

## پیش بینی میزان تراوایی سنگ مخزن با استفاده از داده‌های پتروفیزیکی

مرتضی احمدی<sup>۱</sup>؛ علی یزدیان<sup>۲</sup>؛ محسن صائمی<sup>۳</sup>

۱- دانشگاه تربیت مدرس، Tel: ۰۹۱۲۲۰۸۰۶۷۷

۲- دانشگاه تربیت مدرس، Tel: ۰۹۱۲۱۵۹۴۶۵۴

۳- دانشگاه تربیت مدرس، Tel: ۰۹۱۲۴۵۴۴۵۴۱، mo\_saemi@yahoo.com

(دریافت ۱۷ خرداد ۱۳۸۵، پذیرش ۵ دی ۱۳۸۵)

### چکیده

تراوایی مهمترین پارامتر کلیدی در توصیف یک مخزن هیدروکربوری می‌باشد. مقادیر تراوایی معمولاً از آزمایش‌های چاه و مغزه‌های حفاری بدست می‌آید. لذا باید توجه داشت که اغلب داده‌های به‌دست آمده از مغزه‌ها و آزمایش‌های چاه در تعداد کمی از چاه‌های یک میدان موجود است. از طرفی تقریباً در تمامی چاه‌های میدان نمودارنگاری صورت می‌گیرد. بنابراین استفاده از روش‌هایی که بتوانند از روی نمودارهای چاه‌نگاری به تخمین پارامترهای فوق‌پردازند بسیار مفید خواهد بود. پیش‌بینی تراوایی مناسب و رسم توزیع آن با استفاده از نمودارهای چاه‌پیمایی از اهداف اصلی این تحقیق می‌باشد. لذا برای نیل به این هدف، از روش شبکه عصبی برای ایجاد مدل تراوایی میدان نفتی مشترک پارس جنوبی که در خلیج فارس و در ۱۰۰ کیلومتری ساحل واقع است، استفاده شده است. نتایج به‌دست آمده نشان می‌دهد که مدل مذکور به خوبی قادر به تخمین مقادیر تراوایی در نقاط مختلفی از مخزن مورد مطالعه می‌باشد.

### کلمات کلیدی

تراوایی، نمودارهای چاه‌پیمایی، مخازن هیدروکربوری، شبکه عصبی

## ۱- مقدمه

اهمیت توصیف مخزن، به دلیل توانایی آن در تشخیص پارامترهای اساسی زمین شناسی و پتروفیزیکی مؤثر در حرکت سیال در نواحی هیدروکربوری، به عنوان یک پارامتر اساسی زمین شناسی و پتروفیزیکی مؤثر در حرکت سیال می باشد [۱۰]. پیش بینی مقادیر تراوایی سازندها همواره یکی از مشکلات اساسی برای مهندسین نفت بوده است. اطلاعات به دست آمده از تراوایی سازندها، قابلیت طراحی و مدیریت فرایندهای مؤثر در توسعه میادین نفت و گاز را به مهندسین می دهد. در پروژه های مهندسی نفت تعیین محل بهینه چاه های تولیدی و توسعه ای در یک میدان نفتی دارای اهمیت به سزایی است. به دست آوردن کاراکترهای مهم مخزنی نظیر تراوایی می تواند در تعیین محل بهینه برای حفاری چاه های بعدی مفید باشد.

در پروژه های مهندسی نفت اغلب کمبود داده های ضروری، مثل مغزه ها یا آزمایش های برجای درون چاهی به علت هزینه های بسیار بالا احساس می گردد. علاوه بر این ممکن است پروژه مذکور، متحمل هزینه های غیر اقتصادی با توجه به از دست دادن ذخایر نفتی در حین تولید (در روش آزمایش فشار) گردد. از طرفی در سال های اخیر استفاده از سیستم های هوشمند مانند منطق فازی، شبکه های عصبی مصنوعی و نروفازی به طور گسترده ای در صنعت نفت رواج داشته است. از این رو با استفاده از سیستم های هوشمند در ایجاد داده های مورد نیاز و کاهش هزینه ها، می توان طرح توسعه یک میدان نفتی را تا میزان بالایی بهبود بخشید [۲،۷].

در این مطالعه، شبکه عصبی مدلی را ارائه می دهد که در آن می توان نحوه توزیع تراوایی را در هر نقطه از میدان به دست آورد. لذا با توجه به اینکه تعیین بهینه چاه های تولیدی در مراحل توسعه میدان دارای اهمیت به سزایی است، از این روش می توان برای شناسایی لایه های تراوایی سنگ مخزن در نقاطی که در آنها اطلاعات مغزه در دسترس نیست، استفاده نمود.

پیش از این روش های تجربی تعیین تراوایی از نمودارهای چاه پیمایی بر اساس مدل کوزنی - کارمن<sup>۱</sup> (۱۹۳۷) ارائه شده است. روابط تجربی دیگری نیز توسط وایلی، رز<sup>۲</sup> (۱۹۵۰) و شولومبرژه<sup>۳</sup> (۱۹۹۱) مطرح شده است [۱۱].

در میان تمامی روش های تعیین تراوایی از نمودارهای چاه، قابلیت شبکه های عصبی در پیش بینی مقادیر تراوایی سنگ مخزن بسیار مورد توجه محققین قرار گرفته است. اخیراً

مطالعات انجام شده توسط اربوگاست، فرانکلین<sup>۴</sup> (۱۹۹۹) و وانک<sup>۵</sup> و همکارانش (۲۰۰۰) نشان داده است که شبکه های عصبی به صورت بالقوه توانایی زیادی جهت تخمین خصوصیات پتروفیزیکی سازندها از سایر پارامترهای فیزیکی سنگ مخزن دارا می باشند [۱، ۱۰]. کاربرد سیستم های عصبی در تعیین خصوصیات فیزیکی مخزن، اولین بار توسط داوتون و پرنسکی<sup>۶</sup> (۱۹۹۲)، همچنین بالان<sup>۷</sup> و همکارانش (۱۹۹۵) صورت گرفت [۵]. بعد از آن محقق<sup>۸</sup> و همکارانش (۱۹۹۶) توانستند با استفاده از شبکه های عصبی به تخمین تراوایی از روی تخلخل و اشباع آب بپردازند. به طور کلی تلاش های زیادی در زمینه پیش بینی پارامترهای فیزیکی سنگ مخزن با استفاده از سیستم های هوشمند انجام شده است [۹].

