

توصیف مخزن هیدروکربن دار ماسه‌سنگی F3 (دریای شمال) با استفاده از نشانگرهای لرزه‌ای و شبکه‌ی عصبی احتمالاتی

مسعود لشکری‌آهنگرانی^۱، سعید مجددی‌فر^{۲*} و محسن همتی‌چگنی^۳

۱- دانش‌آموخته کارشناسی ارشد مهندسی معدن، دانشگاه صنعتی اراک، اراک

۲ و ۳- استادیار گروه مهندسی معدن، دانشگاه صنعتی اراک، اراک

نویسنده مسئول: mojeddifar@arakut.ac.ir*

نوع مقاله: کاربردی

پذیرش: ۹۹/۱۰/۲۱

دریافت: ۹۹/۶/۱۷

چکیده

اکتشاف ذخایر هیدروکربنی معمولاً بر اساس وارون‌سازی داده‌های لرزه‌ای صورت می‌گیرد که دارای پیچیدگی‌های محاسباتی می‌باشد. لذا ارائه روش‌های ساده‌تر بر مبنای شبکه‌های عصبی احتمالاتی می‌تواند از این پیچیدگی‌ها بکاهد و نیز با توجه به عدم قطعیت کمتر، می‌تواند ابزار قدرتمندی برای کارهای اکتشافی باشد. در این مقاله از شبکه‌ی عصبی احتمالاتی شعاع مینا بر اساس قاعده بیز برای تخمین تخلخل مخزن هیدروکربن دار F3 در دریای شمال استفاده شده است. با توجه به این که محاسبه‌ی احتمال درست‌نمایی بیز وابسته به پارامتری به نام شاخص نرمی است، در این مقاله با استفاده از روش اعتبارسنجی مقایسه‌ای مقدار $0/21$ به عنوان شاخص نرمی بهینه انتخاب گردید. بر این اساس به منظور بالا بردن قدرت تفکیک خروجی شبکه عصبی احتمالاتی، ۱۶ بازه‌ی تخلخل از $0/22$ تا $0/3$ انتخاب شد و سه نشانگر لرزه‌ای انرژی، شباهت و دامنه لحظه‌ای به عنوان ورودی به الگوریتم شبکه عصبی احتمالاتی برگزیده شدند. همچنین روش برازش خطی به منظور تخمین تخلخل میان نشانگرهای ورودی و پارامتر تخلخل به کار گرفته شد. نتایج الگوریتم شبکه عصبی احتمالاتی با نتایج روش برازش خطی در ماتریس هم‌آمیختگی مورد مقایسه قرار گرفت که نتایج ماتریس مذکور نشان می‌دهد که پارامتر صحت کل برای الگوریتم شبکه عصبی احتمالاتی برابر با $0/7587$ و برای معادله‌ی برازش خطی مقاومت صوتی برابر با $0/4623$ است. علاوه بر این، مقایسه‌ی عملکرد دو روش بر روی مقاطع تخمین زده شده نشان می‌دهد که شبکه‌ی عصبی احتمالاتی می‌تواند سازند با تخلخل بیش‌تر را که حاوی گاز است، آشکارسازی نماید. بنابراین با توجه به نتایج به دست آمده، می‌توان شبکه‌ی عصبی احتمالاتی را به عنوان ابزاری مناسب‌تر به منظور تخمین تخلخل سازندها و اکتشاف ذخائر هیدروکربنی نسبت به برازش خطی معرفی نمود.

واژه‌های کلیدی: شبکه‌ی عصبی احتمالاتی، نشانگر انرژی، نشانگر شباهت، نشانگر دامنه لحظه‌ای، شاخص نرمی

۱- پیشگفتار

همکاران، (۱۹۸۱). وارون‌سازی داده‌های برانبارش شده، تکنیکی است که می‌تواند پارامترهای الاستیک مخزن همانند سرعت موج p، سرعت موج s و دانسیته را تخمین بزند. در این بین نشانگر لرزه‌ای مقاومت صوتی زمین که از حاصل ضرب سرعت موج در دانسیته زمین به دست می‌آید معمولاً همبستگی بالایی با پارامتر تخلخل نشان می‌دهد و به همین دلیل محققان زیادی از رابطه ناشی از برازش خطی این نشانگر با تخلخل، برای تخمین تخلخل مخازن هیدروکربنی استفاده می‌کنند. اما وجود پیچیدگی‌های زمین‌شناسی و ناهمگنی در لایه‌های زمین منجر به عدم قطعیت در نتایج این تخمین می‌شود. بنابراین همواره نمی‌توان یک معادله‌ی خطی تجربی به دست آورد که به کل یک مخزن ناهمگن زمین‌شناسی نسبت داد و تخلخل

تخمین توزیع پارامترهای پتروفیزیکی در بین چاه‌های یک مخزن هیدروکربن دار یکی از اهداف مهم در صنعت نفت است. تخلخل یکی از مهم‌ترین پارامترهای پتروفیزیکی در تعیین جانمایی ذخایر گازی در مخازن هیدروکربنی است. از این‌رو اندازه‌گیری‌های آزمایشگاهی از چاه و تفسیر پتروفیزیکی نگارهای چاه می‌تواند تخمین‌های با ارزشی از خصوصیات پتروفیزیکی مخازن به دست آورند (بت و همکاران، ۱۹۵۸). نگارهای حفاری بازه‌ی مکانی محدودی از اطراف یک چاه را گزارش می‌دهند ولی داده‌های لرزه‌نگاری به دلیل پوشش کامل مخزن هیدروکربنی و تفکیک‌پذیری جانبی بهتر و نیز تولید اطلاعات ساختاری و چینه‌ای مفید مورد توجه مفسرین قرار دارند (گرانر و

