

مقایسه کارکرد شبکه‌های عصبی مرسوم برای برآورد تخلخل در یکی از میدان‌های نفتی جنوب خاوری ایران

فرشاد توفیقی^۱، پرویز آرمانی^{۲*}، علی چهارزی^۳ و اندیشه علیمزادی^۱

۱- گروه مهندسی معدن، دانشکده فنی، دانشگاه بین‌المللی امام خمینی، قزوین، ایران

۲- گروه زمین‌شناسی، دانشکده علوم، دانشگاه بین‌المللی امام خمینی، قزوین، ایران

۳- مدیریت طرح‌های اکتشافی، شرکت نفت فلات قاره ایران، تهران، ایران

تاریخ دریافت: ۱۳۹۹/۹/۲۷ تاریخ پذیرش: ۱۳۹۹/۱۲/۲۵

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 صوتی 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.

کلمات کلیدی: برآورد تخلخل، بازگردانی لرزه‌ای، PNN، RBFN، MLFN

مقدمه

دسته‌بندی پارامترهای کیفی نیز رواج بسیاری یافته است [۱-۳]. بهره‌گیری از این روش باعث افزایش دقت کار و کاهش هزینه و زمان می‌شود [۴]. تخلخل یکی از مهم‌ترین ویژگی‌های پتروفیزیکی سنگ مخزن است، چرا که در محاسبات حجمی نفت موجود در مخزن [۵]، محاسبات اشباع سیالات، توصیف مخزن [۶]،

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،

*مسئول مکاتبات

armani@sci.ikiu.ac.ir

آدرس الکترونیکی: شناسه دیجیتال: (DOI: 10.22078/pr.2021.4318.2957)

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^۳ ویژگی‌های پتروفیزیکی زیرسطحی از جمله سرعت موج برشی^۴، سرعت موج فشردگی^۵ و امپدانس صوتی ویژه (که توسط ضرب چگالی در سرعت امواج لرزه‌ای نیز به‌دست می‌آید) نیز پرداخته می‌شود [۱۵]. امپدانس صوتی یکی از مهم‌ترین نشان‌گرهای لرزه‌ای است که با ویژگی‌های پتروفیزیکی به ویژه تخلخل رابطه‌ای معنادار دارد و به‌صورت پلی ارتباطی میان ویژگی‌های پتروفیزیکی و ویژگی‌های کشسان^۶ است [۱۱ و ۱۶]. نشان‌گرهای لرزه‌ای اطلاعات لرزه‌ای هستند که به‌صورت مستقیم و غیرمستقیم از راه انجام روابط ریاضیاتی پیچیده بر روی داده لرزه‌ای ایجاد می‌شوند [۱۷]. در نتیجه استخراج داده‌ها از نشان‌گرهای لرزه‌ای کمک شایانی در برآورد ویژگی‌های فیزیکی مخزن‌ها می‌کند [۱۸]. همچنین، لازم به یادآوری است که در بسیاری از مواقع به‌دلیل ناهمگن بودن منطقه، چه به‌صورت عمودی و چه به‌صورت افقی، ایجاد رابطه‌ای عددی میان امپدانس صوتی و تخلخل با روش‌های مرسوم آماري و بدون بهره‌گیری از هیچ‌گونه تابعی نیز امکان‌پذیر نیست. بنابراین، برای برآورد تخلخل نیاز به یک مدل سطح بالا و هوشمند است [۱۹].

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^۷ در محیط‌های ناهمگن است [۲۰].


شناسایی واحدهای جریان‌ی در محیط‌های ناهمگن [۷]، بررسی‌های اقتصادی پروژه [۸]، به‌عنوان یکی از مهم‌ترین پارامترهای مخزنی در نرم‌افزارهای شبیه‌ساز [۹]، مشخص کردن فشار نقاط مختلف مخزن به منظور کاهش خطر حفاری [۱۰] و همچنین، تعیین الگوهای جریان هیدروکربن‌های مختلف [۱۱ و ۱۲] کاربرد دارد. در آغاز تخلخل از راه بررسی مستقیم مغزه تهیه‌شده در آزمایشگاه‌ها مانند وزن کردن مستقیم نمونه، قوطه‌وری، روش‌های نوری، اسکن توموگرافی کامپیوتری^۱ و روش انبساط گازی به‌دست می‌آمدند 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^۲ 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 [۱۳]. 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 [۶]. 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 [۱۴]. در هنگام برداشت‌های لرزه‌ای امواجی با فرکانس بالا میرا می‌شوند که در مدل‌سازی سه‌بعدی کوشش

1. Computerized Tomography Scan (CT Scan)
2. Nuclear Magnetic Resonance (NMR)
3. Inversion
4. Shear Wave Velocity (VS)
5. Pressure Wave Velocity (VP)
6. Elastic
7. Flow Units


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 [۲۱]. دو چاه HD_1 و HD_6 بر پایه جایگاه جغرافیایی آن‌ها به‌عنوان داده‌های ناشناخته در نظر گرفته شده‌اند (شکل ۲).