نکته حائز اهمیت در این مطالعه استفاده از نمودارهای متعدد و جدید مانند نمودار جذب فتوالکتریک و مقاومت ویژه است که در گذشته از آنها در فرآیند مدل سازی استفاده نشده است. علاوه بر این تاثیر عمق سازندها به عنوان ویژگی فیزیکی سازندهای مخزن، بر روی تغییرات تراوایی در جای خود قابل ملاحظه می باشد.

## ۲- زمین شناسی منطقه

میدان پارس جنوبی<sup>۹</sup> بزرگترین مخزن گازی جهان است که در خط مرزی ایران و قطر واقع در خلیج فارس می باشد. اطلاعات به دست آمده از میدان پارس جنوبی، مبتنی بر مطالعات لرزه ای و چاه های اکتشافی است که از سالهای ۱۹۸۸ تا ۲۰۰۳ میلادی انجام شده اند. در میدان مورد مطالعه چندین مخزن نفتی و گازی با توجه به اطلاعات به دست آمده مشخص شده است. در این میان مخازن نفتی میدان پارس جنوبی در سازندهای خامی<sup>۱۰</sup> و بنگستان<sup>۱۱</sup> واقع شده است. علاوه بر این، مخازن در بردارنده هیدروکربن های گازی در سازندهای کنگان<sup>۱۲</sup> و دالان<sup>۱۳</sup> قرار دارند که این سازندها به ترتیب دارای سن های زمین شناسی تریاس و پرمین می باشند. رسوب گذاری سازندهای کربناته در محیط های دریایی کم عمق و در اواسط دوره پرمین شروع شده، و تا اوایل دوره تریاس به طول انجامیده است.

## ۳- مطالعات پتروفیزیکی

## ۳-۱- نمودارهای چاه پیمایی

میدان پارس جنوبی در سال ۱۹۹۰ توسط اولین چاه اکتشافی مورد بررسی قرار گرفت که در نتیجه آن سازندهای گازی کنگان و دالان شناسایی شدند. بعد از آن چاه‌های زیادی به منظور اکتشاف و طرح توسعه میدان حفر شدند که عملیات نمودارنگاری از چاه تقریباً در تمامی آنها انجام شده و اطلاعات پتروفیزیکی مفیدی در دسترس می‌باشد. داده‌های به‌دست آمده از این نمودارها که در ارزیابی پتروفیزیکی سازندهای مورد مطالعه بسیار مؤثرند شامل:

نمودارهای پرتو گاما<sup>۱۴</sup>، دانسیته کل<sup>۱۵</sup>، اشباع آب<sup>۱۶</sup>، صوتی (DT)، نوترون<sup>۱۷</sup>، عمق و فاکتور جذب فتوالکتریک<sup>۱۸</sup> و مقاومت ویژه الکتریکی<sup>۱۹</sup> می‌باشند.

## ۳-۲- مطالعات مغزه

استفاده از ابزارهای مغزه‌گیری و استخراج مغزه‌ها از ناحیه تولیدی و اندازه‌گیری تراوایی آن تحت شرایط شبیه‌سازی شده داخل چاه، یکی از قدیمی‌ترین روش‌ها برای اندازه‌گیری تراوایی سازندها می‌باشد. مغزه‌گیری از هر چاه موجود در یک میدان بزرگ، بسیار پرهزینه است. ولی لازم است که مغزه‌گیری در چند چاه بدون اهمیت به این موضوع که میدان مورد نظر بزرگ یا کوچک است، انجام شود. بنابراین باید سعی کرد تا نمونه‌های معرف<sup>۲۰</sup> از هر چاه تهیه شوند.

به‌طور کلی در میدان پارس جنوبی در ۱۱ چاه عملیات مغزه‌گیری در سازندهای کنگان و دالان انجام شده است. اطلاعات به‌دست آمده از این مغزه‌ها شامل داده‌های تراوایی افقی و قائم، تخلخل و دانسیته می‌باشد که در آزمایشگاه مورد مطالعه و اندازه‌گیری قرار گرفته‌اند.

همانطور که ملاحظه می‌شود محدودیت‌های اجرایی از لحاظ هزینه و زمان در حین عملیات مغزه‌گیری باعث می‌گردد تا عملیات برداشت مغزه از سنگ مخزن توجیه اقتصادی نداشته باشد. با این حال نباید فراموش کرد که وجود چنین داده‌هایی در روند طراحی و توسعه مدل‌های تحلیل‌گر اجتناب‌ناپذیر است، زیرا اطلاعات به‌دست آمده از مغزه‌ها، بخشی از داده‌های مفید و با ارزش را ایجاد می‌نمایند.