استفاده از نشانگرهای لرزه‌ای لحظه‌ای و انرژی تخلخل را در یک سازند کربناته تخمین زدند. مطالعات مذکور نشان می‌دهد که استفاده از شبکه‌های عصبی به منظور پیش‌بینی پارامترهای پتروفیزیکی مخازن در بسیاری از موارد کارآمد بوده و سرعت عمل و زمان پردازش داده‌های لرزه‌ای را بهبود می‌بخشد. این تحقیق تلاش دارد با به کارگیری الگوریتمی متفاوت به نام شبکه‌ی عصبی احتمالاتی، با استفاده از نشانگرهای لرزه‌ای به تخمین پارامتر تخلخل در یک مخزن هیدروکربنی ماسه‌سنگی بپردازد. الگوریتم شبکه عصبی احتمالاتی تلفیقی از مدل احتمالاتی بایزین در ساختار شبکه عصبی است. در حقیقت مدل احتمالاتی با در نظر گرفتن ارتباطات میان پارامترهای ورودی الگوریتم، یک توزیع احتمالاتی پسین را محاسبه و خروجی الگوریتم را در یک کلاس مشخص طبقه‌بندی می‌کند. در این تحقیق از داده‌های لرزه‌ای سه بعدی یک مخزن گازی به نام F3 در حومه‌ی کشور هلند استفاده شده است. نشانگرهای لرزه‌ای که در حقیقت توابع ریاضی اعمال شده بر روی سیگنال‌های لرزه‌ای می‌باشند به عنوان ورودی الگوریتم شبکه عصبی احتمالاتی در نظر گرفته شدند. نشانگرهای مورد استفاده به عنوان ورودی به الگوریتم باید دو شرط را دارا باشند: اول این که بیش‌ترین همبستگی را با پارامتر تخلخل نشان دهند و دوم این که کمترین همبستگی را با یکدیگر داشته باشند. نکته‌ی قابل توجه این است که این تحقیق علی‌رغم همبستگی بالای نشانگر مقاومت صوتی با تخلخل از این نشانگر استفاده نمی‌کند چرا که سعی دارد از پیچیدگی‌های روش‌های وارون‌سازی لرزه‌ای همانند تخمین موجک لرزه‌ای دوری کند و راهکاری جایگزین را بر اساس شبکه عصبی احتمالاتی معرفی نماید. به منظور اعتبارسنجی، از ماتریس درهم آمیختگی استفاده شده است. برای این منظور ماتریس درهم آمیختگی شبکه عصبی احتمالاتی و فرمول برازش خطی مقاومت صوتی با پارامتر تخلخل محاسبه گردید و با یکدیگر مقایسه می‌گردد.

مواد و روش‌ها

۱- شبکه عصبی احتمالاتی


شبکه عصبی احتمالاتی برای اولین بار توسط اسپیچ ارائه شد (اسپیچ، ۱۹۹۰). این شبکه در مقایسه با بسیاری از

را مستقیماً از یک تابع تبدیل مقاومت صوتی محاسبه کرد (اندرسون و همکاران، ۱۹۸۶). از سوی دیگر عدم قطعیت‌های موجود در به کارگیری روش‌های وارون‌سازی لرزه‌ای همانند تخمین موجک لرزه‌ای در روش‌های بر مبنای مدل، می‌تواند تخمین پارامتر مقاومت صوتی را با خطا روبه‌رو کند که در توصیف مخزن هیدروکربنی می‌تواند تاثیرگذار باشد. اسکولز و همکاران برای اولین بار ایده استفاده از چند نشانگر لرزه‌ای به طور همزمان را بر اساس رگرسیون چند متغیره به منظور تخمین پارامترهای پتروفیزیکی مطرح کردند (چولز و همکاران، ۱۹۹۴). لیم و همکاران (۲۰۰۸) از شبکه عصبی به منظور تخمین پارامترهای پتروفیزیکی با استفاده از نگار چاه‌ها بهره گرفتند و برخی از محققین از خصوصیات لرزه‌ای به منظور سنگ‌شناسی (سینگ و همکاران، ۲۰۱۶)، تشخیص نگار صوتی و حجم شیل (لی و لی، ۱۹۹۸) و نفوذ پذیری (لیم، ۲۰۰۸) استفاده کردند. همپسون و همکاران (۲۰۰۱) سعی کردند با استفاده از نشانگرهای لرزه‌ای، خصوصیات نگار چاه‌های موجود در منطقه را پیش‌بینی کنند. یکی از این خصوصیات پارامتر تخلخل بود که سعی شده است بدون به کارگیری مقاومت صوتی و به طور مستقیم از نشانگرهای لرزه‌ای محاسبه شود. سوپوچا و استیوارت لاگ تخلخل را با استفاده از نشانگرهای لرزه‌ای و روش‌های زمین‌آماری محاسبه نمودند (سوپوچا و استیوارت، ۲۰۰۴). در مطالعه دیگری عملکرد شبکه عصبی به منظور تخمین تخلخل با روش‌های زمین‌آماری مقایسه گردید و نتایج حاصل از شبکه عصبی قابل قبول ارزیابی شد (مالویک و رسکالو، ۲۰۰۷). زاهوسکی و بارانی (۲۰۰۵) تخلخل را با استفاده از نشانگرهای لرزه‌ای در درون سنگ‌های آهکی تخمین زدند. هو و همکاران (۲۰۰۸) تلاش کردند با به کارگیری شبکه‌های عصبی و روش مونت کارلو خصوصیات فیزیکی مخازن هیدروکربنی با تعداد چاه‌های حفرشده‌ی کم را پیش‌بینی کنند. والنسی (۲۰۰۹) توزیع تخلخل به دست آمده از روش برازش خطی چند متغیره را با شبکه عصبی مقایسه کرد و نشان داد که نتایج حاصل از شبکه عصبی از خطای کمتری برخوردار است. سینگ و همکاران (۲۰۱۶) با به کارگیری شبکه عصبی چند لایه و به کارگیری داده‌های لرزه‌ای به مطالعه و تفسیر دودکش‌های گازی پرداختند. علمیرادی و همکاران (۲۰۱۲) با به کارگیری الگوریتم‌های ماشین‌بردار پشتیبان و شبکه‌ی عصبی و

که $p(c|x)$ احتمال پسین، $p(x|c)$ احتمال درستنمایی و $p(c)$ احتمال پیشین را محاسبه می‌کند. از آنجاییکه احتمال $p(x)$ برای تمام کلاس‌ها (c_i) یکسان است می‌توان از آن در محاسبات صرف نظر نمود و به عنوان یک ثابت آن را در نظر گرفت. احتمال $p(c)$ با استفاده از داده‌های آموزشی موجود محاسبه می‌شود ولی محاسبه‌ی احتمال درستنمایی کار ساده‌ای نیست و اسپچ (۱۹۹۰) برای حل این مشکل، شبکه‌ی عصبی احتمالاتی را پیشنهاد نمود که ساختمان کلی آن مطابق شکل ۱ است.