هدف اصلی از این پژوهش مقایسه دقت و تعمیم‌پذیری سه مدل مرسوم شبکه عصبی، یعنی شبکه عصبی پیش‌خور چند لایه^۱، شبکه تابع شعاع مینا^۲ و شبکه عصبی احتمالی^۳ در برآورد تخلخل با بهره‌گیری از امپدانس صوتی و سایر نشان‌گرهای لرزه‌ای به‌دست آمده از برآزش گام‌به‌گام در سازند آسماری است.



شکل ۱ جایگاه میدان نفتی مورد بررسی [۲۲]

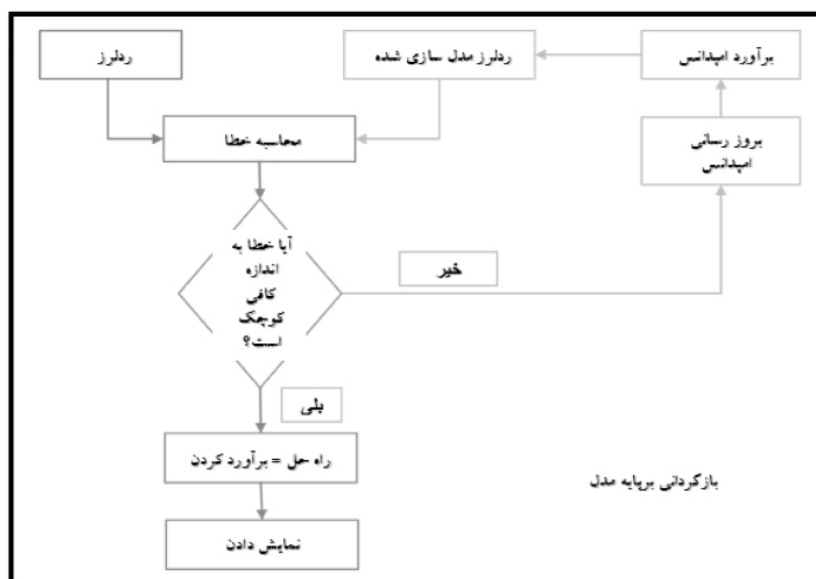


شکل ۲ جایگاه چاه‌های نفتی مورد بررسی

1. Multi-layer Feed Forward Neural Network (MLFN)
2. Radial Basis Function Network (RBFN)
3. Probabilistic Neural Network (PNN)

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^۳ برای مدل‌سازی بازگردانی امیدانس 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 شمایی عملیاتی را نشان داده شد. 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 موردنظر (در پژوهش‌های آینده نشان‌گرها و نقاط اطلاعاتی) نیز نادیده گرفته می‌شود و با بهره‌گیری از دیگر چاه‌ها به برآورد آن چاه پرداخته می‌شود.

هدف از بهره‌گیری از چاه‌های HD_1 و HD_6 نیز به‌ترتیب 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. 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^۱ تنها در چاه‌های HD_6 و HD_7 موجود بود. نخستین گام برای آماده‌سازی داده‌های ورودی هم‌حوزه 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 بازتاب^۲ در محل درست خود و همچنین، استخراج موجک میانگین برای ساخت ردلرزه‌های مصنوعی در محل



شکل ۳ شمایی عملیاتی از نظریه بازگردانی برپایه مدل [۱۵]


1. Check Shot Data
2. Reflection Coefficient (RC)
3. Model based Inversion

منظور از خطا در این بخش، خطای جذر میانگین مربعات است و شمار ۱۶۰ نشان‌گر مورد بررسی قرار گرفت.

شبکه عصبی مصنوعی

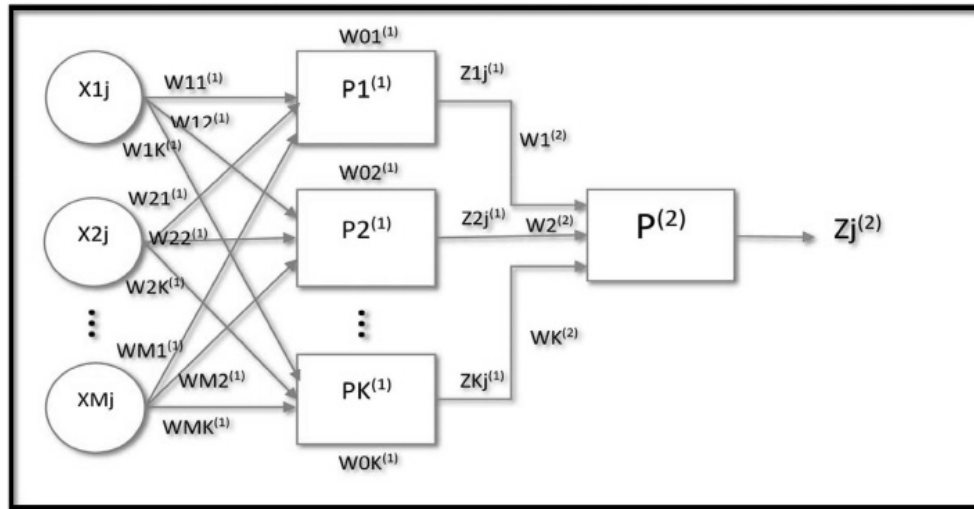
شبکه عصبی مصنوعی و یا سیستم پیوندگرا، یک سیستم محاسباتی مبهم است که از شبکه عصبی زیستی الگوبرداری شده است. به علت مبهم بودن کارکرد و محاسبات انجام گرفته در آن، این سیستم را به اصطلاح جعبه سیاه^۱ می‌نامند [۲۳]. شبکه عصبی پیش‌خور چندلایه یا MLFN، یک شبکه عصبی کلاسیک بوده که به‌عنوان یک شبکه چندلایه ادراکی^۲ 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 و وزن‌های تنظیم شده اشاره کرد. در شکل ۵ نیز ساختار شبکه چند لایه با M ورودی و تعداد K تا گره^۳ نیز نشان داده شد. همواره نخستین لایه در MLFN نیز لایه ورودی و آخرین لایه نیز لایه خروجی نامیده می‌شود.