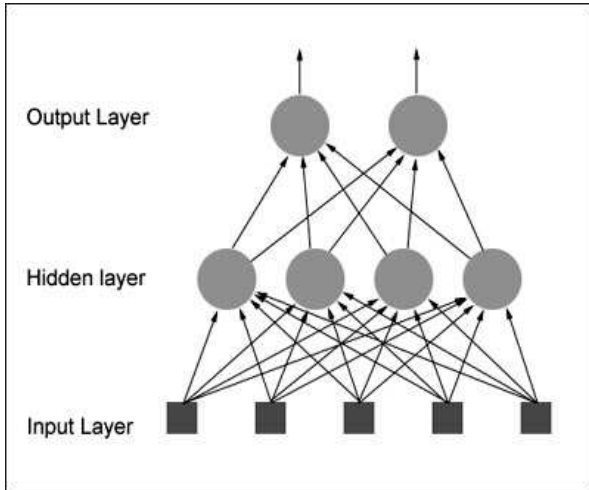
## ۴- روش‌های تعیین تراوایی در مخازن هیدروکربوری

روش‌های متفاوتی برای تخمین میزان تراوایی از روی نمودارها وجود دارند که به‌طور کلی می‌توان آنها را به سه دسته تقسیم کرد. روش‌های تجربی<sup>۲۱</sup>، روش‌های آماری<sup>۲۲</sup>، و مدل‌سازی عصبی<sup>۲۳</sup>. روش‌های تجربی، با اندازه‌گیری تخلخل و اشباع آب کاهش نیافتنی<sup>۲۴</sup> از نمونه‌های استوانه‌ای سنگ، و با توسعه مدل‌های ریاضی که ارتباط بین تخلخل و اشباع آب کاهش نیافتنی با تراوایی را نشان می‌دهند، خلاصه می‌شود. مرحله بعد، در این روش به‌دست آوردن بهترین تخمین از تخلخل و اشباع آب کاهش نیافتنی از نمودارهای چاه و به دنبال آن به کار گرفتن آنها جهت پیش‌بینی تراوایی است.

مهم‌ترین قسمت در این مرحله، ایجاد یک رابطه میان تخلخل و اشباع آب کاهش نیافتنی با تراوایی است. یکی از معایب این روش این است که برای به‌دست آوردن تراوایی لازم است تا مقادیر تخلخل (تخلخل مؤثر: بخشی از تخلخل کل است که در آن شبکه منافذ در ارتباط با یکدیگرند) و اشباع آب کاهش نیافتنی مشخص باشند. این پارامترها اغلب در آزمایشگاه توسط نمونه‌های مغزه اندازه‌گیری می‌شوند. تخلخل مؤثر و اشباع آب کاهش نیافتنی در مرحله بعد با یک درجه خاص از دقت از نمودارهای چاه که از آنها برای مدل توسعه یافته تجربی استفاده شده است، تخمین زده می‌شود.

لازم به ذکر است که تخلخل محاسبه شده از نمودارها لزوماً تخلخل مؤثر نیست. محاسبه اشباع آب کاهش نیافتنی از نمودارهای چاه روش مناسبی نمی‌باشد. وقتی از مدل‌های تجربی که برای سازندهای خاصی ساخته شده‌اند در جاهای دیگر استفاده می‌شود، این مدل‌ها غالباً بسیار ضعیف عمل می‌کنند. مدل‌های آماری از روش رگرسیون چندگانه برای ایجاد یک رابطه بین نمودارهای چاه و مقادیر تراوایی استفاده می‌کنند. این مدل‌ها ضریب تراوایی را بیشتر از مدل‌های تجربی پیش‌بینی می‌نمایند. تحقیقات قبلی انجام شده توسط محقق و همکارانش [۹] نشان می‌دهد که از روش‌های تجربی تنها می‌توان در مخازن همگن استفاده کرد و به‌طور کلی این روش‌ها دارای معایب زیادی در پیش‌بینی خواص مخزن هستند. از طرفی روش رگرسیون آماری تنها قادر به پیش‌بینی روند تغییرات تراوایی بوده و نمی‌تواند مقادیر تراوایی را به‌طور دقیق محاسبه کند. بنابراین در این مطالعه استفاده از این دو روش جهت تعیین خصوصیات فیزیکی سنگ، به دلیل پراکندگی بالای موجود بین پارامترهای پتروفیزیکی امکان‌پذیر

شکل ۱ نمایی از ساختار یک شبکه عصبی سه لایه با تعداد نرون‌های متعدد در لایه‌های ورودی و میانی و یک نرون در لایه خروجی را نشان می‌دهد.



شکل ۱: ساختار عمومی شبکه عصبی [۲].

لایه‌های پنهان نقش سازماندهی عملکرد یک شبکه مصنوعی را بر عهده دارد. تعداد لایه‌های پنهان و سلول‌های عصبی موجود در این لایه‌ها تاثیر به‌سزایی در عملکرد شبکه دارد. در حالت کلی، تعداد سلول‌های عصبی موجود در لایه پنهان به ساختار شبکه، تعداد ورودی‌ها و خروجی‌های شبکه، تعداد دسته داده‌های آموزشی، میزان اختلال و خطای داده‌ها، پیچیدگی تابع آموزشی و الگوریتم آموزشی بستگی دارد. استفاده غیر ضروری از لایه‌های زیاد و سلول‌های عصبی باعث بالا رفتن میزان خطا در لایه خروجی می‌گردد. لایه نهایی هر شبکه عبارت از لایه خروجی می‌باشد که نتیجه عملکرد شبکه عصبی و پارامترهای مورد نظر را ارائه می‌دهد [۲] و [۱۰].

#### ۶- مطالعه موردی

در ابتدا چهار چاه که دارای داده‌های مغزه و لاگ بودند انتخاب شدند. این چاه‌ها عبارتند از: چاه‌های شماره ۵، ۶، ۷، ۱۲. انتخاب چاه‌های موردنظر بر اساس توزیع و پراکندگی آنها در میدان مورد مطالعه می‌باشد، به‌طوریکه بتوان پوششی مناسب را از لحاظ ساختاری و تنوع لیتولوژی در محدوده مورد نظر ایجاد کرد.

متغیرهایی که به‌عنوان ورودی شبکه برای آن انتخاب شده‌اند شامل: نمودارهای پرتو گاما، دانسیته کل، اشباع آب، صوتی، نوترون، عمق و فاکتور جذب فتوالکتریک و نمودارهای


نیست. یکی از تکنیک‌های اندازه‌گیری مجازی، شبکه‌های عصبی مصنوعی هستند که قادرند مقادیر تراوایی را از نمودارهای چاه به خوبی پیش‌بینی کنند. این روش بهترین و جدیدترین روش از میان روش‌های قبلی است [۶].

