخلخل	امپدانس صوتی	۰/۰۴۰۳۱۸	۰/۷۴۶۱۴۴
۵	ریشه دوم تخلخل	ریشه دوم امپدانس صوتی	۰/۰۴۰۴۱۸	۰/۷۴۴۲۵۶

۰/۷۴۵۰۳۲	۰/۰۴۰۵۰۶	مجذور امیدانس صوتی	ریشه دوم تخلخل	۶
۰/۷۴۳۹۷۴	۰/۰۴۰۵۵۸	معکوس امیدانس صوتی	مجذور تخلخل	۷
۰/۷۴۰۶۶۴	۰/۰۴۰۶۶۴	لگاریتم امیدانس صوتی	ریشه دوم تخلخل	۸
۰/۷۴۸۴۳۵	۰/۰۴۰۶۸۴	معکوس امیدانس صوتی	تخلخل	۹
۰/۷۱۷۳۵۷	۰/۰۴۰۶۹۶	مجذور امیدانس صوتی	لگاریتم تخلخل	۱۰
۰/۷۴۶۱۲۰	۰/۰۴۰۸۴۴	مجذور امیدانس صوتی	تخلخل	۱۱
۰/۷۱۱۰۹۸	۰/۰۴۱۰۰۷	امیدانس صوتی	لگاریتم تخلخل	۱۲

پس از مشخص شدن لیست نشان‌گرهای لرزه‌ای بهینه، به طراحی و تنظیم پارامترهای شبکه‌های عصبی مختلف به گونه‌ای پرداخته شد که مانع از رخ دادن پدیده بیش‌برازش شود. فرآیند بیش‌برازش فرآیندی است که در آن شبکه دارای کارکرد عالی در دسته داده‌های آموزشی است اما کارکرد بسیار ضعیفی در دسته داده‌های اعتبارسنجی دارد که علت اصلی آن تطابق بیش از حد سیستم با دسته داده‌های آموزشی است. برای جلوگیری از این پدیده سعی شده است که پارامترهای بهینه به گونه‌ای تعیین شوند که دارای بالاترین دقت آموزشی و کمترین خطای پیش‌بینی باشند، پس با روش آزمون و خطا و با در نظر گرفتن شرط بیان شده تلاش شده است که در تکرار دفعات بالا نیز نتایج کارکرد سیستم بررسی شود. در طراحی این شبکه‌ها دو گزینه ابتدایی یعنی وجود روند خاص در میان داده‌ها و همچنین نوع کارکرد شبکه‌ها کاملاً یکسان می‌باشد. در صورت وجود روند خاص، مثلاً روند افزایشی و یا کاهشی با افزایش ژرفا نیز باعث بهبود کارکرد شبکه می‌شود که البته در این پژوهش چنین نبوده است. همچنین، نوع کارکرد این شبکه‌ها به حالت پیش‌بینی عددی با عنوان "به تصویر کشیدن"<sup>۲</sup> تنظیم شده است. پارامترهای بهینه شبکه MLFN در جدول ۶ نمایش داده شد. هرچه شمار گره‌ها و یا همان شمار نرون‌ها در لایه نهان بیشتر باشد شبکه تنظیم شده دارای دقت بیشتر و خطای کمتری در بخش آموزشی دارد. اما اگر از شمار بهینه نرون فراتر رود باعث رخ دادن فرآیند بیش‌برازش می‌شود. از سوی دیگر، اگر شمار نرون‌ها از شمار بهینه آن‌ها کمتر باشد دقت کمی در برآورد خواهد داشت. مقدار بهینه شمار نرون‌ها در لایه نهان، ۶ عدد است. پارامتر بعدی، بیشینه دفعات تکرار فرآیند است. زمانی که شمار داده‌های آموزشی کم باشد، با بهره‌گیری از تکرار فرآیند آموزش شبکه کوشش در تنظیم بهتر و دقیق‌تر آن خواهد شد که البته اگر دفعات تکرار بیش از مقدار بهینه شود باعث رخ دادن فرآیند بیش‌برازش می‌شود. مقدار بهینه بیشینه دفعات تکرار فرآیند، ۳ است. همچنین، پارامتر بعدی در واقع تعیین‌کننده شمار تکرار برای تنظیم شبکه است. برای حل روابط غیرخطی معمولاً با بکارگیری فرآیند تکرار و آموزش نیز به شناسایی روابط پیچیده پرداخته می‌شود (جدول ۶). مقدار این پارامتر کمتر از پارامتر بیشینه دفعات تکرار فرآیند، یعنی ۲ بار است.