شبکه‌های عصبی دیگر نظیر الگوریتم پس‌انتشار^۱ سریع‌تر آموزش می‌بیند. در حقیقت این شبکه نوع خاصی از شبکه‌های عصبی شعاع‌منا^۲ است و در بسیاری از مطالعات برای طبقه‌بندی بکار گرفته می‌شود (ویلسون و مارتینز، ۱۹۹۸). منطق اصلی طبقه‌بندی در شبکه عصبی احتمالاتی، منطق بیز بوده که براساس این قاعده، طبقه‌بندی بردار ورودی x در یک کلاس c از رابطه‌ی (۱) محاسبه می‌گردد:

$$p(c|x) = \frac{p(x|c).p(c)}{p(x)} \quad (1)$$



شکل ۱. ساختار چهار لایه‌ی یک شبکه‌ی عصبی احتمالاتی

رابطه‌ی (۲) انتخاب درست شاخص نرمی است که باید با منطق صحیحی تعیین گردد تا بهترین نتیجه‌ی ممکن را حاصل نماید. در این تحقیق با استفاده از روش اعتبارسنجی مقایسه‌ای^۲ بهترین مقدار برای شاخص نرمی انتخاب شده است. در لایه‌ی سوم یک تابع احتمالاتی درست‌نمایی برای هر کلاس c_i محاسبه می‌شود که برای این منظور از توابع گوسین اعمال شده بر روی نمونه‌های آموزشی، در هر کلاس میانگین‌گیری می‌شود و مقدار این تابع برای هر کلاس c_i مطابق رابطه‌ی (۳) به دست می‌آید:

$$p(x|c_i) = \frac{1}{(2\pi)^{d/2} \sigma^d} \frac{1}{N_i} \sum_{j=1}^{N_i} \exp\left[-\frac{(x-x_{ij})^T(x-x_{ij})}{2\sigma^2}\right] \quad (3)$$

که در این رابطه N_i برابر تعداد بردارهای آموزشی مربوط به کلاس i ام است. در نهایت لایه چهارم با استفاده از معادله‌ی (۱) کلاسی را به عنوان خروجی اعلام می‌کند که بیش‌تری را داشته باشد (مایو و همکاران، ۲۰۰۰).

بر اساس شکل ۱، شبکه عصبی احتمالاتی متشکل از چهار لایه است که عبارتند از: ۱- لایه ورودی، ۲- لایه الگو، ۳- لایه تجمیع‌کننده و ۴- لایه تصمیم‌گیری. لایه ورودی، داده‌ی جدید را به صورت بردار دریافت می‌کند و این بردار را به تک‌تک گره‌های موجود در لایه‌ی دوم تحویل می‌دهد (مایو و همکاران، ۲۰۰۰). در هر یک از گره‌های موجود در لایه دوم، یک تابع گوسین با مرکزیت نمونه‌های آموزشی قرار می‌گیرد. این تابع گوسین فاصله‌ی داده جدید را با نمونه‌های آموزشی $(\Phi_{ij}(x))$ مطابق رابطه‌ی (۲) محاسبه می‌کند:

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{d/2} \sigma^d} \exp\left[-\frac{(x-x_{ij})^T(x-x_{ij})}{2\sigma^2}\right] \quad (2)$$

در رابطه‌ی (۲)، d برابر با بعد بردار ورودی یا همان داده‌های آموزشی است، σ برابر انحراف‌معیار است که به آن شاخص نرمی^۱ نیز می‌گویند و x_{ij} بردارهای آموزشی درون هر گروه می‌باشند (ریبرو، ۲۰۰۴). مهم‌ترین نکته‌ی

¹ Smoothing parameter

² Cross validation


¹ Back Propagation

² Radial Basis Function

پیش پردازش داده‌ها

این تحقیق از داده‌های لرزه‌نگاری سه‌بعدی دریایی، در دریای شمال (North sea) (بلوک F3) استفاده کرده است. حوضه F3، بلوکی است که در جنوب دریای شمال در حومه‌ی کشور هلند واقع شده است. سنگ بستر این مخزن در دوره‌ی سنوزوئیک در طی فرایندهای ماگمایی شکل گرفته است و در دوره‌ی نئوژن رسوبگذاری‌های این حوضه‌ی رسوبی با شدت زیاد انجام گرفته است. نرخ رسوبگذاری در این منطقه شدید بوده و عمدتاً از لایه‌های ماسه‌سنگی، شیل و سیلت تشکیل شده است. منطقه

رسوبگذاری اصلی این مخزن به سه لایه تقسیم می‌شود که سازند میانی بیش‌تر ماسه‌سنگی و سازندهای بالا و پایین آن شیلی است. مطالعات و حفاری‌های انجام شده در منطقه نشان می‌دهد که تجمع هیدروکربن منطقه در لایه‌ی میانی این منطقه رخ داده است (سورنسن و همکاران، ۱۹۹۷). از منطقه‌ی مورد مطالعه نگاره‌های دانسیته، گاما و صوتی چهار چاه در اختیار است که از نگار دانسیته برای تخمین تخلخل در اطراف چاه استفاده می‌شود. در شکل ۲ شمای کلی مخزن F3 و موقعیت چاه‌های آن به همراه محدوده‌ی مخزن را نشان داده است.