#### ۵- سیستم شبکه‌های عصبی

شبکه‌های عصبی مصنوعی با الهام از شبکه عصبی بیولوژیکی بوجود آمده‌اند. کارکرد این شبکه شبیه عملکرد مغز انسان می‌باشد و یکی از خصوصیات جالب آنها این است که توانایی یادگیری دارند. البته باید توجه داشت که یادگیری در شبکه‌های عصبی مصنوعی محدود می‌باشد و آنچه در عمل مورد توجه قرار می‌گیرد توانایی محاسباتی این شبکه‌ها می‌باشد. یک شبکه شامل واحدهایی به‌نام سلول عصبی یا نرون می‌باشد و این قابلیت را دارد که با به‌کار بردن یک دسته داده ورودی بتواند یک دسته داده خروجی دلخواه را تولید نماید. هر کدام از این دسته داده‌های ورودی و خروجی را می‌توان به شکل یک بردار فرض نمود. برای آموزش دادن یک شبکه، بردارهای ورودی به صورت متوالی به‌کار گرفته می‌شوند و هر سلول موجود در شبکه ورودی‌ها را به‌صورت غلظت متعددی دریافت می‌نماید.

غلظت دریافتی با اعمال وزن، معین می‌شوند و ورودی‌هایی که بر آنها وزن اعمال شده، در واحد پردازشگر سلول جمع می‌شوند. خروجی هر واحد پردازشگر می‌تواند به واحدهای پردازشگر دیگر انتقال یابد. در طول آموزش شبکه، وزن‌های شبکه به تدریج به مقادیر ثابتی همگرا تبدیل می‌شوند که به ازای آنها با اعمال بردار ورودی، بردار خروجی دلخواه تولید می‌شود. سلول‌های عصبی موجود در یک شبکه، بسته به نوع عملکردشان، در لایه‌های خاصی قرار می‌گیرند. هر شبکه عصبی دارای حداقل سه لایه است که شامل لایه ورودی، لایه میانی معروف به لایه پنهان و لایه خروجی می‌باشد. لایه ورودی محل وارد شدن اطلاعات مورد نظر شبکه می‌باشد. انتخاب نوع و تعداد ورودی‌های شبکه در کیفیت عملکرد شبکه تاثیر زیادی دارد. استفاده از تعداد زیاد و غیر ضروری و همچنین غیر مستقل پارامترهای ورودی باعث پیچیدگی بیش از اندازه شبکه و در نتیجه عملکرد نامناسب آن خواهد شد. همچنین امکان دسترسی و استفاده از داده‌های با کیفیت بالا (دسته داده‌های کامل دارای داده‌هایی با میزان خطای پایین) دارای اهمیت می‌باشد.

شکل ۳ نمودار پراکندگی داده‌های تراوایی و نمودار تخلخل نوترون را نشان می‌دهد.



شکل ۳: پراکندگی داده‌های تراوایی و نمودار تخلخل نوترون.

توزیع پراکندگی سایر نمودارها در مقابل تراوایی به‌طور مشابه نشان می‌دهد که ارتباط میان داده‌های حاصل از نمودارهای چاه و نفوذپذیری سنگ مخزن بسیار پیچیده و ناملموس است. بنابراین درجه ناهمسانگری سازندهای تشکیل دهنده میدان مورد مطالعه، به‌واسطه تغییرپذیری گسترده خصوصیات زمین‌شناسی و پتروفیزیکی آن، بسیار بالا می‌باشد. برای مثال مقادیر تراوایی اندازه‌گیری شده از مغزه‌ها، در محدوده‌ای بین ۰/۰۰۰۱ تا ۱۰۳ میلی‌داری در حال تغییرند.

#### ۲-۶- طراحی شبکه عصبی


با توجه به اینکه طبیعت توابع محرک به‌کار گرفته شده در لایه‌های میانی و خروجی به‌گونه‌ایست که مقادیر ورودی را در بازه  $[-1, 1]$  توزیع می‌کنند، لذا برای آموزش بهتر لازم است تا داده‌های ورودی و مطلوب در محدوده صفر تا یک نرمال شوند. برای این کار با استفاده از نرم‌افزار برنامه‌نویسی **Matlab**، داده‌ها به‌گونه‌ای در محدوده صفر و یک قرار گرفتند که میانگین آنها صفر، و انحراف معیار آنها برابر با یک شود. تمامی داده‌های مورد استفاده در این مطالعه شامل داده‌های آموزشی، تست و اعتبارسنجی با استفاده از این روش نرمال شده و در آموزش و تست شبکه به‌کار گرفته می‌شوند. عبارت زیر نحوه نرمال کردن خروجی شبکه عصبی را نشان می‌دهد:

$$Pn = (P - \text{Mean}(p)) / \text{Std}(P) \quad (1)$$

مقاومت ویژه می‌باشند. برای تبدیل نمودارهای مورد نظر به مقادیر کمی، از نرم‌افزار Digitizer استفاده شده است. این نرم‌افزار قادر است نمودارهای اسکن شده و یا فایل‌های تصویری به‌دست آمده از دستگاه‌های قرائت کننده را به‌صورت عددی تبدیل نماید. در واقع خروجی تصحیح شده این نرم‌افزار ورودی شبکه عصبی را تشکیل می‌دهد.