جدول ۶ پارامترهای بهینه شبکه پایانی MLFN

چند لایه پیشخور	نوع شبکه عصبی
خیر	آیا داده ها دارای روند خاصی می باشند؟
برآورد عددی	نوع فرآیند
۶	تعداد گره ها در لایه نهان
۳	تعداد کل تکرار
۲	تعداد تکرار گرادیان توام

در جدول ۷ پارامترهای بهینه شبکه PNN نمایش داده شده است. اولین پارامتر این شبکه، پارامتر سیگما و یا همان پارامتر Smoothing است که هر چه مقدار این پارامتر بیشتر باشد اثر نقاط اطلاعاتی اطراف داده مورد نظر در تعیین مقدار آن بیشتر خواهد شد. به عبارت دیگر، تأثیر همسایگی نقاط اطلاعاتی بر هدف افزایش خواهد یافت. مقدار بهینه پارامتر یاد شده ۱۳ است. در بخش بعدی بازه مورد نظر، برای پارامتر سیگما تعیین می شود یعنی نقاط اطلاعاتی که در این بازه نسبت به هدف قرار دارند در برآورد آن نقطه اطلاعاتی تأثیرگذار می باشند. اگر بازه تعیین شده بسیار کوچک باشد، شبکه اطلاعاتی را برآورد می کند که پیوستگی خاصی با یکدیگر ندارند و اگر بازه مورد نظر خیلی بزرگ باشد اطلاعات برآورد شده همانند یکدیگر بوده و قدرت جداسازی برآورد شبکه کاهش می یابد. مقدار بهینه این بازه ۰/۱ تا ۳/۴ واحد است. روش ارزیابی شبکه به صورت چاه به چاه انتخاب شده است که علت آن هم گستردگی زیاد محیط مورد بررسی است که ارزیابی به صورت نقطه به نقطه به علت ناهمگنی اطلاعات باعث کاهش راندمان کار می شود. پس بهتر است که مقیاس را بزرگتر کرده و از روش چاه به چاه که پراکندگی کمتری نسبت به نقاط اطلاعاتی مورد استفاده دارد، بهره گیری شود. و اما آخرین بخش مربوط به شمار دفعات تکرار فرآیند آموزش است که در بخش پیشین شرح داده شد. مقدار بهینه این پارامتر ۳ بار است.

جدول ۷ پارامترهای بهینه شبکه PNN پایانی

احتمالی	نوع شبکه عصبی
خیر	آیا داده ها دارای روند خاصی می باشند؟
برآورد عددی	نوع فرآیند
۱۳	تعداد سیگماهای مورد استفاده
۰/۱۰۰ - ۳/۴۰۰	مقدار سیگمای مورد استفاده
چاه به چاه	نوع ارزیابی
۳	تعداد تکرار گرادیان توام

در آخر پارامترهای بهینه شبکه RBF در جدول ۸ دیده می شود. در این شبکه از پارامتر هموارکننده به علت توانایی بالا و دقت قابل قبول در برآورد نقاط اطلاعاتی نیز بهره گیری نشده است؛ زیرا به کارگیری آن باعث کاهش دقت و افزایش همانندی میان اطلاعات برآورد شده می شد. همچنین، محاسبه پارامتر سیگما به صورت هوشمند انتخاب شده است که در این حالت سیستم کوشش می کند با بهره گیری از روش رگرسیون غیرخطی، مناسب ترین مقدار نشانگر فاصله ای را برای نقاط اطلاعاتی مورد نظر تعیین کند. نیاز به یادآوری است که با کاهش مقدار پارامتر سیگما وزن های به دست آمده به مقادیر آموزشی همگرا می شوند و بالعکس. همچنین، تفاوت پارامتر هموارکننده یاد شده در جدول ۶ با پارامتر سیگما این است



