

به کارگیری شبکه عصبی هوشمند جهت پیش‌بینی تراوایی سازند با استفاده از داده‌های چاه پیمایی

آرش ربیعی^۱، حسین صیاد^۲

۱- فارغ‌التحصیلکارشناسی ارشد نفت مخازن هیدرولکربوری، دانشکده نفت اهواز
Arashrabie66@gmail.com

چکیده:

تراوایی یکی از پارامترهای کلیدی جهت توصیف و مدل سازی مخازن می‌باشد. علی‌رغم پیشرفت‌های زیاد در روش‌های مختلف ارزیابی تراوایی همچون چاه آزمایی‌پیمایی، همچنان دقیق ترین روش اندازه‌گیری تراوایی، آنالیز مغزه می‌باشد که روشی پر هزینه و زمانبر بوده و در عین حال نتایج آن تنها برای تعداد محدود و عمق محدودی از چاه‌ها موجود می‌باشد. به علت موجود بودن داده‌های مربوط به چاه پیمایی تقریباً در تمامی چاه‌های حفاری شده، تلاش‌های زیادی جهت برقراری رابطه‌ای منطقی بین داده‌های چاه پیمایی و تراوایی حاصل از آنالیز مغزه حاصل گردیده است. تحقیقات گذشته نشان داده است که روش‌های هوشمند همچون شبکه‌های عصبی مصنوعی به خاطر قابلیتشان در حل مسائل پیچیده، به خوبیتوانایی پیش‌بینی تراوایی را از داده‌های چاه پیمایی دارا می‌باشند. در این مطالعه مدلی بر اساس شبکه عصبی پیش‌روندۀ برای پیش‌بینی میزان تراوایی مخزن با استفاده از داده‌های چاه پیمایی ارائه شده است. نتایج حاصل از عملکرد شبکه عصبی به کار گرفته شده نشان می‌دهد که شبکه موجود با خطای میانگین مربعات(Mean square error, MSE) ۰,۰۰۰۲۲ و ضریب تعیین (R^2) ۰,۹۸۷۴(Coefficient of determination, R²) کاندیدای مناسبی جهت پیش‌بینی تراوایی مخزن توسط داده‌های چاه پیمایی می‌باشد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، تراوایی، چاه پیمایی، الگوریتم پس انتشار

^۱- فارغ‌التحصیل کارشناسی ارشد نفت مخازن هیدرولکربوری، دانشگاه صنعت نفت اهواز

^۲- فارغ‌التحصیل مهندسی نفت مخازن هیدرولکربوری، دانشگاه علوم و تحقیقات تهران

۱- مقدمه:

تراوایی مخزن یکی از پارامترهای اساسی و مهم در ارزیابی کیفیت مخزن و همچنین مورد نیاز جهت شبیه سازی عددی مخزن و حرکت سیال در مخزن، برنامه های حفاری و محاسبات مربوط به تزریق و تولید از مخزن می باشد [۳-۱]. محاسبه این پارامتر برای کل مخزن همچنان به عنوان یکی از چالش های بزرگ برای مهندسین نفت باقی مانده است. در واقع بسیاری از محاسبات مربوط به مهندسی نفت بدون در دست داشتن میزان دقیق تراوایی مخزن امکان پذیر نمی باشد [۴, ۵]. به طور معمول تراوایی در آزمایشگاه و به صورت مستقیم از نمونه سنگ مخزن محاسبه می گردد [۶, ۷]. اما تهیه نمونه های زیاد از چاه های مختلف امری پر هزینه و تقریباً غیر ممکن می باشد و در عمل تنها از تعداد محدودی از چاه ها و از عمق محدودی نمونه برداری می گردد [۸]. از دیگر روش های مورد اسفاده جهت تعیین تراوایی مخزن می توان به چاه آزمایی (Well Testing) اشاره کرد. این روش نیز هزینه اجرایی بسیار بالایی دارد اما میزان تراوایی متوسط مخزن را با دقت بالا مشخص می نماید [۹]. استفاده از چاه پیمایی (Well Logging) به عنوان روشی جایگزین پیشنهاد گردیده است. در دو دهه گذشته تلاش های زیادی جهت پیش بینی تراوایی از داده های حاصل از نمودارهای چاه پیمایی توسط برقراری ارتباط با داده های موجود از تراوایی به دست آمده از نمونه سنگ، در عمق یکسان، انجام گردیده است [۱۰, ۳]. و از آنجایی که چاه پیمایی تقریباً در تمامی چاه ها انجام می گردد، می توان توسط داده های حاصل از آن تراوایی کل مخزن را محاسبه کرد. در اکثر تلاش ها جهت پیش بینی تراوایی مخزن از داده های مغزه و چاه پیمایی معمولاً از رابطه ای خطی و یا غیر خطی بین داده های تراوایی موجود و دیگر خواص پتروفیزیکی سنگ استفاده می گردد [۱۱]. به عنوان مثال در مقالات مختلف از روابط تجربی بسیار زیادی جهت پیش بینی تراوایی از داده های چاه پیمایی استفاده شده است [۱۲-۱۴]. اما نتایج نشان داده شده به خصوص برای مخازن کربناته که دارای ناهمگونی (Heterogeneity) زیاد می باشند نشان از ناکارآمد بودن این روش ها دارد [۳, ۷, ۱۵].