#### ۱-۶- ارتباط بین نمودارهای چاه‌پیمایی و نفوذپذیری مخزن

هر یک از نمودارهای چاه‌پیمایی تا حدی می‌توانند با تراوایی سازندها در ارتباط باشند. از آنجایی که تجسم فیزیکی و کمی این نوع از روابط برای ما غیرممکن است می‌توان با انجام آنالیز حساسیت بر روی داده‌ها نشان داد که کدام یک از نمودارها کمترین اثر یا بیشترین اثر را بر روی تراوایی سازندها خواهد گذاشت. برای مثال نمودار پرتو گاما طبیعی سازندها معرف درصد حجم شیل موجود در سازندهاست و از آنجایی که وجود شیل به عنوان عاملی بازدارنده در روند جریان سیال محسوب می‌شود، لذا با افزایش حجم شیل در سازندها میزان تراوایی آن کاسته می‌شود [۹]. با این وجود ارتباط میان این دو پارامتر را نمی‌توان به اشکال فیزیکی و یا فرم‌های ریاضی مدلسازی کرد (شکل ۲).



شکل ۲: توزیع پراکندگی داده‌های تراوایی و مقادیر نمودار پرتو گاما طبیعی.

معمولاً در بیشتر جاهایی که تخلخل سازندها زیاد است، طبیعی است که باید مقادیر تراوایی در این نقاط نیز بالا باشد (البته نه در همه جاها). لیکن به دلیل پیچیدگی روابط بین این دو خاصیت فیزیکی سازندها و وابستگی آنها به تعداد زیادی از پارامترهای دیگر، تاکنون رابطه مشخصی که بتواند در همه محیط‌های سنگی پاسخ دقیق بدهد، به‌دست نیامده است [۳].

جدول ۱: شبکه های عصبی مختلف با تعداد نرون های مختلف در لایه میانی.

تعداد شبکه	تعداد نرون های لایه میانی	میانگین مربعات خطا (MSE)
1	6	0.0368
2	10	0.0562
3	12	0.0278
4	16	0.00153
5	20	0.00169
6	22	0.000365
7	24	0.000694
8	26	0.000821
9	28	0.00409

زمان آموزش باید به اندازه کافی طولانی باشد تا شبکه بتواند تمامی نمونه های ایجاد شده را یاد بگیرد. همچنین لازم است تا از آموزش اضافی<sup>۲۶</sup> شبکه جلوگیری به عمل آید. این پدیده باعث به یاد سپردن<sup>۲۷</sup> داده های ورودی توسط شبکه می شود. شبکه ای که تمام داده های آموزشی خود را حفظ کند. وقتی در معرض یک گروه جدید از داده ها برای تست شبکه قرار می گیرد، بسیار ضعیف عمل می کند. در طول آموزش، شبکه سعی می کند تا خود را اصلاح کرده و از این طریق کمترین میزان خطای ممکن را به دست آورد. در اغلب اوقات مکان هایی در سطح خطا<sup>۲۸</sup> وجود دارد که در این نقاط شبکه به صورت موقتی همگرا می گردد. این پدیده حتی در مواقعی که فرایند یادگیری کامل نشده است نیز اتفاق می افتد. لذا لازم است شبکه ای طراحی شود که در آن بتوان از محدودیت هایی که نقاط حداقل محلی<sup>۲۹</sup> ایجاد می کنند رهایی یافته، کمترین مقدار خطا به صورت مطلق<sup>۳۰</sup> حاصل شود. شکل ۴ به صورت شماتیک سطح خطایی را که در آن نقاط مینیمم محلی و مطلق واقع شده اند را نشان می دهد. محور افقی این نمودار بیانگر روند آموزش و همگرایی شبکه با توجه به افزایش حلقه های تکرار محاسبات (Epoch) می باشد. محور عمودی نیز میزان خطای موجود بین مقادیر واقعی و خروجی شبکه را نشان می دهد [۸، ۱۰].

معمولا در مسائل مرتبط با سیستم شبکه های عصبی دو نوع هدف متفاوت از یکدیگر دنبال می شود. یکی طبقه بندی داده های ورودی و قرار دادن آنها در زیر مجموعه های مناسب و دیگری ایجاد یک مدل تخمین گر جهت ایجاد یک رگرسیون غیرخطی از داده های ورودی شبکه و نزدیک کردن این

که در آن P ماتریس داده های ورودی یا خروجی، Mean(p) ماتریس میانگین P، Std(P) ماتریس انحراف از معیار P و Pn ماتریس نرمال شده P می باشد.

لازم به ذکر است که در این حالت خروجی ایجاد شده توسط شبکه عصبی آموزش دیده توزیعی بین بازه [-1,1] دارد، لذا با توجه به توزیع داده های واقعی مورد استفاده در خروجی شبکه عصبی، می بایست خروجی شبکه مورد نظر را برای تمامی داده ها غیر نرمال کرد [۷].

عبارت زیر نحوه غیرنرمال کردن خروجی شبکه عصبی را نشان می دهد:

$$P = \text{Std}(P) * Pn + \text{Mean}(P) \quad (2)$$

توپولوژی و ساختار شبکه عصبی، نقش موثری در میزان تغییرات نرخ یادگیری و سرعت آموزش شبکه دارد. از این رو تعیین بهینه تعداد لایه ها و تعداد نرون های موجود در لایه مخفی، جزء مهم ترین پارامترهای طراحی شبکه به شمار می روند. افزایش نرون ها و تعداد لایه ها موجب پیچیدگی شبکه و در نتیجه افزایش زمان یادگیری و کاهش کارایی آن می گردد. از طرفی با کاهش تعداد نرون ها در لایه مخفی (کمتر از مقدار بهینه)، خطای ایجاد شده روندی صعودی داشته و شبکه مورد نظر واگرا می گردد.

با توجه به مطالب ذکر شده در بالا، در این مطالعه شبکه های متعددی با تعداد نرون های مختلف در لایه مخفی ساخته شده اند. هدف از ایجاد تغییر در تعداد نرون های موجود در لایه مخفی، تعیین تعداد بهینه عنصر پردازشگر (نرون) در این لایه است که قادر به یادگیری روابط موجود بین پارامترهای ورودی و خروجی با کمترین مدت زمان محاسبه باشند.