شکل ۲. نمای سه‌بعدی مخزن F3 به همراه موقعیت چاه‌های مورد استفاده

به منظور آموزش الگوریتم عصبی احتمالاتی از داده‌های چاه‌های ۱، ۲ و ۳ استفاده شد و از چاه ۴ برای اعتبارسنجی الگوریتم مذکور با استفاده از ماتریس درهم‌آمیختگی استفاده گردید. تعداد داده‌های آموزشی به دست آمده از چاه‌های آموزشی کلاً برابر ۶۲۴ داده می‌باشد که ۲۰۸ داده از چاه ۱، ۲۱۵ داده از چاه ۲ و ۲۰۱ داده از چاه ۳ استخراج شده است. همچنین تعداد ۱۹۹ داده از چاه ۴ به عنوان داده‌های تست به دست آمد که در مرحله آموزش الگوریتم عصبی احتمالاتی به کار گرفته نشدند. اطلاعات آماری داده‌های مورد استفاده‌ی این تحقیق در جدول ۱ گزارش شده است. نشانگرهای لرزه‌ای مخزن F3، با استفاده از نرم‌افزار Opendtect محاسبه شدند و سپس به نرم‌افزار MATLAB منتقل و به کمک الگوریتم عصبی احتمالاتی عملیات آموزش، اعتبارسنجی و تخمین مقاطع عمودی انجام گردید. هشت نشانگر لرزه‌ای شباهت، تظاهر، انرژی، دامنه لحظه‌ای، فاز لحظه‌ای، فرکانس لحظه‌ای، هیلبرت لحظه‌ای و فاکتور Q لحظه‌ای در هر نقطه از مخزن F3 با استفاده از نرم‌افزار Opendtect محاسبه گردید. به منظور

بهبود نتایج الگوریتم عصبی احتمالاتی، ماتریس ضرایب همبستگی میان نشانگرهای محاسبه شده مورد توجه قرار گرفت و در جدول ۲ نشان داده شده است. براساس جدول ۲، نشانگر مقاومت صوتی دارای بیش‌ترین ضریب همبستگی با پارامتر تخلخل (۰/۸۷-) می‌باشد. از آنجایی‌که محاسبه‌ی این نشانگر پیچیدگی‌های محاسباتی روش‌های وارون‌سازی را به همراه دارد این تحقیق در نظر دارد بدون استفاده از این نشانگر، الگوریتم عصبی احتمالاتی را آموزش دهد. بنابراین نشانگرهای شباهت، تظاهر، انرژی و دامنه لحظه‌ای به عنوان نشانگرهایی با بالاترین ضریب همبستگی انتخاب شدند. برای بهبود عملکرد الگوریتم باید نشانگرهای ورودی از یکدیگر استقلال آماری نیز داشته باشند. اگر به نشانگرهای انتخابی دقت شود مشاهده می‌شود که نشانگر تظاهر همبستگی بالایی با نشانگر شباهت از خود نشان می‌دهد (۰/۹۶) بنابراین نشانگر تظاهر به دلیل همبستگی کمتر با تخلخل حذف می‌شود و تنها سه نشانگر انرژی، شباهت و دامنه لحظه‌ای مورد استفاده قرار می‌گیرند.

جدول ۱. اطلاعات آماری داده‌های مورد استفاده

نام نشانگر	میانگین	انحراف معیار	حداکثر مقدار	حداقل مقدار	همبستگی با تخلخل
شباهت	۰/۸۸۸۳۳	۰/۰۵۳۴۸	۰/۹۴۸۵۶	۰/۷۴۲۱	۰/۲۹۳۲
تظاهر	۰/۹۵۱۲۱	۰/۰۵۳۲۷	۰/۹۹۳۲۵	۰/۷۶۳۱۷	۰/۲۷۶۴
انرژی	۴۶۴۵۴۶۷	۳۵۲۵۰۲۰	۱/۵E+۰۷	۵۳۲۷۲۷	۰/۳۹۴۱
دامنه لحظه‌ای	۲۴۷۷/۱	۱۷۳۸/۸۶	۷۹۳۱/۸۹	۱۹۳/۰۱۵	۰/۲۵۶۸
فاز لحظه‌ای	-۰/۱۱۲۶۸	۱/۷۰۰۷۷	۳/۲۳۵۵	-۳/۳۰۸۱۷	۰/۰۷۲۷
فرکانس لحظه‌ای	۵۲/۴۴۴۸	۲۲/۳۲۱۶	۱۲۸/۱۴۴	۱/۳۵۰۸۶	۰/۱۷۰۳
هیلبرت لحظه‌ای	-۱۶۶/۰۶۸	۲۰۱۸/۷۳	۶۳۶۳/۰۱	-۷۱۴۴/۶۳	۰/۱۱۴۴
فکتور Q لحظه‌ای	-۹/۸۶۹۱۴	۳۰/۶۹۰۲	۱۶/۲۱۶۷	-۳۹۶/۷۰۴	۰/۰۹۱۵