هر چه دقت کار کمتر و یا به‌عبارت 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. 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 به‌صورت تک‌ی می‌باشند نیز اشاره کرد. نیاز به یادآوری است که



شکل ۴ نتیجه ارزیابی داده‌ها بر پایه چاه‌ها

1. Black Box
2. Multi-layer Perceptron (MLP)
3. Neuron



شکل ۵ شمای عملیاتی از شبکه MLFN با M ورودی و K گره [۲۵]

توابع تحریک^۱ نیز تابع Logistic است که خروجی آن را بین +۱ و -۱ 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:

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

وزن شبکه براساس خطای پسا انتشاری که توسط الگوریتم محاسبه می‌شود، تعیین می‌شود. به این صورت که با افزایش و کاهش اوزان مختلف کوشش می‌شود که خطای برآورد به کمترین مقدار خود برسد [۲۵]. شبکه شعاع مبنا (RBF) برای درون‌یابی دسته داده‌هایی در فضای غیرخطی طراحی شده است [۲۴]. در مدل‌سازی ریاضیاتی، شبکه تابع شعاع مبنا نیز یک شبکه عصبی مصنوعی پیش‌خور^۲ با تابع تحریک شعاع مبنا است که بر پایه تئوری منظم‌سازی^۳ و از تابع گاوسی^۴ به‌عنوان تابع تحریک اصلی نیز بهره‌گیری می‌کند که در آن از فواصل به‌عنوان "نشان‌گر فضایی" بهره‌برداری می‌شود [۲۶].

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 [۲۴]. ورودی‌های شبکه MLP نیز برداری با M نشان‌گر است که مقدار آن به صورت $[xT]j = [x1j, x2j, \dots, xMj]$ است که در آن $j=1, 2, \dots, N$ و یا به دیگر سخن، تعداد نمونه‌های لایه‌های ورودی به صورت رابطه ۱ نوشته می‌شود.

$$y(1)kj = \sum_{i=0}^M W(1)ki \cdot xij = W^{(1)T} \cdot xj, k = 1, 2, \dots, K \quad (1)$$

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

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

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

که در رابطه ۲ نیز $Z(1)kj$ خروجی حاصل از لایه اول است. در شبکه‌های MLP یکی از پر کاربردترین

1. Activation Function
2. Feed Forward
3. Regularization
4. Gaussian Function

است که محاسبات برآورد پارامتر مورد نظر نیز به صورت زیر نوشته می‌شود:

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

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^۳ بر داده‌ها نیز عمل می‌کند. از شبکه PNN همواره می‌توان 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 بهره‌گیری کرد [۲۸]. اگر بردار x_i به عنوان ورودی شبکه PNN تعریف شده باشد در آن صورت خروجی $O_n(x_i)$ نیز از طریق جمع خطی n نقطه اطلاعاتی در بخش آموزش بر پایه رابطه ۸ نیز به دست می‌آید.

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

که در رابطه ۸، $D(x, xi)$ فاصله بین داده ورودی x با هر یک از داده‌های آموزشی آن است.


فرض کنید دو نمونه S_j و S_i 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. 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 ϕ استفاده می‌شود. توابع غیرخطی ϕ_j نیز توابع "پایه" نامیده می‌شوند. از نظر ریاضیاتی، تابع پایه عبارت است از:

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

که در رابطه ۶ نیز σ ، پارامتر سیگما و یا به عبارت دیگر، پارامتر هموارسازی^۲ است. باید توجه شود که d^2_{jn}/σ^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 مبنای یک تابعی است که با فاصله گرفتن از مرکز، یکنواختی پاسخ آن کاهش می‌یابد [۲۷]. خروجی شبکه، یک ترکیب خطی توابع شعاع مبنای ورودی و پارامترهای نورون



شکل ۶ برآورد نمونه ناشناخته X_n توسط دو نمونه S_j و S_i [۲۵]

1. Basis
2. Smoothing
3. Parzen Window

نظر پرداخته شود و سپس با تکرار این فرآیند برای دیگر نمونه‌ها، به تعیین خطا به‌وسیله میانگین‌گیری از خطاها پرداخته می‌شود [۱۷] که البته لازم به یادآوری است که در این پژوهش از روش ارزیابی چاه‌به‌چاه بهره‌گیری شد.