جهت رفع مشکلات ذکر شده استفاده از روش های هوشمند همچون شبکه های عصبی مصنوعی توسط بسیاری از نویسندهای پیشنهاد گردیده است [۱۶-۱۸]. همچنین تحقیقات گذشته نشان از توانایی بالای این شبکه ها جهت پیش بینی تراوایی حتی در مخازن با ناهمگونی بالا دارد [۱۹-۲۳]. شبکه های عصبی، با الهام گیری از مغز انسان، قادر به درک روابط پنهان بین داده های حاصل از چاه پیمایی و تراوایی متناظر اندازه گیری شده از مغزه بوده و قادر به پیش بینی تراوایی برای هر داده چاه پیمایی بدون نیاز به مغزه می باشند. از آنجایی که شبکه های عصبی از هیچ گونه معادله تجربی خاصی استفاده نمی کنند، محدود به استفاده برای یک سازند خاص نیز نمی باشند و توانایی پیش بینی برای مخازن مختلف با سازند های مختلف را دارا می باشند که این نشان از قدرت شبکه های عصبی دارد [۲۴].

در این مطالعه تراوایی مخزن با به کار گیری شبکه عصبی مصنوعی تخمین زده شد و از شبکه پرسپترون چند لایه (Multilayer Perceptron) استفاده گردید. جهت آموزش این شبکه از روش پس انتشار (Back Propagation) و از تابع لونبرگ-مارکوات (Levenberg-Marquardt) که از پرکاربرد ترین توابع مورد استفاده می باشد، بهره گرفته شد. بانک اطلاعاتی مورد استفاده در این پژوهش شامل ۳۹۶ داده مربوط به مغزه و نمونه سنگ مخزن و همچنین اطلاعات حاصل از چاه پیمایی می باشد که از مخازن هیدروکربوری واقع در جنوب ایران گرفته شده است.

۲- روش شناسی:

۱-۲ دورنما:

تلash های بسیاری جهت پیش بینی تراوایی با استفاده از وضع معادلات تجربی از طریق داده های چاه پیمایی همچون تخلخل، اشباع آب و عمق انجام گردیده است. هر چند روابط موجود بیشتر برای مخازن همگن کاربرد دارد اما این روش ها برای بسیاری از مخازن ماسه سنگی و کربناته به کار گرفته شده و نتایج قابل قبولی جهت پیش بینی تراوایی ارائه داده اند. پیش بینی تراوایی از مخازن با نا همگنی بالا چالشی بزرگ برای مهندسین نفت می باشد. مطالعات اخیر نشان می دهد که روش های هوشمند همچون شبکه عصبی مصنوعی به عنوان ابزاری قدرتمند جهت شناسایی روابط پیچیده بین ورودی ها و خروجی های مورد نظر، کاربرد وسیعی دارند. مفهوم شبکه عصبی و ساختار استفاده شده در این مطالعه در قسمت های بعدی توضیح داده شده است.