که پارامتر سیگما به دلیل تأثیرگذاری بر نشان‌گر فاصله، بر شباهت بین نقاط اطلاعاتی برآورد شده با نقاط اطلاعاتی آموزشی نیز تأثیرگذار است. همواره در مدل‌سازی‌ها یک مقدار اولیه به ورودی‌های یک شبکه برای ایجاد پایداری و داشتن کارکرد نزدیک به واقعیت، به منظور در نظر گرفتن نوفه موجود در داده‌ها اضافه می‌شود که مقدار آن در این پژوهش ۱۰۰٪ و یا یک واحد است. این مقدار اولیه در تعیین وزن شبکه تأثیرگذار است. و اما آخرین پارامتر شبکه RBF، دسته‌بندی کردن داده‌ها است. در پژوهش‌هایی که داده‌های مورد استفاده دارای ویژگی‌های همانند و نزدیک به یکدیگر هستند، دسته‌بندی داده‌ها و نسبت دادن نقاط اطلاعاتی مورد نظر به دسته‌های ایجاد شده باعث افزایش دقت اطلاعات برآورد شده می‌گردد. اما در این پژوهش به دلیل ناهمگنی و شباهت کم اطلاعات مورد استفاده، از دسته‌بندی داده‌ها استفاده نشد.

جدول ۸ پارامترهای بهینه شبکه RBF پایانی

مقدار	پارامتر
خیر	آیا داده‌های روند خاصی دارند؟
هیچ	پارامتر هموارکننده
هوشمند	محاسبه پارامتر سیگما
۱۰۰٪	مقدار اولیه
خیر	آیا می‌خواهید از دسته‌بندی استفاده شود؟

پس از تعیین و طراحی شبکه‌های بهینه، با استفاده از خطای مجذور میانگین ریشه‌ها و ضریب همبستگی نیز به ارزیابی کارکرد شبکه‌ها پرداخته شد. با استفاده از ضریب همبستگی به توان و دقت شبکه در برآورد پارامتر مورد نظر و با استفاده از RMSE نیز به توان شبکه در شناسایی روند تغییرات آن نیز می‌توان پی برد. نتایج به‌دست آمده از کارکرد شبکه‌ها در برآورد تخلخل چاه HD\_1 و HD\_6 نیز به ترتیب در جدول‌های ۹ و ۱۰ آورده شده است.

جدول ۹ کارکرد شبکه‌ها در برآورد تخلخل چاه HD\_1

روش	RMSE	ضریب همبستگی
RBFN	۰/۰۱۹۹۰۸۴	۰/۸۹۹۵۶۸
PNN	۰/۰۱۹۸۹۶۰	۰/۹۱۷۸۱۵
MLFN	۰/۰۲۷۱۹۷۴	۰/۸۶۳۰۱۷

جدول ۱۰ کارکرد شبکه‌ها در برآورد تخلخل چاه HD\_6

روش	RMSE	ضریب همبستگی
RBFN	۰/۰۵۲۴۸۲۵	۰/۶۲۲۴۰۴
PNN	۰/۰۶۳۷۲۶۸	۰/۷۱۰۴۷۳۵
MLFN	۰/۰۷۶۹۳۰۲	۰/۴۰۸۷۳۳۰

## نتیجه گیری

بر پایه جدول‌های ۹ و ۱۰، شبکه MLFN دارای ضعیف‌ترین کارکرد بوده چرا که بالاترین خطا و کمترین ضریب همبستگی را ثبت کرده است. اما دو شبکه دیگر دارای کارکرد بسیار نزدیک به هم بوده‌اند که البته مقدار اندکی شبکه PNN نسبت به شبکه RBFN در دقت برآورد تخلخل و همچنین، در شناسایی روند تغییرات آن کارکرد بهتری داشت. در رابطه با شبکه‌های باقی‌مانده، در این چاه علی‌رغم بهتر بودن ضریب همبستگی PNN، شبکه RBFN دارای دقت بالاتری در برآورد تخلخل در چاه HD\_6 بود. بنابراین، شبکه MLFN دارای بدترین کارکرد نسبت به سایر شبکه‌ها در برآورد تخلخل هم در بخش درون‌یابی و هم در بخش برون‌یابی بود. شبکه RBFN کارکرد خوب و قابل قبولی در برآورد تخلخل در بخش درون‌یابی داشت، اما برون‌یابی بخشی آن باعث برتری این شبکه شد و نشان دهنده قدرت بالای شبکه در شناسایی روند موجود میان پارامترهای گوناگون و تعمیم‌پذیری آن است که باید این شبکه را به‌عنوان بهترین شبکه برای برون‌یابی تخلخل در بین این سه شبکه دانست. شبکه PNN بهترین کارکرد را در برآورد تخلخل در بخش درون‌یابی داشت که می‌توان قابل اعتمادترین شبکه برای مطالعات درون‌یابی دانست، اما در بخش برون‌یابی قدرت برآورد کمتری نسبت به RBFN داشت.