جدول ۲. ماتریس همبستگی نشانگرهای لرزه‌ای


مقاومت صوتی	فکتور Q لحظه‌ای	هیلبرت لحظه‌ای	فرکانس لحظه‌ای	فاز لحظه‌ای	دامنه لحظه‌ای	انرژی	تظاهر	شباهت	تخلخل	
-۰/۸۷	۰/۰۹	۰/۱۱	-۰/۱۷	۰/۰۷	۰/۲۷	۰/۳۹	۰/۲۷	-۰/۲۹	۱	تخلخل
-۰/۳۹	۰/۰۲	۰/۰۳	-۰/۱۵	۰/۰۸	۰/۲۷	۰/۴۶	۰/۹۶	۱	-۰/۲۹	شباهت
-۰/۳۴	۰/۰۴	۰/۰۸	-۰/۱۴	۰/۱۱	۰/۱۵	۰/۳۱	۱	۰/۹۶	۰/۲۷	تظاهر
-۰/۴۱	۰/۰۲	۰/۰۲	-۰/۰۲	۰/۰۷	۰/۵۸	۱	۰/۳۱	۰/۴۶	۰/۳۹	انرژی
-۰/۳۱	۰/۰۵	۰/۱	-۰/۲۱	۰/۰۸	۱	۰/۵۸	۰/۱۵	۰/۲۷	۰/۲۷	دامنه لحظه‌ای
-۰/۱۴	۰/۰۳	۰/۶۴	-۰/۰۷	۱	۰/۰۸	۰/۰۷	۰/۱۱	۰/۰۸	۰/۰۷	فاز لحظه‌ای
۰/۱۵	-۰/۰۶	-۰/۰۴	۱	-۰/۰۷	-۰/۲۱	-۰/۰۲	-۰/۱۴	-۰/۱۵	-۰/۱۷	فرکانس لحظه‌ای
-۰/۱۵	۰/۰۶	۱	-۰/۰۴	۰/۶۴	۰/۱	۰/۰۲	۰/۰۸	۰/۰۳	۰/۱۱	هیلبرت لحظه‌ای
-۰/۱۲	۱	۰/۰۶	-۰/۰۶	۰/۰۳	۰/۰۵	۰/۰۲	۰/۰۴	۰/۰۲	۰/۰۹	فکتور Q لحظه‌ای
۱	-۰/۱۲	-۰/۱۵	۰/۱۵	-۰/۱۴	-۰/۳۱	-۰/۴۱	-۰/۳۴	-۰/۳۹	-۰/۸۷	مقاومت صوتی

نتایج و بحث

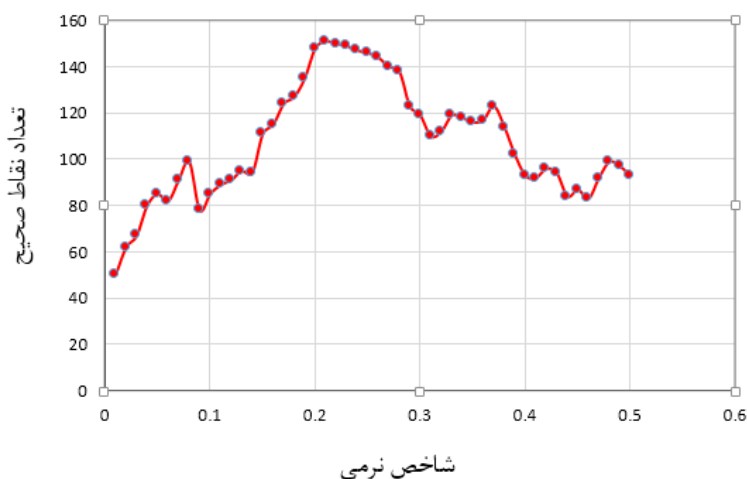
۱- توصیف مخزن هیدروکربنی گازدار F3:

می‌کند. در شکل ۳، ساختار ورودی‌ها و خروجی شبکه عصبی احتمالاتی نشان داده شده است. الگوریتم شبکه عصبی احتمالاتی در محیط نرم‌افزار MATLAB کدنویسی شد. با توجه به آنکه دقت شبکه عصبی احتمالاتی بر اساس محاسبه‌ی درست تابع درست‌نمایی برای هر کلاس است و مقدار تابع درست‌نمایی به شاخص نرمی وابسته است، بنابراین تخمین مقدار بهینه شاخص نرمی در این روش اهمیت زیادی دارد. به منظور تعیین مقدار بهینه شاخص نرمی از تکنیک اعتبارسنجی مقایسه‌ای (هو و همکاران، ۲۰۰۸) استفاده شد. برای این منظور به کمک نرم‌افزار MATLAB داده‌های چاه ۴ به عنوان داده‌های اعتبارسنجی به کار گرفته شد و به ازای مقادیر مختلف شاخص نرمی تعداد داده‌هایی که کلاس آن‌ها درست تخمین زده شده‌اند در شکل ۴ نشان داده شده است. شکل ۴ نشان می‌دهد بیش‌ترین صحت زمانی حاصل می‌شود که مقدار شاخص نرمی برابر ۰/۲۱ گردد.

تعداد ۶۲۴ داده شامل سه نشانگر انرژی، شباهت و دامنه لرزه‌ای مربوط به چاه‌های شماره ۱، ۲ و ۳ به صورت تصادفی انتخاب شد و مقادیر نرمال شده آن‌ها برای آموزش شبکه عصبی احتمالاتی مورد استفاده قرار گرفت و داده‌های چاه ۴ برای اعتبارسنجی تخمین‌های شبکه آموزش دیده استفاده شد. مقادیر این نشانگرهای لرزه‌ای با استفاده از نرم‌افزار Opendtect بر روی مخزن F3 محاسبه و استخراج گردید. خروجی شبکه احتمالاتی آموزش دیده، کلاس‌های مختلف تخلخل است. از آنجایی که تخلخل یک متغیر پیوسته است و دامنه‌ی تغییرات آن در مخزن F3 بین ۰/۲۲ تا ۰/۳ تغییر می‌کند بنابراین با گام ۰/۰۵ در ۱۶ گروه طبقه‌بندی شد که شبکه احتمالاتی، براساس بردار ورودی (انرژی، شباهت و دامنه لحظه‌ای) طبقه تخلخل مرتبط را به عنوان خروجی مشخص



شکل ۳. ساختار ورودی‌ها و خروجی شبکه عصبی احتمالاتی



شکل ۴. نمودار صحت داده‌های اعتبارسنجی در مقابل تغییرات شاخص نرمی

هیدروکربنی استفاده گردید. مقاطع طبقه‌بندی شده توسط شبکه عصبی احتمالاتی در in-line 244 و in-line 336 مخزن F3 در شکل ۵ نشان داده شده است. همانطور که در شکل ۵ مشاهده می‌شود، می‌توان سه لایه با تغییرات تخلخل قابل توجه را در منطقه تشخیص داد. زون‌های A و C نشان‌دهنده مناطق با تخلخل پایین هستند و زون B نمایش‌دهنده تخلخل بالا است. براساس مطالعات زمین‌شناسی مخزن F3، تجمع هیدروکربن گازی در زون B رخ داده است.