۲-۲ شبکه های عصبی مصنوعی:

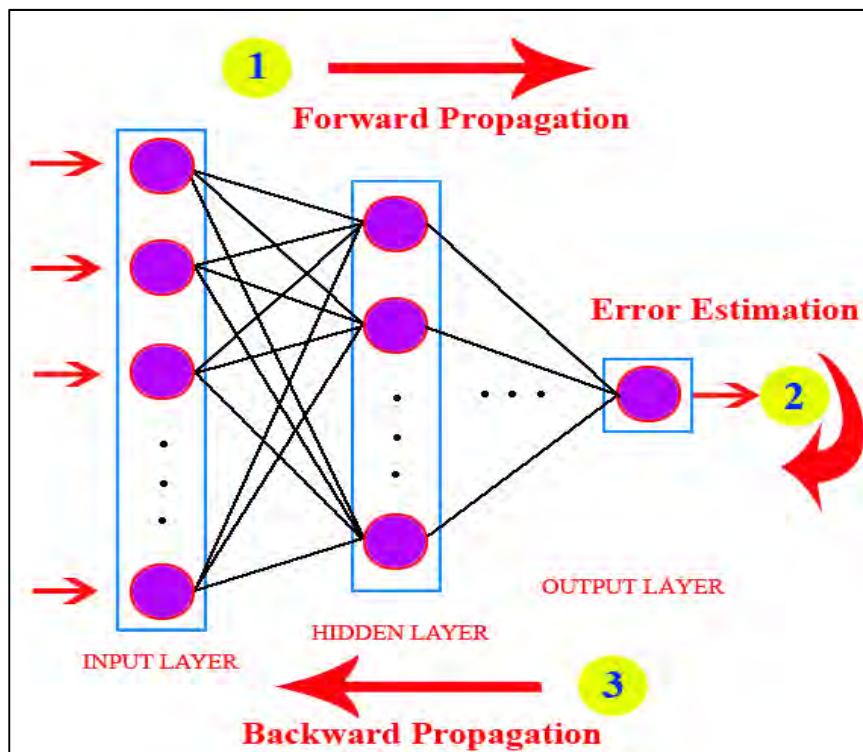
شبکه های عصبی مصنوعی (Artificial Neural Networks, ANN) ابزاری بسیار قدرتمند جهت انجام محاسبات غیر خطی می باشد. در واقع ANN یک واحد پردازش اطلاعات می باشد که نحوه عملکرد آن شبیه به مغز انسان است. برخلاف کامپیوتر های دیجیتال که اصولاً وابسته به اعمال مجموعه ای از دستور العمل ها می باشد، هیچ مدل ریاضی به خصوصی جهت استفاده از شبکه های عصبی مورد نیاز نمی باشد، زیرا همانند مغز انسان توانایی یادگیری تنها با تعدادی مثال را دارا می باشد. از این رو استفاده از شبکه های عصبی هوشمند برای مسائلی که روابط بین داده های ورودی و خروجی به صورت ریاضی مشخص نمی باشد، به شدت توصیه می گردد. به طور کلی یک واحد شبکه عصبی از نورون یا واحد های پردازش و قدرت ارتباط بین این نورون ها یا وزن (Weights) تشکیل گردیده است. آموزش یک شبکه عصبی توسط تغییر دادن وزن بین نورون ها تا رسیدن مقدار خروجی شبکه به داده خروجی واقعی انجام می گردد [۲۵].

۳-۲ شبکه های چند لایه پرسپترون:

شبکه های عصبی پرسپترون از معروف ترین نوع شبکه های عصبی می باشند. این نوع شبکه از لایه های مختلف تشکیل شده است که اولین لایه را لایه ورودی (Input Layer) می نامند که داده های ورودی را دریافت می کند. لایه آخر را لایه خروجی می نامند که جواب خروجی از شبکه را ارائه می نماید. بین لایه ورودی و لایه خروجی یک یا چند لایه پنهان وجود دارد که عملکرد شبکه را کنترل می کنند.