## سپاس‌گزاری

از گروه مهندسی نفت و معدن دانشگاه بین‌المللی امام خمینی برای فراهم کردن زمینه این پژوهش و از شرکت نفت فلات قاره برای داده‌های نفتی مورد نیاز سپاس‌گزاریم.

## نشانه‌ها و نمادها

- MLFN: شبکه عصبی پیش‌خور چند لایه
- RBFN: شبکه عصبی شعاع مینا
- PNN: شبکه عصبی احتمالی
- MLP: شبکه چند لایه
- M: تعداد ورودی تابع چند لایه ادراکی
- K: تعداد گره‌های شبکه چند لایه ادراکی
- $xT_j$ : ورودی شبکه چند لایه ادراکی
- $y(1)_{kj}$ : خروجی لایه اول شبکه MLP
- $y(2)_j$ : ورودی لایه نهان شبکه سه لایه‌ای MLP
- $z(2)_j$ : خروجی پایانی شبکه MLP
- $S_j$  و  $S_i$ : نمونه‌های شناخته شده در شبکه RBF
- $X_n$ : نمونه ناشناخته شبکه RBF
- $W_i$ : وزن به دست آمده برای شبکه RBF
- $\Phi_i$  و یا  $g$ : تابع پایه شبکه RBF
- $\Sigma$ : پارامتر هموارساز، بی بعد RBF
- $\frac{d_{\square\square}}{\sigma}$ : فاصله مقیاسی در شبکه RBF
- $y(X_a)$ : خروجی پایانی شبکه RBF
- $On(x_i)$ : خروجی شبکه PNN
- $D(x, x_i)$ : فاصله بین نمونه مورد نظر با داده‌های آموزشی در شبکه PNN
- $P_j$ : فاکتور مقیاس فاصله در شبکه PNN

## References

- [1] AMINI, A., MOVAHED, B., BEHZAD, ASIRI, H., and MARZAYI, TABESH, F., 2014, Design of Artificial Neural Network for Prediction of Porosity of Asmari Reservoir in Rag-Sefied Field Using Logarithmic and Porous Porosity Data: 3rd National Oil, Gas and Petrochemical Conference, Gachsaran, Iran.4-5.
- [2] ANEES, M., 2013, Seismic attribute analysis for reservoir characterization: 10th Biennial International Conference and Exposition on the theme “Changing Landscapes in Geophysical Innovations”, India, 119-122.
- [3] 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**, 5:11–15.
- [4] BEDI, J., and TOSHNIWAL, D., 2019, PP-NFR: an improved hybrid learning approach for porosity prediction from seismic attributes using non-linear feature reduction: Journal of Applied Geophysics, **166**, 22-32.
- [5] CAO, J., YANG, J., WANG, Y., WANG, D., and SHI, Y., 2015, Extreme Learning Machine for Reservoir Parameter Estimation in Heterogeneous Sandstone Reservoir: Mathematical Problems in Engineering, **287816**, 1-10.
- [6] CHOPRA, S., and MARFURT, K.J., 2007, Seismic Attributes for Prospect Identification and Reservoir Characterization: (chapter 1) 1<sup>st</sup> ed. Society of Exploration Geophysicists. 1-24.
- [7] ELKATANY, S., TARIQ, Z., MAHMOUD, M., and ABDULRAHEEM, A., 2018, New insights into porosity determination using artificial intelligence techniques for carbonate reservoirs: Petroleum Journal, **4**, 4:1-11.
- [8] EZEKWE, J.N., 2003, Applied Reservoir Management Principles with Case Histories: SPE Annual Technical Conference and Exhibition. Colorado. 5-8.
- [9] FAUSETT, L.V., 1994, Fundamentals of Neural Networks Architectures: Algorithms and Applications (chapter 1) 1<sup>st</sup> ed. Pearson. 3-4
- [10] GHARECHELOU, S., AMINI, A., KADKHODAIE-ILKHCHI, A., and MORADI, B., 2015, An integrated approach for determination of pore-type distribution in carbonate-siliciclastic Asmari Reservoir, CHESHMEH-KHOSH Oilfield, SW Iran: Journal of Geophysics and Engineering, **12**, 793-809.
- [11] GHAZBAN, F., 2007, Petroleum Geology of the Persian Gulf (chapter 9) 1<sup>st</sup> ed. Tehran, Tehran University and National Iranian Oil Company publication, 586-587.
- [12] 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.
- [13] HOSSEINI, A., ZIAII, M., KAMKAR ROUHANI, 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 of Earth Sciences, **3**, 2:168-174.
- [14] HUUSE, M., and FEARY, D.A., 2005, Seismic inversion for acoustic impedance and porosity of Cenozoic cool-water carbonates on the upper continental slope of the Great Australian Bight: Marine Geology, **215**, 3-4:123-134.
- [15] 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.
- [16] MCCULLOCH, W.S., and PITTS, W., 1943, A logical calculus of the ideas immanent in nervous activity: Bulletin of Mathematical Biophysics, **5**, 115–133.
- [17] MCPHEE, C., REED, J., and ZUBIZARRETA, I., 2015, Core Analysis: A Best Practice Guide, (chapter 8) 1<sup>st</sup> ed. Edinburgh, Elsevier Publication, 347-448.
- [18] MOJEDDIFAR, S., KAMALI, G., RANJBAR, H., and SALEHIPOUR BAVARSAD, B., 2014, A comparative study between a pseudo-forward equation [pfe] and intelligence methods for the characterization of the North Sea reservoir: International Journal of Mining and Geo-Engineering, **48**, 2:173–190.
- [19] ORR, M.J., 1996, Introduction to Radial basis function neural networks: Research Report for the Institute of Adaptive and Neural Computation, University of Edinburgh. 9-11.