به منظور مقایسه‌ی خروجی‌های به دست آمده از الگوریتم عصبی احتمالاتی با روش‌های مرسوم تخمین تخلخل در مخزن هیدروکربنی، از روش برازش خطی نشانگر مقاومت صوتی با پارامتر تخلخل به دست آمده از نگار دانسیته استفاده می‌گردد. همانطور که بیان شد نشانگر مقاومت صوتی، همبستگی قابل توجه‌ای را با پارامتر تخلخل نشان می‌دهد که براساس این می‌توان تخلخل را با استفاده از معادله‌ی خطی حاصل از برازش به دست آورد. شکل ۶ خط برازش شده بر روی نقاط مقاومت صوتی در مقابل پارامتر تخلخل مخزن F3 را نشان می‌دهد. نقاط نشان داده

پس از آموزش کامل شبکه‌ی عصبی احتمالاتی با داده‌های آموزشی، از ماتریس درهم‌آمیختگی به منظور ارزیابی عملکرد این الگوریتم استفاده گردید. نتایج طبقه‌بندی شده‌ی ۱۹۹ داده‌ی تست از چاه ۴ با استفاده از الگوریتم شبکه عصبی احتمالاتی در ماتریس درهم‌آمیختگی (جدول ۳) ارائه شده است. هر ستون و هر سطر از جدول ۳ یک طبقه‌ی تخلخل را نشان می‌دهد که با مقدار وسط از هر بازه‌ی تخلخل نشان داده شده است. اعداد نشان داده شده بر روی قطر اصلی این ماتریس، تعداد پیکسل‌هایی را نشان می‌دهد که به درستی در طبقه‌ی مورد نظر طبقه‌بندی شده‌اند ولی اعداد درایه‌های غیر از قطر اصلی، طبقه‌بندی اشتباه این پیکسل‌ها را در طبقات دیگر نشان می‌دهد. پارامتر صحت کلی که برابر است با نسبت کل پیکسل‌های درست طبقه‌بندی شده (درایه‌های قطر اصلی ماتریس) به کل پیکسل‌های مورد استفاده، برای الگوریتم عصبی احتمالاتی برابر با ۰/۷۵۸۷ ارزیابی شده است که برای تخمین تخلخل چاه ۴ به عنوان چاه تست، کارایی قابل‌قبولی در نظر گرفته می‌شود. بنابراین از این الگوریتم به منظور طبقه‌بندی تخلخل در مقاطع مخزن

درصد انطباق معادله‌ی برازش (معادله‌ی ۴) بر روی داده‌های آموزشی، برابر ۰/۸۷ می‌باشد و همچنین به منظور ارزیابی عملکرد معادله‌ی ۴ برای تخمین تخلخل مخزن F3، از همان ۱۹۹ داده‌ی تست چاه ۴ استفاده گردید که ماتریس درهم‌آمیختگی آن در جدول ۴ گزارش شده است.



شده در شکل ۶ همان ۶۲۴ داده‌ی آموزشی استفاده شده برای شبکه‌ی عصبی احتمالاتی می‌باشد. معادله‌ی خط برازش داده شده در شکل ۶ برابر است با:

$$porosity = (-2.3 * 10^{-5}) * AI + 0.664108 \quad (4)$$

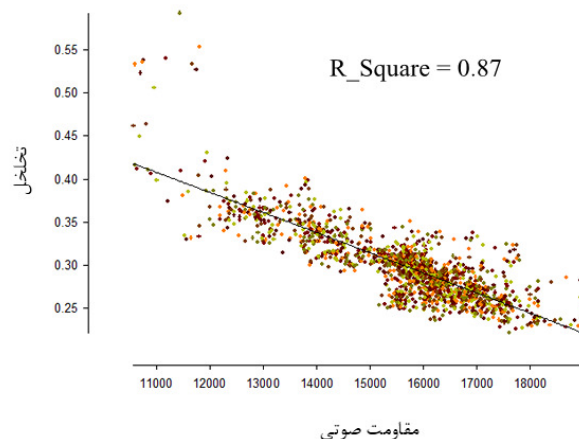
جدول ۳. ماتریس در هم‌آمیختگی برای الگوریتم عصبی احتمالاتی

ماتریس	۰/۲۵۲۵	۰/۲۵۷۵	۰/۲۶۲۵	۰/۲۶۷۵	۰/۲۷۲۵	۰/۲۷۷۵	۰/۲۸۲۵	۰/۲۸۷۵	۰/۲۹۲۵	۰/۲۹۷۵	مجموع
۰/۲۵۲۵	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱
۰/۲۵۷۵	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۰/۲۶۲۵	۱	۳	۳۳	۱	۰	۱	۰	۰	۱	۰	۴۰
۰/۲۶۷۵	۰	۰	۰	۳	۰	۰	۰	۰	۰	۰	۳
۰/۲۷۲۵	۰	۱	۱	۱	۱۰	۰	۰	۱	۰	۱	۱۵
۰/۲۷۷۵	۰	۰	۱	۴	۲	۷۱	۳	۲	۰	۲	۸۵
۰/۲۸۲۵	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱
۰/۲۸۷۵	۱	۰	۰	۰	۰	۰	۱	۶	۱	۲	۱۱
۰/۲۹۲۵	۰	۰	۰	۰	۰	۱	۱	۱	۱۰	۲	۱۵
۰/۲۹۷۵	۰	۰	۰	۰	۰	۲	۰	۵	۴	۱۷	۲۸
مجموع	۳	۴	۳۵	۹	۱۲	۷۵	۵	۱۵	۱۶	۲۵	۱۹۹

صحت کلی: ۰/۷۵۸۷



شکل ۵. (a) مقطع تخلخل طبقه‌بندی شده توسط شبکه عصبی احتمالاتی در in-line 244، (b) مقطع تخلخل طبقه‌بندی شده توسط شبکه عصبی احتمالاتی در in-line 336



شکل ۶. نمودار متقاطع داده‌های تخلخل در مقابل مقاومت صوتی در مخزن F3.