جدول ۱ نشان می دهد که از میان تمام شبکه های ساخته شده، تنها یک شبکه با ۲۲ نرون در لایه میانی توانسته است کمترین میزان خطا را ایجاد کند.

بنابراین بر طبق نتایج به دست آمده، شبکه ای سه لایه با ۸ نرون در لایه ورودی، ۲۲ نرون در لایه میانی و یک نرون در لایه خروجی طراحی می شود.

در این مطالعه، از یک شبکه عصبی پس انتشار جلورونده<sup>۲۵</sup> با ناظر برای دستیابی به اهداف مورد نظر استفاده شد. نرخ یادگیری شبکه با توجه به کمینه سازی زمان آموزش شبکه تنظیم می گردد. در طول آموزش لازم است تا چندین پارامتر به دقت بررسی شوند.

## ۳-۶- آموزش و آزمایش شبکه

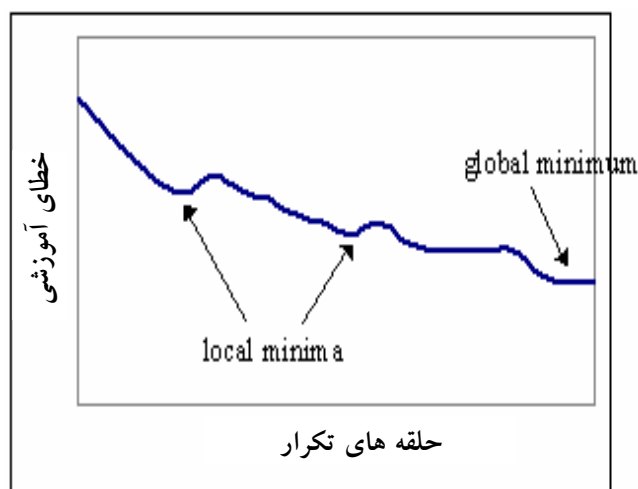
معمولا برای تعیین میزان صحت و قدرت تعمیم یافتگی یک شبکه عصبی، داده‌های مورد استفاده در طراحی شبکه به سه دسته داده‌های آموزشی، داده‌های تست و داده‌های اعتبارسنجی تقسیم می‌شوند. تعداد ۲۸۰ جفت داده در قالب ماتریس‌های ورودی و خروجی از چاه‌های میدان موجود می‌باشند. از این میان ۱۵٪ از داده‌ها برای اعتبارسنجی و ۲۵٪ از آنها جهت آزمایش شبکه به صورت جدا از داده‌های آموزش در نظر گرفته شدند. هفت پارامتر پتروفیزیکی به دست آمده از روی نمودارهای چاه‌پیمایی در قالب متغیرهای ورودی، و داده‌های آزمایشگاهی تراوایی اندازه‌گیری شده از مغزه‌های حفاری به عنوان متغیر مطلوب در لایه خروجی شبکه گنجانده شد [۴].

آموزش شبکه مورد نظر زمانی به پایان می‌رسد که در اصطلاح شبکه همگرا شده و میانگین مربع‌های خطا<sup>۳۱</sup> به حداقل ممکن برسد. در مرحله بعد شبکه آموزش دیده با داده‌هایی متفاوت از داده‌های آموزش اعتبارسنجی و تست می‌شود تا از صحت و دقت شبکه در تخمین داده‌های واقعی اطمینان حاصل شود.

هر دوره از یک مسیر رفت و یک مسیر برگشت ایجاد شده است. در مسیر رفت<sup>۳۲</sup> کمیت‌های ورودی شبکه وزن‌دار شده، مجموع این مقادیر وزن‌دار شده در توابع محرک نرون‌های مربوط به هر لایه قرار می‌گیرند. خروجی هر نرون مجدداً به عنوان بردارهای ورودی جدید به لایه بعدی تزریق شده و عملیات مشابهی روی هر یک از آنها صورت می‌گیرد. خروجی آخرین لایه با خروجی مورد نظر شبکه مقایسه شده و اختلاف آنها به عنوان خطا در نظر گرفته می‌شود. در مسیر برگشت با توجه به خطای به دست آمده، بردارهای وزن و بایاس به گونه‌ای طراحی می‌شوند که در مسیر رفت بعدی مقدار خطای کمتری به دست آید. این مراحل تکرار شونده (Epochs) تا جایی ادامه دارند که کمترین مقدار خطا به دست آید و شبکه مورد نظر پایدار شود.


در جدول ۲ میانگین مربعات خطای حاصل از داده‌های آموزش و اعتبارسنجی، به عنوان شاخصی جهت تعیین میزان همگرایی شبکه ارائه شده است. شبکه طراحی شده پس از انجام ۱۰۰۰ دوره تکرار محاسباتی (Epoch) بین متغیرهای ورودی و خروجی شبکه، نهایتاً در کمترین میزان خطا به همگرایی مطلوب رسیده است.

متغیرها به داده‌های واقعی که می‌توان آن‌را به عنوان داده‌های مطلوب در خروجی شبکه عصبی قرار داد.

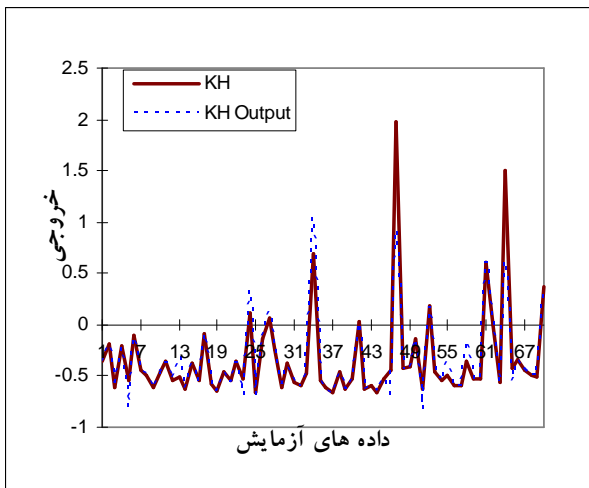


شکل ۴: نقاط مینیمم محلی و مطلق در سطح خطای داده‌های آموزش شبکه [۱۰].