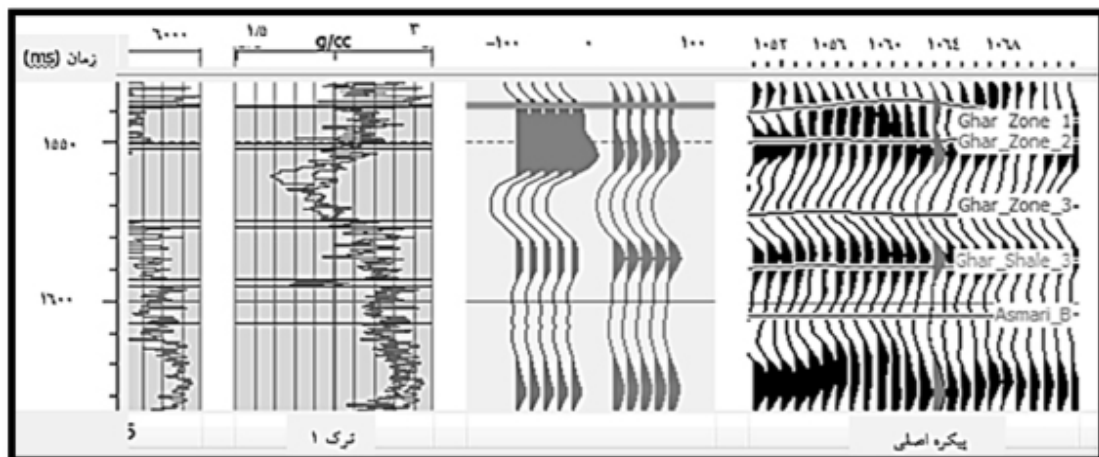
یافته‌ها و گفتگو

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.

که از طریق رابطه ۹ نیز به‌دست می‌آید.

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

که در رابطه ۹، k تعداد نقاط اطلاعاتی ورودی است و همچنین، ρ_j فاکتور مقیاس فاصله^۱ برای هر یک از نشان‌گرهای ورودی است که تنها پارامتر PNN است که نیاز به تنظیم‌شدن دارد. این شبکه در مقایسه با دیگر شبکه‌های عصبی مصنوعی، مانند MLP که دارای پارامترهای بسیاری برای تنظیم‌شدن هستند، بسیار راحت‌تر، سریع‌تر و مؤثرتر تنظیم می‌شود [۲۵]. مقدار بهینه ρ_j در شرایط کمترین مقدار خطا نیز به‌دست می‌آید که در این حالت، نمونه موردنظر خارج شده و کوشش می‌شود که با بهره‌گیری از دیگر نمونه‌ها به برآورد نمونه مورد




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

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 امپدانس صوتی ایجاد شده با امپدانس صوتی واقعی موجود در چاه HD_3 را در **شکل ۹** و نمایی از بُرش امپدانس صوتی مدل‌سازی شده در محل چاه HD_5 را در **شکل ۱۰** دید.

به این فرآیند تطبیق داده‌های چاه با داده‌های لرزه‌ای^۱ گفته می‌شود. در مرحله بعدی، کوشش شد بر پایه سرسازندهای چاه، برروی داده‌های لرزه‌ای، افق‌های مورد نظر مشخص شوند که از این‌رو 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 برروی داده‌های لرزه‌ای، آماده آغاز فرآیند بازگردانی برای شناسایی امپدانس صوتی در کل پیکره سازند آسماری است.




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

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

جدول ۲ پارامترهای بهینه مدل‌سازی پایانی بازگردانی

پارامتر	مقدار
حدود مدل	۰/۰۰۰۴
اندازه میانگین بلوک	ms 2
مقدار اولیه	٪۱
پیشینه شمار تکرار	۸ بار




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

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.

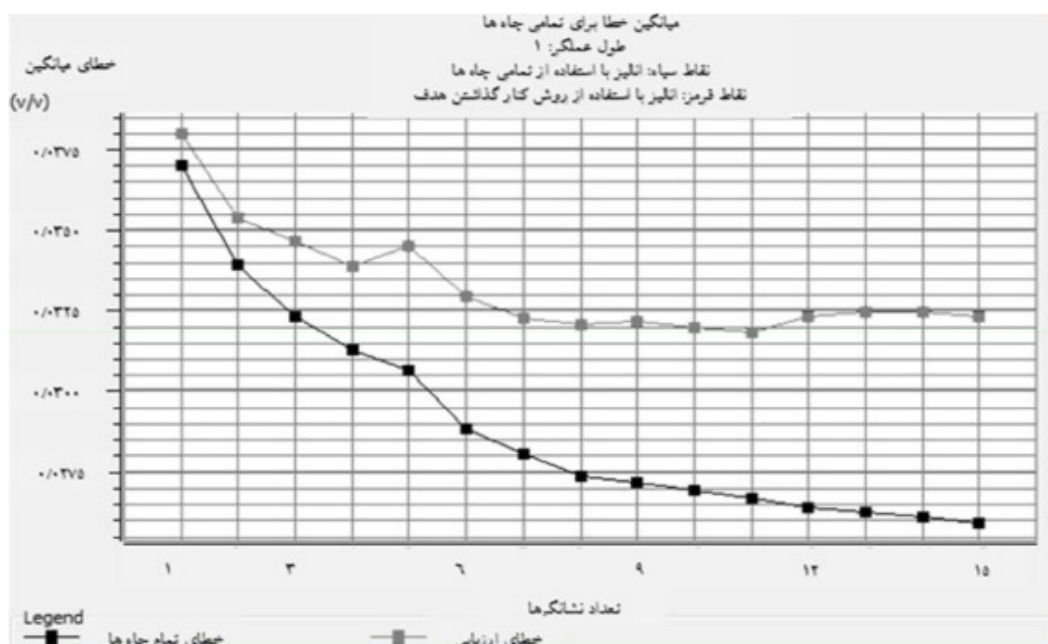
پس از اجرای فرآیند بازگردانی، امپدانس صوتی ایجاد شده به‌عنوان یک نشان‌گر لرزه‌ای خارجی نیز به کار می‌رود. در این گام باید در ابتدا داده‌های موجود را نسبت به چاه‌های موجود ارزیابی کرد. در شکل ۱۱ نتیجه ارزیابی داده‌ها نسبت به چاه‌ها آورده شد که بر پایه توضیحات بخش پیشین، چاه HD_7 باعث ناپایداری مدل‌سازی می‌شود و حذف شد. پارامترهای بهینه مدل‌سازی نشان‌گرهای چندگانه