موفقیت در کسب نتایج قابل اعتماد از شبکه عصبی تا حد زیادی به ساختار شبکه عصبی، نحوه آموزش شبکه عصبی و پردازش داده ها وابسته می باشد. از معمول ترین و پرکاربرد ترین ساختار های شبکه عصبی می توان به شبکه پیش رونده (Feed Forward) اشاره کرد که در آن اطلاعات و سیگنال ها تنها در یک جهت، از لایه ورودی به سمت لایه خروجی، حرکت می کند. شماتیک ساده یک شبکه عصبی چند لایه پرسپترون با الگوریتم پس انتشار در شکل ۱ آورده شده است. همانطور که در شکل ۱ دیده می شود، سیگنال ورودی در لایه ها پخش شده و سیگنال خروجی را ایجاد می نماید. سپس خروجی حاصل از شبکه عصبی با خروجی هدف (Target Output) مقایسه گردیده و بر مبنای خطای موجود سیگنال لازم جهت تغییر وزن ها و بایاس

(Bias)، توسط الگوریتم پس انتشار (Back Propagation) صادر می‌گردد. مراحل آموزش شبکه تا رسیدن به معیارهای از پیش تعیین شده همچون میزان خطای قابل قبول ادامه پیدا می‌کند [۲۶]. یک شبکه عصبی پیش‌رونده سه لایه با الگوریتم پس انتشار توانایی پیش‌بینی نتیجه از نوع تابع پیوسته غیرخطی را دارا می‌باشد [۲۷].



شکل ۱: نمایی ساده از یک شبکه عصبی چند لایه پرسپترون با الگوریتم پس انتشار

۴-۲ جمع آوری و آنالیز داده ها:

داده های استفاده شده در این مطالعه از ۴ چاه حفر شده در مخازن میدان پارس جنوبی که همگی مغزه گیری شده اند، تهیه گردیده است. همچنین اطلاعات مربوط به چاه پیمایی این چاه ها نیز موجود می باشد. جهت انتخاب پارامتر های ورودی برای شبکه عصبی سعی گردیده است که متغیر هایی که به نوعی موثر در میزان تراوایی مخزن می باشند و همچنین در هر ۴ چاه موجود هستند، انتخاب گردد. در نهایت پارامتر های انتخاب شده عبارتند از: پرتوی گاما های پردازش شده، Computed Gamma Ray (CGR) جهت تشخیص سازند شیلی با تراوایی پایین، رسانندگی سازند (IC) و اشیاع آب سازند (Water) (Induction Conductivity, IC) به علت ارتباط این دو پارامتر با تراوایی، پارامترهای مرتبط به اندازه گیری میزان تخلخل سازند (Neutron Saturation, S_w) به علت ارتباط Porosity, NPHI; Bulk Density, ROHB; Sonic Transit Time, DT با تراوایی، ترکیبات لیتولوژی سازند (Shale) (Anhydrite, Dolomite, Calcite) که تأثیر مهمی بر میزان تراوایی دارند و در نهایت عمق که با افزایش آن

بر میزان فشار کل روی سازند (overburden pressure) افزوده شده و در نتیجه کاهش تراوایی را در پی دارد. جدول ۱ محدوده اطلاعات مورد استفاده در این مطالعه را نشان می دهد.

جدول ۱: محدوده های مورد استفاده شده

Attribute	CGR	IC	Sw	NPHI	ROHB	DT	ANHYD-fraction	DOL-fraction	Calcite-fraction	Depth (ft)
Minimum	0	7.863	0.113	0.000397	2.243	46.97	0	0	0	1921.1541
Maximum	66.11	20000	1	0.2588	2.863	65.63	0.4	0.86	1	2707.9956
CGR: Computed Gamma Ray Neutron Porosity		IC: Induction Conductivity ROHB: Bulk Density		Sw: Water saturation DT: Sonic Transit Time		NPHI:				

۵-۲ طراحی شبکه عصبی:

ساختار شبکه عصبی مورد استفاده در این مطالعه از نوع شبکه پرسپترون چند لایه پیش رونده می باشد. شبکه طراحی شده دارای ۲ لایه مخفی می باشد. تعداد نورون های مناسب برای لایه های مخفی به صورت حدس و خطا مشخص گردید. همچنین تعداد نورون های لایه اول، برابر با تعداد پارامترهای ورودی، ۱۰ نورون می باشد. تنها خروجی شبکه نیز میزان تراوایی می باشد.