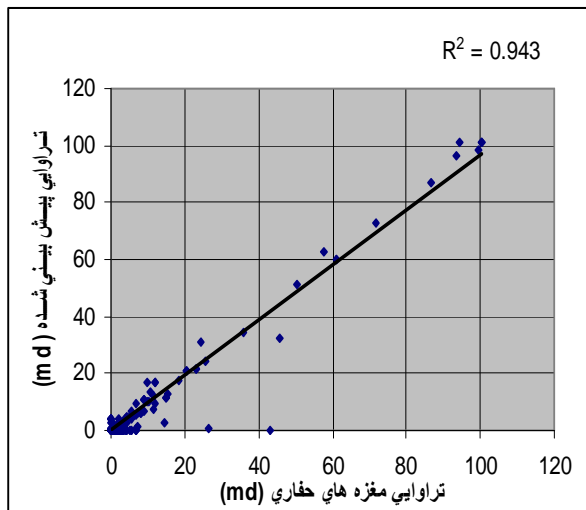
از آنجایی که مساله به کار رفته در این مطالعه از نوع دوم است، لذا بهترین شبکه‌ای که قادر به تحلیل و پردازش یک مساله غیرخطی است، شبکه پس انتشار خطا می‌باشد. انجام محاسبات ریاضی مرتبط با بردارهای ورودی به هر لایه و وزن‌ها و بایاس‌های متناظر با هر یک از آنها به عهده توابع محرک است. بنابراین انتخاب این توابع در مدل طراحی شده باید به گونه‌ای باشد تا بتوان بهترین پیش‌بینی را از مقادیر ورودی‌های شبکه انجام داد. با توجه به مسائل ذکر شده در بالا تابع محرک در لایه میانی زیگموئیدی، و در آخرین لایه خطی در نظر گرفته شده است. شکل ۵ نمایی از یک نرون زیگموئیدی و رابطه آنرا نشان می‌دهد.



شکل ۵: مولفه‌های یک نرون زیگموئیدی [۲].



شکل ۷: توزیع یک بعدی داده‌های واقعی و داده‌های پیش‌بینی شده در آزمایشگاه.



شکل ۸: توزیع داده‌های آموزشی واقعی و پیش‌بینی شده در دو بعد.

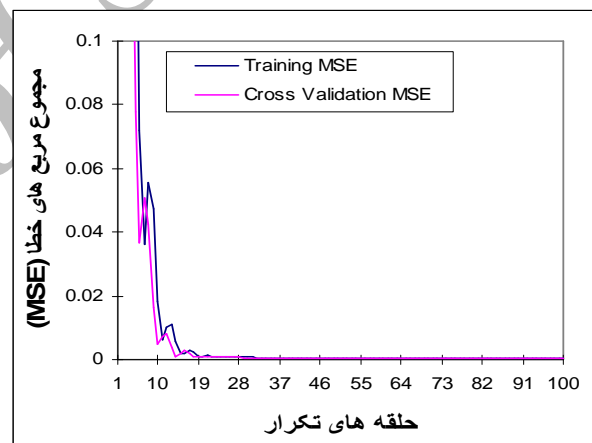
به طور مشابه، شکل ۹ همگرایی کاملی را بین داده‌های تست آزمایشگاهی و داده‌های تست پیش‌بینی شده نشان می‌دهد. شبکه مورد نظر قادر به پردازش داده‌های غیرخطی و پیش‌بینی مناسب از داده‌های تراوایی در هر نقطه از میدان مورد مطالعه است.

به طور مشابه در جدول ۳ میانگین مربع‌های خطای (MSE)، میانگین خطای مطلق (MAE)، حداقل خطای مطلق و حداکثر خطای مطلق به دست آمده از داده‌های تست ارائه شده است.

جدول ۲: میانگین مربعات خطای حاصل از داده‌های آموزش و اعتبارسنجی.

Best Networks	Training	Cross Validation
Epoch #	1000	1000
Minimum MSE	0.000365	0.00651
Final MSE	0.000365	0.00837

در شکل شماره ۶ منحنی یادگیری<sup>۳۳</sup> شبکه آمده است، که در آن روند همگرایی شبکه (کاهش خطا) تنها در ۱۰۰ دوره تکرار اولیه نشان داده شده است. انطباق کامل منحنی‌های آموزشی و اعتبارسنجی با یکدیگر، نشان می‌دهد که شبکه مورد نظر به خوبی قادر است تا مقادیر تراوایی را در سایر نقاط میدان پیش‌بینی کند. به عبارت دیگر شبکه به تعمیم یافتگی مطلوب رسیده است.



شکل ۶: منحنی یادگیری شبکه عصبی.

در شکل ۷، خط پرننگ داده‌های واقعی اندازه‌گیری شده در آزمایشگاه را نشان می‌دهد که به خوبی با داده‌های تراوایی پیش‌بینی شده (خط کمرنگ) انطباق دارد. محور افقی بیانگر جفت داده‌های آموزشی واقعی و به دست آمده از شبکه در اعماق مختلف زمین است که به صورت اتفاقی انتخاب شده‌اند. در شکل ۸ نیز توزیع مقادیر تراوایی در دو حالت آزمایشگاهی و تخمین زده شده نشان داده شده است. همگرایی بین داده‌های آزمایشگاهی و خروجی شبکه عصبی تقریباً نزدیک به یک است.