شکل ۱۱ نتیجه ارزیابی داده‌ها بر پایه چاه‌ها

جدول ۴ پارامترهای بهینه مدل‌سازی نشان‌گرهای چندگانه

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



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 امیدانس صوتی	۰/۰۴۰۱۹۱	۰/۷۵۵۴۸۸
۲	تخلخل	لگاریتم امیدانس صوتی	۰/۰۴۰۲۱۹	۰/۷۵۵۰۸۴
۳	تخلخل	امیدانس صوتی	۰/۰۴۰۲۹۱	۰/۷۵۴۰۶۲
۴	ریشه دوم تخلخل	امیدانس صوتی	۰/۰۴۰۳۱۸	۰/۷۴۶۱۴۴
۵	ریشه دوم تخلخل	ریشه دوم امیدانس صوتی	۰/۰۴۰۴۱۸	۰/۷۴۴۲۵۶
۶	ریشه دوم تخلخل	مجذور امیدانس صوتی	۰/۰۴۰۵۰۶	۰/۷۴۵۰۳۲
۷	مجذور تخلخل	معکوس امیدانس صوتی	۰/۰۴۰۵۵۸	۰/۷۴۳۹۷۴
۸	ریشه دوم تخلخل	لگاریتم امیدانس صوتی	۰/۰۴۰۶۶۴	۰/۷۴۰۶۶۴
۹	تخلخل	معکوس امیدانس صوتی	۰/۰۴۰۶۸۴	۰/۷۴۸۴۳۵
۱۰	لگاریتم تخلخل	مجذور امیدانس صوتی	۰/۰۴۰۶۹۶	۰/۷۱۷۳۵۷
۱۱	تخلخل	مجذور امیدانس صوتی	۰/۰۴۰۸۴۴	۰/۷۴۶۱۲۰
۱۲	لگاریتم تخلخل	امیدانس صوتی	۰/۰۴۱۰۰۷	۰/۷۱۱۰۹۸

این شبکه‌ها به‌حالت پیش‌بینی عددی با عنوان "به تصویر کشیدن"^۱ 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 بیش برآزش می‌شود.

جدول ۶ پارامترهای بهینه شبکه پایانی MLFN

نوع شبکه عصبی	چند لایه پیشخور
آیا داده‌ها دارای روند خاصی می‌باشند؟	خیر
نوع فرآیند	برآورد عددی
تعداد گره‌ها در لایه نهان	۶
تعداد کل تکرار	۳
تعداد تکرار گرادیان توام	۲

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.

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 بیش برآزش^۱ شود. فرآیند بیش برآزش 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 کاهش با افزایش ژرفا نیز باعث بهبود کارکرد شبکه می‌شود که البته در این پژوهش چنین نبوده است. همچنین، نوع کارکرد

1. Over Fitting
2. Mapping

یکدیگر ندارند و اگر بازه مورد نظر خیلی بزرگ باشد اطلاعات برآورد شده همانند یکدیگر بوده و قدرت جداسازی برآورد شبکه کاهش می‌یابد. مقدار بهینه این بازه ۰/۱ تا ۳/۴ واحد است. روش ارزیابی شبکه به صورت چاه‌به‌چاه 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 می‌شود. پس بهتر است که مقیاس را بزرگ‌تر کرده و از روش چاه‌به‌چاه که پراکندگی کمتری نسبت به نقاط اطلاعاتی مورد استفاده دارد، بهره‌گیری 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. در آخر پارامترهای بهینه شبکه RBF در **جدول ۸** دیده می‌شود. در این شبکه از پارامتر هموارکننده به علت توانایی بالا و دقت قابل قبول در برآورد نقاط اطلاعاتی نیز بهره‌گیری نشده است؛ زیرا به کارگیری آن باعث کاهش دقت و افزایش همانندی میان اطلاعات برآورد شده می‌شد. همچنین، محاسبه پارامتر سیگما به صورت هوشمند انتخاب شده است که در این حالت سیستم کوشش می‌کند با بهره‌گیری از روش رگرسیون غیرخطی، مناسب‌ترین مقدار نشان‌گر فاصله‌ای را برای نقاط اطلاعاتی مورد نظر تعیین کند. نیاز به یادآوری است که با کاهش مقدار پارامتر سیگما وزن‌های به‌دست آمده به مقادیر آموزشی همگرا می‌شوند و بالعکس.