- [20] POWELL, M.J.D., 1987, Radial basis functions for multivariable interpolation: a review, *Algorithms for Approximation*: Clarendon. 143– 167.
- [21] RONEN, S., SCHULTZ, P.S., HATTORI, M., and CORBETT, C., 1994, Seismic guided estimation of log properties, Part 1, 2 and 3: *The Leading Edge*, **13**: 305-10, 674-678, 770-776.
- [22] RUSSELL, B.H., 1988, *Introduction to seismic inversion methods* (Chapter 8) 1th ed. Calgary, Society of exploration Geophysicist, 1-14.
- [23] RUSSELL, B.H., 2004, *The application of multivariate statistics and neural networks to the prediction of reservoir parameters using seismic attributes*: Ph.D. thesis, Faculty of Graduate Studies, Dissertation University of Calgary. 17-18.
- [24] SOLEIMANI, B., BAHADORI, A., and MENG, F., 2013, Microbiostratigraphy, microfacies and sequence stratigraphy of upper cretaceous and Paleogene sediments, Hendijan oil field, Northwest of Persian Gulf, Iran: *Natural Science*, **5**. 11:1165-1182.
- [25] SPECHT, D.F., 1990, Probabilistic neural networks: *Neural Networks*, **3**, 1:109–118.
- [26] TARANTOLA, A., 2005, *Using the Solution of the Inverse Problem*, 1st ed. Paris, Society for Industrial and Applied Mathematics, 37-38.
- [27] YAZDANIAN, J., and NOORI, B., 2007, *Geological Final Report-Well HD\_7*, Iranian Offshore Oil Company, 57.

# Comparison of the function of conventional neural networks for estimating porosity in one of the southeastern Iranian oil fields

Farshad Tofighi<sup>1</sup>, Parviz Armani<sup>2[1]</sup>, Ali Chehrizi<sup>3</sup>, Andisheh Alimoradi<sup>4</sup>

<sup>1</sup>Department of Mining, Faculty of Engineering, Imam Khomeini International University

<sup>2</sup> Department of Geology, Faculty of Sciences, Imam Khomeini International University

<sup>3</sup>Head of Exploration Project Management, Iranian Offshore Oil Company

<sup>4</sup>Department of Mining, Faculty of Engineering, Imam Khomeini International University

In the oil industry, artificial intelligence is used to identify relationships, optimize, estimate and classify porosity. One of the most important steps in evaluating the petrophysical parameters of the reservoir is to identify the porosity properties. The main purpose of this study is to compare the accuracy and generalizability of three multilayer feed neural networks (MLFNs), radius base function networks (RBFNs) and probabilistic neural networks (PNNs) to estimate porosity using seismic properties. In this regard, geological data of 7 wells were evaluated from an offshore oil field in Hindijan in the northwest of the Persian Gulf basin. Acoustic impedance was estimated using model-based inversion method and then the mentioned neural networks were designed using optimal seismic properties and evaluated by stepwise regression method. Finally, it became clear that the MLFN model did not work well for estimating porosity. PNN has the best performance accuracy in porosity interpolation, but RBFN generalizability is better.

Keywords: seismic inversion, porosity estimation, MLFN, RBFN, PNN