۶-۲ آموزش شبکه عصبی:

برای آموزش شبکه عصبی توسط الگوریتم پس انتشار، از متدهای کاهش گرادیان (gradient steepest descent) که معمولاً کاهش تابع عملکرد (مانند خطای میانگین مربعات(Mean Square Error, MSE)) را در پی دارد، استفاده می گردد. این الگوریتم بسیار آهسته بوده و برای مسائل عملی تقریباً امکان پذیر نمی باشد [۲۸]. در این مطالعه از الگوریتم لونبرگ-مارکوات-Marquardt)جهت آموزش شبکه عصبی استفاده شده است که توانایی رسیدن به جواب را ۱۰۰ تا ۱۰ برابر سریعتر نسبت به الگوریتم های معمولی دارا می باشد [۲۹, ۲۸].

۷-۲ زمان توقف آموزش شبکه:

بدون توجه به میزان پیچیدگی روابط بین داده های ورودی و خروجی، یک شبکه عصبی با ساختار مناسب توسط آموزش مناسب قادر به یادگیری روابط موجود می باشد [۲۸]. اما یکی از پارامتر های مهم زمان توقف آموزش می باشد. زمانی که الگوریتم پس انتشار استفاده می گردد معمولاً دو روش جهت توقف آموزش موجود می باشد. روش اول اندازه گیری میزان خطای میانگین مربعات بوده و روش دیگر تایید بهبود آموزش بعد از هر مرحله آموزش (epoch) می باشد [۳۰] که جهت جلوگیری از حفظ کردن داده های آموزش (over fitting) به جای یادگیری روابط بین آن ها توسط شبکه عصبی می باشد. زیرا در بعضی از مسائل شبکه عصبی با حفظ کردن داده ها میزان MSE را بسیار پایین نشان داده اما توانایی پیش بینی داده های جدید را دارا نمی باشد. داده

های موجود در این مطالعه به سه دسته داده های آموزش (Train data)، اعتبار سنجی (Validation data) و تست (Test data) با نسبت های به ترتیب ۷۰٪، ۱۵٪ و ۱۵٪ تقسیم بندی شده اند.

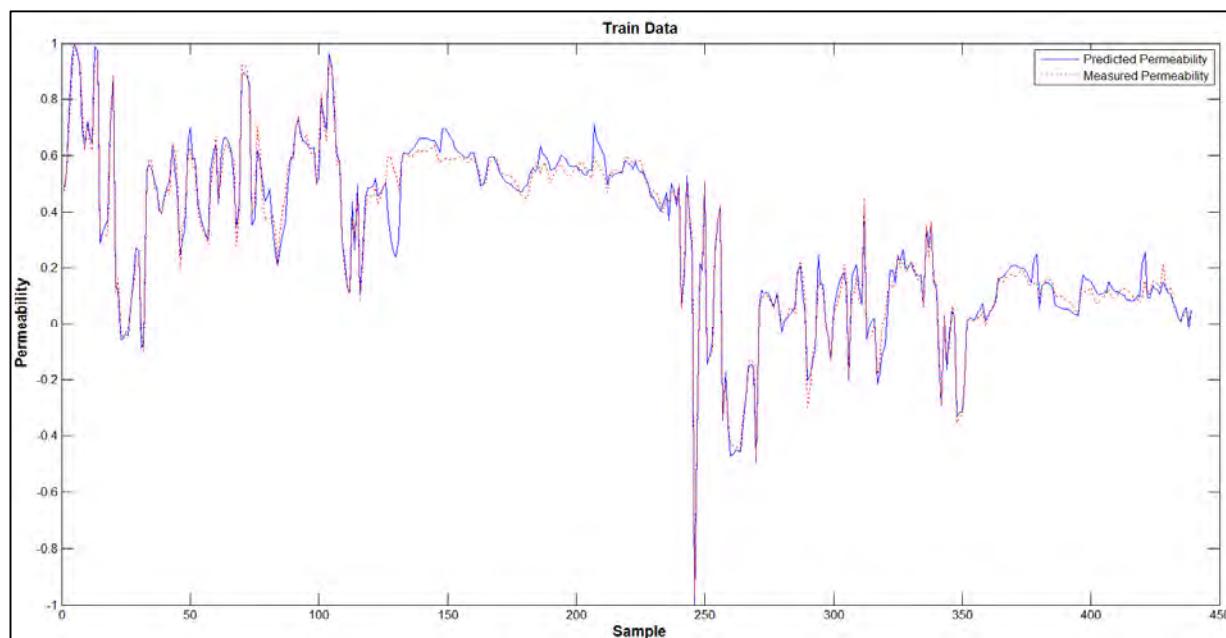
۳- بحث و نتایج:

مطالعه انجام شده نشان می دهد که استفاده از شبکه عصبی جهت پیش بینی تراوایی مخزن بسیار موفق عمل می کند. برای ساده سازی و کاهش محاسبات، داده ها توسط معادله ۱ به صورت خطی نرمال شده و در محدوده ۱-۱ قرار گرفتند. شبکه عصبی طراحی شده توسطتابع لونبرگ-مارکوات آموزش داده شد.

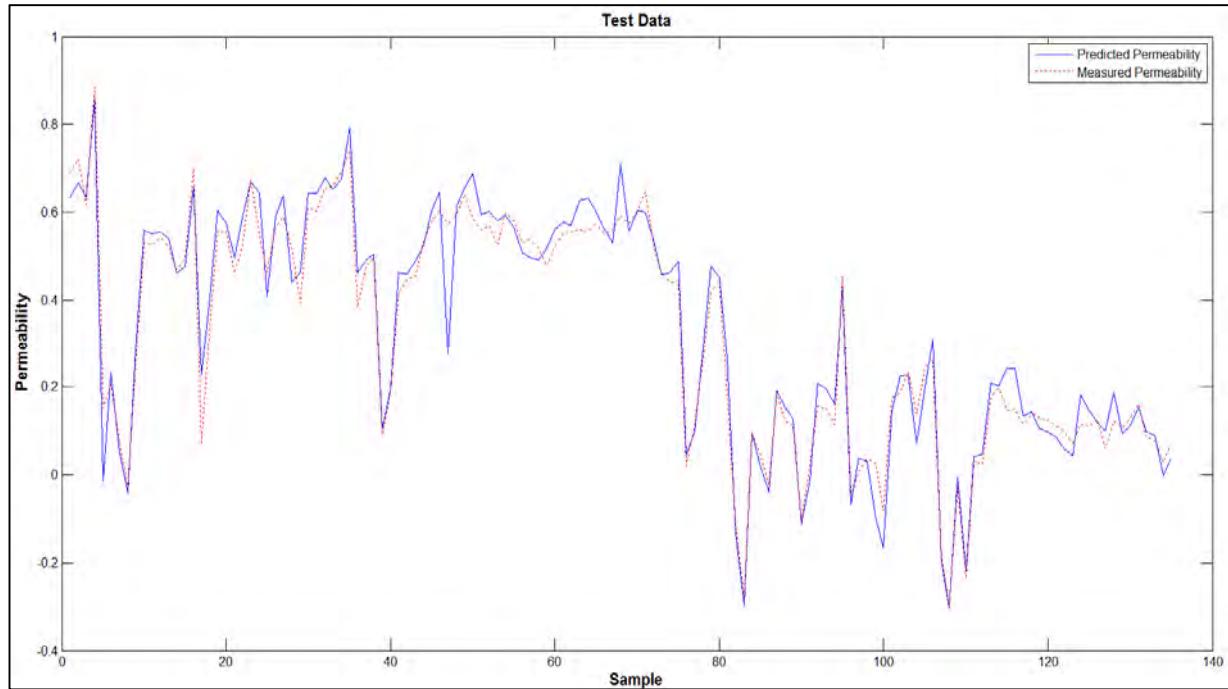
$$y = \frac{(y_{max} - y_{min}) \times (x - x_{min})}{(x_{max} - x_{min})} + y_{min} \quad (1)$$

تابع فعال سازی برای نورون های موجود در لایه های مخفی تابع سیگموید بوده و همچنین از تابع خطی برای نورون لایه خروجی استفاده گردید. داده های حاصل از چاه پیمایی به عنوان ورودی و میزان تراوایی به عنوان خروجی شبکه می باشد. همچنین همان طور که پیشتر ذکر شد، تعداد نورون های لایه های مخفی نیز توسط حدس و خطا به دست آمدند که برای لایه های مخفی اول و دوم به ترتیب برابر با ۱۱ و ۵ نورون بود. بنابراین ساختار کلی شبکه به کار گرفته شده در این مطالعه به صورت ۱-۱۱-۵-۱۰ می باشد که به این معنی است که لایه ورودی، دو لایه مخفی و لایه خروجی به ترتیب دارای ۱۰، ۱۱، ۵ و ۱ نورون می باشند.