جدول ۸ پارامترهای بهینه شبکه RBF پایانی

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

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 بیش برآزش 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. در **جدول ۷** پارامترهای بهینه شبکه PNN نمایش داده شده است.

جدول ۷ پارامترهای بهینه شبکه PNN پایانی

نوع شبکه عصبی	احتمالی
آیا داده‌ها دارای روند خاصی می‌باشند؟	خیر
نوع فرآیند	برآورد عددی
تعداد سیگماهای مورد استفاده	۱۳
مقدار سیگمای مورد استفاده	۰/۱۰۰-۳/۴۰۰
نوع ارزیابی	چاه‌به‌چاه
تعداد تکرار گرادیان توام	۳

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 می‌شود یعنی نقاط اطلاعاتی که در این بازه نسبت به هدف قرار دارند در برآورد آن نقطه اطلاعاتی تأثیرگذار می‌باشند. اگر بازه تعیین شده بسیار کوچک باشد، شبکه اطلاعاتی را برآورد می‌کند که پیوستگی خاصی با

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

نتیجه‌گیری

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 نشان‌دهنده 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.

همچنین، تفاوت پارامتر هموارکننده یادشده در جدول ۶ با پارامتر سیگما این است که پارامتر سیگما به‌دلیل تأثیرگذاری بر نشان‌گر فاصله، بر شباهت بین نقاط اطلاعاتی برآورد شده با نقاط اطلاعاتی آموزشی نیز تأثیرگذار است. همواره در مدل‌سازی‌ها یک مقدار اولیه^۱ 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 ۱۰٪ 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 به‌دلیل ناهمگنی و شباهت کم اطلاعات مورد استفاده، از دسته‌بندی داده‌ها استفاده نشد. پس از تعیین و طراحی شبکه‌های بهینه، با استفاده از خطای مجذور میانگین ریشه‌ها^۲ 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 به‌ترتیب 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

1. Prewhitening

2. Root Mean Square Error (RMSE)

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.

MLFN: شبکه عصبی پیش‌خور چند لایه

RBFN: شبکه عصبی شعاع مبنا

PNN: شبکه عصبی احتمالی

MLP: شبکه چند لایه

M: تعداد ورودی تابع چند لایه ادراکی

K: تعداد گره‌های شبکه چند لایه ادراکی

xTj: 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)

Si و *Sj*: نمونه‌های شناخته شده در شبکه (RBF)

Xn: نمونه ناشناخته شبکه (RBF)

Wi: وزن به‌دست آمده برای شبکه (RBF)

Φ_i و g : تابع پایه شبکه (RBF)

Σ : پارامتر هموارساز، بی بعد (RBF)

d^{2n}/σ^2 : فاصله مقیاسی در شبکه (RBF)

$y(Xa)$: خروجی پایانی شبکه (RBF)

$On(xi)$: خروجی شبکه (PNN)

$D(x, xi)$: فاصله بین نمونه مورد نظر با داده‌های

آموزشی در شبکه (PNN)

Pj : فاکتور مقیاس فاصله در شبکه (PNN)

مراجع

- [1]. Iturrarán-Viveros U, 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.
- [2]. Fausett L V (1994) Fundamentals of neural networks architectures, Algorithms and Applications (chapter 1) 1st ed. Pearson. 3-4
- [3]. Cao J, Yang J, Wang Y, Wang D, Shi Y (2015) Extreme learning machine for reservoir parameter estimation in heterogeneous sandstone reservoir, in mathematical problems in engineering, 287816, 1-10.
- [4]. Amini A, Movahed B, Behzad Asiri H, 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.
- [5]. Asoodeh M, 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.
- [6]. Ezekwe JN (2003) Applied reservoir management principles with case histories, SPE Annual Technical Conference and Exhibition. Colorado. 5-8.
- [7]. Gholami A, Ansari HR (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.
- [8]. Elkatatny S, Tariq Z, Mahmoud M, Abdulraheem A (2018) New insights into porosity determination using artificial intelligence techniques for carbonate reservoirs, *Petroleum Journal*, 4. 4:1-11.
- [9]. Tarantola A (2005) Using the solution of the inverse problem, 1st ed. Society for Industrial and Applied Mathematics, 37-38.
- [10]. Hosseini A, Ziaii M, Kamkar Rouhani A, Roshandel A, Gholami R, 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.
- [11]. Mojeddifar S, Kamali G, Ranjbar H, 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.
- [12]. Gharechelou S, Amini A, Kadkhodaie-Ilkhchi A, 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.
- [13]. McPhee C, Reed J, Zubizarreta I (2015) Core analysis: A best practice guide, (chapter 8) 1st ed. Elsevier Publication, 347-448.
- [14]. Bedi J, 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.