جدول ۴. ماتریس در هم‌آمیختگی رابطه خطی مقاومت صوتی زمین

ماتریس	۰/۲۵۲۵	۰/۲۵۷۵	۰/۲۶۲۵	۰/۲۶۷۵	۰/۲۷۲۵	۰/۲۷۷۵	۰/۲۸۲۵	۰/۲۸۷۵	۰/۲۹۲۵	۰/۲۹۷۵	مجموع
۰/۲۵۲۵	۱	۲	۹	۱	۱	۰	۰	۰	۰	۰	۱۴
۰/۲۵۷۵	۰	۰	۲	۰	۵	۰	۰	۳	۰	۰	۱۰
۰/۲۶۲۵	۲	۲	۱۸	۳	۰	۲	۰	۰	۰	۰	۲۷
۰/۲۶۷۵	۰	۰	۵	۱	۴	۳	۱	۰	۰	۰	۱۴
۰/۲۷۲۵	۰	۰	۰	۴	۲	۱۶	۰	۶	۰	۰	۲۸
۰/۲۷۷۵	۰	۰	۰	۰	۰	۴۰	۰	۰	۰	۰	۴۰
۰/۲۸۲۵	۰	۰	۰	۰	۱	۳	۱	۳	۰	۲	۱۰
۰/۲۸۷۵	۰	۰	۰	۰	۰	۰	۰	۱	۱	۰	۲
۰/۲۹۲۵	۰	۰	۱	۰	۰	۰	۱	۲	۹	۳	۱۶
۰/۲۹۷۵	۰	۰	۱	۰	۳	۵	۲	۲	۶	۱۹	۲۸
مجموع	۳	۴	۳۶	۹	۱۶	۶۹	۵	۱۷	۱۶	۲۴	۱۹۹

صحت کلی: ۰/۴۶۲۳

منطقه مورد مطالعه، زون A و C لایه‌هایی با شیل و سیلت بیش‌تری نسبت به لایه‌ی B می‌باشد که انتظار می‌رود لایه‌ی B با مقدار تخلخل بیش‌تری گزارش داده شود. اگر به خروجی‌های الگوریتم عصبی احتمالاتی دقت شود، لایه‌ی B با تخلخل بیش‌تری نسبت به روش برازش خطی مقاومت صوتی مجزا شده است که نتایج قابل قبول‌تری می‌باشد همانطور که ماتریس درهم‌آمیختگی نیز این موضوع را اثبات می‌کند. از طرف دیگر، به دلیل این که محاسبه‌ی مقاومت صوتی یک مخزن با استفاده از داده‌های لرزه‌ای نیازمند روش‌های ریاضی پیچیده‌ی وارون‌سازی است بنابراین استفاده از شبکه‌ی عصبی احتمالاتی می‌تواند گزینه‌ی جایگزین مناسب‌تری برای تخمین پارامترهای پتروفیزیکی مخزن باشد.

براساس نتایج به دست آمده از چاه شماره‌ی ۴، پارامتر صحت کلی برای معادله‌ی ۴ برابر با ۰/۴۶۲۳ به دست می‌آید که در مقابل الگوریتم عصبی احتمالاتی، صحت عملکرد آن کاهش چشمگیری پیدا کرده است. مقادیر پارامتر تخلخل در in-line و in-line 244 بر اساس رابطه (۴) محاسبه شد. شکل ۷ تخلخل تخمین‌زده شده توسط معادله‌ی برازش خطی مقاومت صوتی در in-line 244 و in-line 336 را نشان می‌دهد. همانطور که شکل ۷ نشان می‌دهد معادله‌ی برازش خطی، سه لایه‌ی رسوبگذاری منطقه را با تغییرات تخلخل نشان می‌دهد به طوریکه لایه‌ی B با تخلخل بیش‌تری نسبت به دو لایه‌ی بالایی و پایینی نمایش داده شده است. براساس گزارشات زمین‌شناسی



شکل ۷. (a): مقطع تخلخل طبقه‌بندی شده توسط معادله‌ی برازش خطی در **in-line 336**. (b): مقطع تخلخل طبقه‌بندی شده توسط معادله‌ی برازش خطی در **in-line 244**. مقیاس عمودی: زمان (ms) و مقیاس افقی: خطوط عرضی (Cross Lines).

نتیجه‌گیری

را ندارد بنابراین می‌تواند به راحتی جایگزین مطمئنی برای این روش باشد.

نتایج بدست آمده در این تحقیق نشان می‌دهد که تخمین پارامتر تخلخل توسط شبکه عصبی احتمالاتی دقیق‌تر از تخمین تخلخل توسط برازش خطی بین تخلخل و مقاومت صوتی است چرا که تعمیم یک رابطه خطی بین تخلخل و مقاومت صوتی به کل مخزن دقت کافی را ندارد.

تشکر و قدردانی

نویسندگان از داوران محترم نشریه یافته‌های نوین زمین‌شناسی کاربردی که در جهت ارتقای کیفیت این مقاله، پیشنهادات ارزنده‌ای ارائه نمودند، کمال تشکر و قدردانی را دارند.

منابع

- Alimoradi, A., Moradzadeh, A., Bakhtiari, M. R. (2012) LEARNING TECHNIQUES. Journal of Seismic Exploration, 21: 323-345.
- Anderson, J. A., Golden, R. M., Murphy, G. L. (1986) Concepts in distributed systems. in Optical and hybrid

این تحقیق از وارون‌سازی داده‌های لرزه‌ای توسط شبکه عصبی احتمالاتی و برازش خطی مقاومت صوتی با پارامتر تخلخل استفاده نموده است تا توزیع تخلخل مخزن گازدار F3 در دریای شمال را پیش‌بینی نماید.