انجام گرفته است. هر چند ممکن است تخمین دقیق تراوایی مشکل باشد، اما با استفاده از روش‌های هوشمند می‌توان به تشخیص زون‌های تراوا و پیش‌بینی مقادیر تراوایی در هر نقطه دلخواه از مخزن پرداخت. علاوه بر این در طرح توسعه میدان، جهت حفر چاه‌های تولیدی و اکتشافی جدید، مدل ایجاد شده قادر است به مهندسين طراح در انتخاب بهترین محل حفاری یاری رساند.

علاوه بر این انطباق کامل منحنی‌های آموزشی و اعتبارسنجی با یکدیگر، نشان می‌دهد که شبکه مورد نظر به‌خوبی قادر است تا مقادیر تراوایی را در سایر نقاط میدان پیش‌بینی نماید. به عبارت دیگر شبکه به تعمیم یافتگی مطلوب رسیده است.

#### ۸- منابع و مراجع

- [1] Arbogast, J.S.; Franklin, M.H.; 1999; "Artificial neural networks and high speed resistivity modeling software speed reservoir characterization", Petroleum engineering international, Vol. 72, No. 5, pp. 57-61.
- [2] Bean, M.; and Jutten, C.; 2000; "Neural networks in geophysical applications", Geophysics, Vol. 65, pp. 1032-1047.
- [3] Bhatt, A.; Helle, H.B.; 2002; "Committee neural networks for porosity and permeability prediction from well logs", Geophysical Prospecting, Vol. 50, pp. 645-660.
- [4] Cho, S.; Wong, P.M.; Kwon, Y.; Gedeon, T.D.; 1998; "Estimation of rock permeability in petroleum reservoir," In: Proceedings of 4th International Conference on Engineering Applications of Neural Networks (EANN), Gibraltar, 10-12 June, pp. 161-164.
- [5] Doveton, J.H.; Prenskey, S.E.; 1992; "Geological applications of wireline logs: a synopsis of developments and trends", The Log Analyst, Vol. 33 No. 3, pp. 286-303.
- [6] Helle, H.B.; Bhatt, A.; Ursin, B.; 2001; "Porosity and permeability prediction from wireline logs using artificial neural networks a North Sea case study", Geophysical Prospecting, No. 49, pp. 43-444.
- [7] Huang, Y.; Wong, P.M.; Gedeon, T.D.; 1998; "Prediction of reservoir permeability using genetic algorithms", AI Applications, Vol. 12, No. 13, pp. 67-75.
- [8] Matlab User's Guide, 2002; "Neural Networks Toolbox for use with Matlab", by the Math Works, Ins.
- [9] Mohaghegh, S.; Ameri, S.; Aminian, K.; 199۵; "A methodological approach for reservoir heterogeneity characterization using artificial neural networks", J. Pet. Sci. Eng, No. 16, pp. 263- 274.
- [10] Wang, P.; Tamhane ; D. ; Aminzadeh, F. ; 2000 ; "A soft computing Approach to Integrate Well logs and geological clusters for Petrophysical Prediction",



شکل ۹: توزیع داده‌های تست واقعی و داده‌های تست پیش‌بینی شده در دو بعد.

جدول ۳: کارایی شبکه عصبی نسبت به داده های تست.

Performance	KH
MSE	0.00651
MAE	0.15956726
Min Abs Error	0.0486265
Max Abs Error	0.75171435

#### ۷- نتیجه گیری

در این تحقیق پیش‌بینی دقیق تراوایی از نمودارهای مختلف چاه‌پیمایی مر بوط به چهار چاه در میدان پارس جنوبی با استفاده از یک سیستم شبکه عصبی سه لایه با الگوریتم یادگیری پس انتشار خطا انجام شد.

تجربه‌های به‌دست آمده در طی طراحی و توسعه شبکه‌های عصبی جهت تخمین مقادیر تراوایی نشان می‌دهد که تعداد داده‌های کافی برای آموزش مناسب شبکه می‌بایست موجود باشد. همچنین تعیین تعداد نرون‌های لایه میانی و یا تعداد داده‌های مورد نیاز برای یادگیری شبکه یا تست آن از جمله مسائلی است که تا مقدار زیادی به تجربه شخصی طراح شبکه بستگی دارد.

ارتباط بین نمودارهای چاه‌پیمایی و تراوایی مخزن بیانگر درجه ناهمگنی بالای سازندهای تشکیل دهنده میدان مورد مطالعه می‌باشد که در اثر تغییرپذیری گسترده خصوصیات زمین‌شناسی و پتروفیزیکی آن منطقه به‌وجود آمده است.

نتایج به‌دست آمده از این مطالعه حاکی از آنست که تخمین تراوایی با استفاده از سیستم شبکه عصبی به خوبی

Proceedings 3rd International Conference on Petroleum Geophysics, New Delhi, India.

[11] Wyllie, M.R.J.; Rose, W.D.; 1950; "Some theoretical considerations related to the quantitative evaluations of the physical characteristics of reservoir rock from electric log data", Transactions, the American Institute of Mining Engineers (AIME) No. 189, pp. 105-118.

آخرنویس

- 1-Kozeny-Carman
- 2 - Wyllie and Rose
- 3 - Schlumberger
- 4 - Arbogast and Franklin
- 5 - Wang et al
- 6 - Doveton and Prenskey
- 7 - Balan
- 8 - Mohaghegh
- 9 - South Pars Gas Field
- 10 - Khami
- 11 - Bangestan
- 12 - Kangan
- 13 - Dalan
- 14 - Gamma ray
- 15 - Bulk density
- 16 - Water saturation
- 17 - Neutron Log
- 18 - Photoelectric absorption factor
- 19 - Resistivity log
- 20 - Representative
- 21 - Empirical methods
- 22 - Statistical methods
- 23 - Neural modeling
- 24 - Irreducible water saturation
- 25 - Feed-forward back propagation
- 26 - Overtraining
- 27 - Memorization
- 28 - Error surface
- 29 - Local minima
- 30 - Global minima
- 31 - Mean-squared error
- 32 - Feed Forward
- 33 - Learning Curve