- [15]. Russell BH (1988) Introduction to seismic inversion methods (Chapter 8) 1st ed. Society of Exploration Geophysicist, 1-14.
- [16]. Huuse M, Feary DA (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.
- [17]. Russell BH (2004) The application of multivariate statistics and neural networks to the prediction of reservoir parameters using seismic attributes. Ph.D. Dissertation University of Calgary. 17-18.
- [18]. Chopra S, Marfurt KJ (2007) Seismic attributes for prospect identification and reservoir characterization, (chapter 1) 1st ed. Society of Exploration Geophysicists. 1-24.
- [19]. 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.
- [20]. Ghazban F (2007) Petroleum geology of the Persian Gulf (chapter 9) 1st ed. Tehran University and National Iranian Oil Company publication, 586-587.
- [21]. Soleimani B, Bahadori A, 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.
- [22]. Yazdani J, Noori B (2007) Geological final report-Well HD_7, Iranian Offshore Oil Company, 57.
- [23]. McCulloch WS, Pitts W (1943) A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115-133.
- [24]. Powell MJD (1987) Radial basis functions for multivariable interpolation: a review, *Algorithms for Approximation*, Clarendon. 143-167.
- [25]. Ronen S, Schultz PS, Hattori M, Corbett C (1994) Seismic guided estimation of log properties, Part 1, 2 and 3: *The Leading Edge*, 13: 305-10, 674-678, 770-776.
- [26]. Orr MJ (1996) Introduction to Radial basis function neural networks. Research Report for the Institute of Adaptive and Neural Computation, University of Edinburgh. 9-11.
- [27]. Specht DF (1990) Probabilistic neural networks, *Neural Networks*, 3. 1:109-118.



Comparison of the Function of Conventional Neural Networks for Estimating Porosity in One of the Southeastern Iranian Oil Fields

Farshad Tofghi¹, Parviz Armani^{2*}, Ali Chehrazi³, Andisheh Alimoradi¹

1. Department of Mining, Faculty of Engineering, Imam Khomeini International University

2. Department of Geology, Faculty of Sciences, Imam Khomeini International University

3. Head of Exploration Project Management, Iranian Offshore Oil Company

armani@sci.ikiu.ac.ir

DOI: 10.22078/pr.2021.4318.2957

Received: December/17/2020

Accepted: March/15/2021

Introduction

Porosity is one of the most important petrophysical properties of reservoir rock. Nowadays artificial intelligence is a mathematical tool based on parallel processing that is widely used in the oil industry to recognize nonlinear relationships, optimization, quantitative parameter estimation as well as qualitative parameter classification [1-3]. The most widely used field of study of artificial intelligence using Acoustic impedance is the estimation and evaluation of petrophysical properties such as porosity, permeability, water saturation, shale volume, water content and thus the identification of flow units in heterogeneous environments [4]. The main purpose of this study is to compare the accuracy and generalizability of three conventional neural network models, namely Multi-Layer Feed Forward Neural Network (MLFN), Radial Basis Function Network (RBFN) and Probabilistic Neural Network (PNN) in estimating porosity using Acoustic impedance and other seismic attributes. Nowadays, in addition to well logging data, 3D seismic data are used for 3D modeling. Acoustic impedance is one of the most important seismic indicators that has a significant relationship with petrophysical properties, especially porosity, and it is a bridge between petrophysical properties and elastic properties [5, 6]. Seismic attributes are seismic information that is generated directly and indirectly by performing complex mathematical relationships on seismic data

[7]. As a result, extracting data from seismic attributes helps in estimating the physical properties of reservoirs [8].

Materials and Methods

This study is a database research that includes geological data from 7 wells in Hindijan oil field located in the northwest of the Persian Gulf. Hindijan oil field is structurally a small anticline with a north-south trend. The two wells HD_1 and HD_6 are considered as unknown data based on their geographical location. The purpose of using HD_1 and HD_6 wells is to identify the accuracy and generalizability of the desired models. In this study, Asmari Formation was investigated. The number of information was 25 to 30 points.

Results and Discussion

In this study, three-dimensional seismic data were used post stacking and the well logging data obtained from this field. Porosity, acoustic and density logs for all wells and check shot data were available only in HD_6 and HD_7 wells. The first step in preparing the input data was to constrain, because well logging data are spatial in nature and seismic data are time in nature. For this purpose, using well correction data, as a time-depth function, all well logging data were transferred to the time domain. Then, using the manual adaptation process, an attempt was made to

increase the adaptation in order to place the reflection coefficients in their correct place and also to extract the mean wavelet to make artificial seismicity at the wells. In this study, the model-based inversion method was used to model the acoustic impedance inversion in the entire 3D body of the Asmari Formation. In the beginning, before selecting the optimal multiple attributes, the input data for each well should be studied and evaluated. Hence, the technique of “Backward elimination” was used. This method how it is that the wells mentioned above are ignored and using other wells to estimate that well. In this study, stepwise regression method was used to select the optimal number of multiple attributes based on single attributes. In this method, first, the single attributes with the lowest porosity estimation error was selected and then an attempt was made to search for the pair of attributes with the lowest estimation error using the trial and error method. This process continues until the maximum number of attributes is reached. The advantage of this method is the high processing speed, but the loss of the best pair of attributes is one of the disadvantages of this method which may have a high error in estimating the porosity individually.

An artificial neural network, or intermediated system,

is an ambiguous computational system which modeled on a biological neural network. The multi-layer feed forward neural network, or MLFN, is a classical neural network also known as a multi-layer perceptron (MLP) network. The first layer in MLP is always called the input layer and the last layer is called the output layer. The layers between the input and output layers are also called hidden layers, the number of which can be from one to any value, there is a number of hidden layers with the optimal number of neurons.