نتایج تخلخل بدست آمده از الگوریتم‌های مورد استفاده توسط ماتریس درهم‌آمیختگی مورد اعتبارسنجی قرار گرفت که پارامتر صحت کل برای الگوریتم عصبی احتمالاتی برابر با ۰/۷۵۸۷ و برای معادله‌ی برازش خطی برابر با ۰/۴۶۲۳ به دست آمده است.

براساس مطالعات زمین‌شناسی مخزن F3، لایه‌ی B باید تخلخل بیشتری را نسبت به لایه‌های اطراف خودش نشان دهد که این امر در خروجی‌های الگوریتم عصبی احتمالاتی به خوبی قابل مشاهده است.

روش وارون‌سازی داده‌های لرزه‌ای توسط شبکه عصبی احتمالاتی به منظور تخمین پارامترهای پتروفیزیکی مخزن، پیچیدگی‌های روش مرسوم وارون‌سازی داده‌های لرزه‌ای و تعیین مقاومت صوتی

- Wilson, D. R., Martinez, T. R (1998) Improved center point selection for probabilistic neural networks. in *Artificial Neural Nets and Genetic Algorithms*. Springer.
- computing. International Society for Optics and Photonics.
- Bethe, H. A., Fuchs, K., Hirschfelder, J. O. Magee, J. L., Neumann, R. V (1958) Blast wave, (No. LA-2000), Los Alamos National Lab, NM.
- Graebner, R., Wason, C., Meinar, H (1981) Seismic Explorati. Science, 211: p. 6.
- Hampson, D. P., Schuelke, J. S., Quirein, J. A (2001) Use of multiattribute transforms to predict log properties from seismic data. *Geophysics*, 66(1): 220-236.
- Hou, J., Takahashi, T., Katoh, A., Jaroonsitha, S., Chumsena, K., Nakayama, K (2008) Application of seismic attributes and neural network for sand probability prediction-A case study in the North Malay Basin. *Bull. Geol. Soc. Malaysia*, 54: 115-121.
- Lim, J. S (2008) Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea. *Journal of Petroleum Science and Engineering*, 49(3): 182-192.
- Liu, Z., Liu, J (1998) Seismic-controlled nonlinear extrapolation of well parameters using neural networks. *Geophysics*, 63(6): 2035-2041.
- Malvić, T., Prskalo, S (2007) Some benefits of the neural approach in porosity prediction (Case study from Beničanci field). *Nafta: exploration, production, processing, petrochemistry*, 58(9): 455-467.
- Mao, K. Z., Tan, K. C., Ser, W (2000) Probabilistic neural-network structure determination for pattern classification. *IEEE Transactions on neural networks*,. 11(4): 1009-1016.
- Ribeiro, M. I (2004) Gaussian probability density functions: Properties and error characterization. Institute for Systems and Robotics, Lisboa, Portugal.
- Schultz, P. S., Ronen, S., Hattori, M., Corbett, C (1994) Seismic-guided estimation of log properties (Part 1: A data-driven interpretation methodology). *The Leading Edge*, 13(5): 305-310.
- Singh, D., Kumar, P. C., Sain, K (2016) Interpretation of gas chimney from seismic data using artificial neural network: A study from Maari 3D prospect in the Taranaki basin, New Zealand. *Journal of Natural Gas Science and Engineering*, 36: 339-357.
- Sørensen, J. C., Gregersen, U., Breiner, M., Michelsen, O (1997) High-frequency sequence stratigraphy of Upper Cenozoic deposits in the central and southeastern North Sea areas. *Marine and Petroleum Geology*, 14(2): 99-123.
- Soubotcheva, N., Stewart, R. R (2004) Predicting porosity logs from seismic attributes using geostatistics. *CREWES Res. Rep.*. 16.
- Specht, D. F (1990) Probabilistic neural networks. *Neural networks*, 3(1): 109-118.
- Valenti, J. C. A. F (2009) Porosity prediction from seismic data using multiattribute transformations, N Sand, Auger Field, Gulf of Mexico.

Reservoir characterization of F3 block (North Sea) using seismic attributes and probabilistic neural network

M. Lashkari ahangarani¹, S. Mojeddifar^{*2} and M. hemmati chegeni³

1- M. Sc., (graduated), Dept., of Mining Engineering, Arak University of Technology, Arak

2, 3- Assist. Prof., Dept., of Mining Engineering, Arak University of Technology, Arak

* mojeddifar@arakut.ac.ir

Received: 2020/9/7 Accepted: 2021/1/10

Abstract

Hydrocarbon explorations usually are performed based on seismic inversion techniques in which there exists computational complexity. Therefore, application of simpler methods such as probabilistic neural network could be considered to decrease uncertainties of the results. The present research used a probabilistic neural network to characterize the sand reservoir of F3 block in North Sea. This algorithm applied the seismic attributes of energy, similarity and instantaneous amplitude as input parameters to estimate porosity distribution of the F3 reservoir. Calculating the likelihood probability is dependent on the smoothing parameter. Therefore, the cross validation technique was used to determine the smoothing parameter that equals to 0.21. This paper considered 16 porosity classes from 0.22 to 0.3 as output of probabilistic algorithm. This algorithm calculated the posterior probability for every point in reservoir to determine the class of each point. The maximum posterior probability was selected as the final output. The obtained results were compared with the linear equation driven regression model for acoustic impedance and porosity values. The comparison showed that the developed network could detect gas-bearing region. Also, the confusion matrix was used to validate the results and the total accuracy parameter was calculated as 0.7587 and 0.4623 for probabilistic neural network and linear regression, respectively. Therefore, Bayesian neural network could be introduced as an effective tool to explore the hydrocarbon-bearing layers because of computational complexity of seismic inversion techniques.

Keywords: Probabilistic neural network, Energy, Similarity, Instantaneous amplitude, Smoothing parameter.