In mathematical modeling, the lattice-based function network is an artificial neural network feed forward to the radius-based excitation function, which is based on the theory of regularity and uses the Gaussian function as the main excitation function, which uses distances as a “spatial indicator” [9]. The probabilistic neural network (PNN) is a neural network that also acts on data by applying the Parzen window. The PNN network can always be used as a fast and reliable method for estimating continuous or discontinuous data as well as for determining the relationship between input and output data [10]. As mentioned, the inversion method used in this study is model based inversion. The result of evaluating the modeled data relative to the real data and a view of the modeled acoustic impedance section at the HD_5 well can be seen in Figure 1.

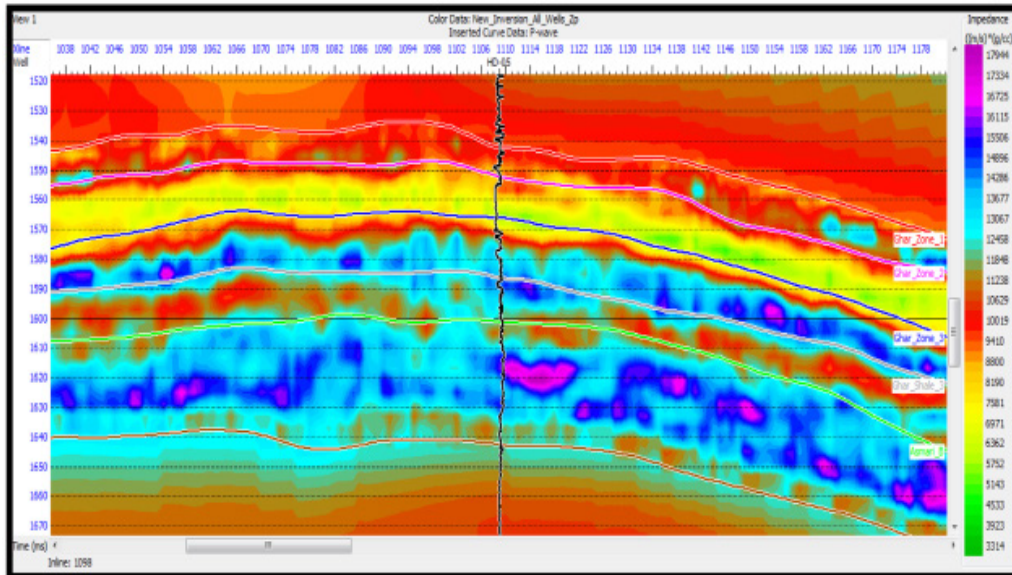


Fig. 1 View of the modeled acoustic impedance section in the HD_5 well.

Conclusions

In this study, the MLFN network had the weakest performance because it recorded the highest error and the lowest correlation coefficient (Tables 1 and 2). Despite the better PNN correlation coefficient, the RBFN network had higher accuracy in estimating porosity in the HD_6 well. The RBFN network had a good and acceptable performance in estimating the porosity in the interpolation section, but its partial extrapolation made this network excellence and shows

the high power of the network in identifying the trend between its various parameters and its generalizability. This network should be considered as the best network for extrapolation between these three networks. The PNN network had the best performance in estimating porosity in the interpolation sector, which can be considered the most reliable network for interpolation studies, but in the extrapolation sector, it had less estimation power than the RBFN.

Table 1 Function of networks in estimating well porosity HD_1.

Method	RMSE	correlation coefficient
RBFN	0.0199084	0.899568
PNN	0.0198960	0.917815
MLFN	0.0271974	0.863017

Table 2 Function of networks in estimating well porosity HD_6

Method	RMSE	correlation coefficient
RBFN	0.0524825	0.622404
PNN	0.0637268	0.7104735
MLFN	0.0769302	0.4087335

References

1. Iturrarán-Viveros U, Parra J O (2014) Artificial Neural Networks applied to estimate permeability, porosity and intrinsic attenuation using seismic attributes and well-log data, Elsevier Publisher, Journal of Applied Geophysics, 107:45-54.
2. Fausett LV (1994) Fundamentals of Neural Networks Architectures, Algorithms and Applications (chapter 1) 1st ed. Pearson. 3-4
3. Cao J, Yang J, Wang Y, Wang D, Shi Y (2015) Extreme Learning Machine for Reservoir Parameter Estimation in Heterogeneous Sandstone Reservoir, in Mathematical Problems in Engineering, 2015. 287816, 1-10.
4. Ghazban F (2007) Petroleum Geology of the Persian Gulf (chapter 9) 1st ed. Tehran University and National Iranian Oil Company publication, 586-587.
5. Mojeddifar S, Kamali G, Ranjbar H, 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.
6. Huuse M, 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.
7. Russell BH (2004) The application of multivariate statistics and neural networks to the prediction of reservoir parameters using seismic attributes. Ph.D. Dissertation University of Calgary. 17-18.
8. Chopra S, Marfurt K J (2007) Seismic Attributes for Prospect Identification and Reservoir Characterization, Society of Exploration Geophysicists, Tulsa, OK.
9. Orr M J (1996) Introduction to Radial basis function neural networks: Research Report for the Institute of Adaptive and Neural Computation, Division of Informatics University of Edinburgh, 9-11.
10. Specht D F (1990) Probabilistic neural networks, Neural Networks, 3 (1):109-118.