در شکل ۲ و ۳ داده های تراوایی اندازه گیری شده در آزمایشگاه و تخمین زده شده توسط شبکه عصبی در دو حالت آموزش و تست مقایسه گردیده است که گویا نزدیکی جوابها پیش‌بینی شده توسط شبکه به مقادیر واقعی تراوایی می باشد.



شکل ۲: مقایسه تراوایی اندازه گیری شده در آزمایشگاه و تخمین زده شده در حالت آموزش



شکل ۳: مقایسه تراوایی اندازه گیری شده در آزمایشگاه و تخمین زده شده در حالت تست

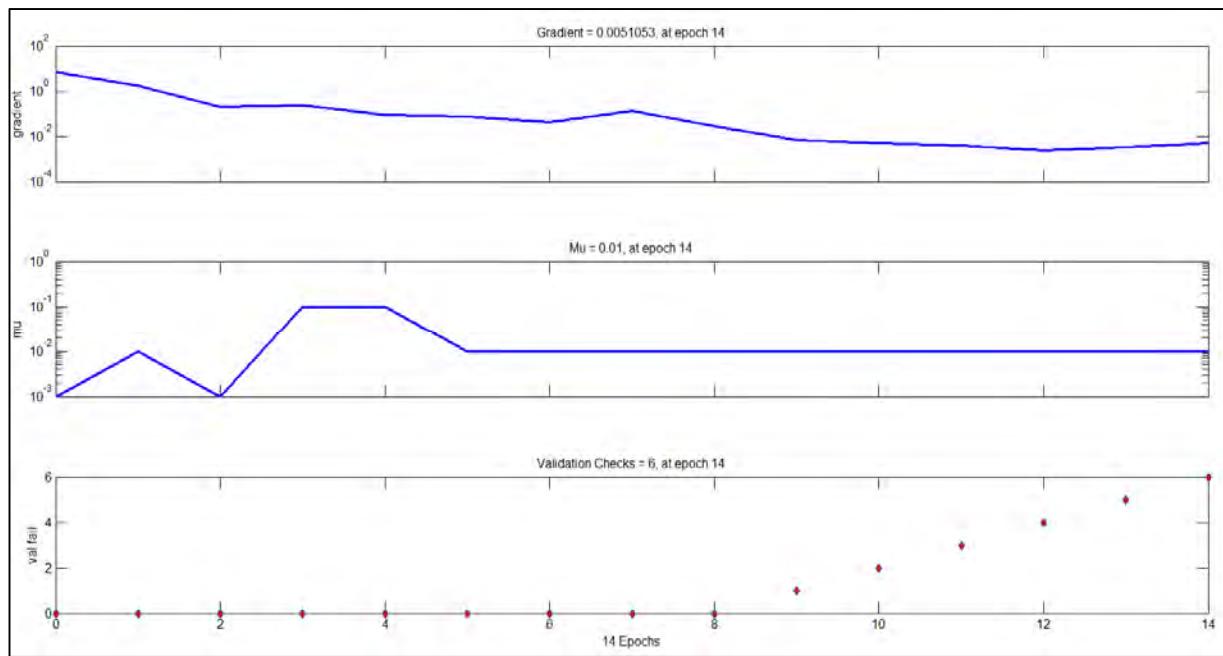
عملکرد شبکه محاسبه‌شاخص میانگین نمره اعاتخطا (MSE) و ضریب تعیین (Coefficient of Determination, R^2) موردار زیباقرار گرفت که بهتر تبیدر معادله‌های ۲ و ۳ نشان داده شده است. MSE و R^2 اندازه گیری شده در این مطالعه به ترتیب برابر با ۰,۰۰۲۲ و ۰,۹۸۷۴ می‌باشد.

$$MSE = \frac{\sum(K_{i,exp} - K_{i,calc})^2}{N} \quad (2)$$

$$R^2 = \left(\frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \right)^2 \quad (3)$$

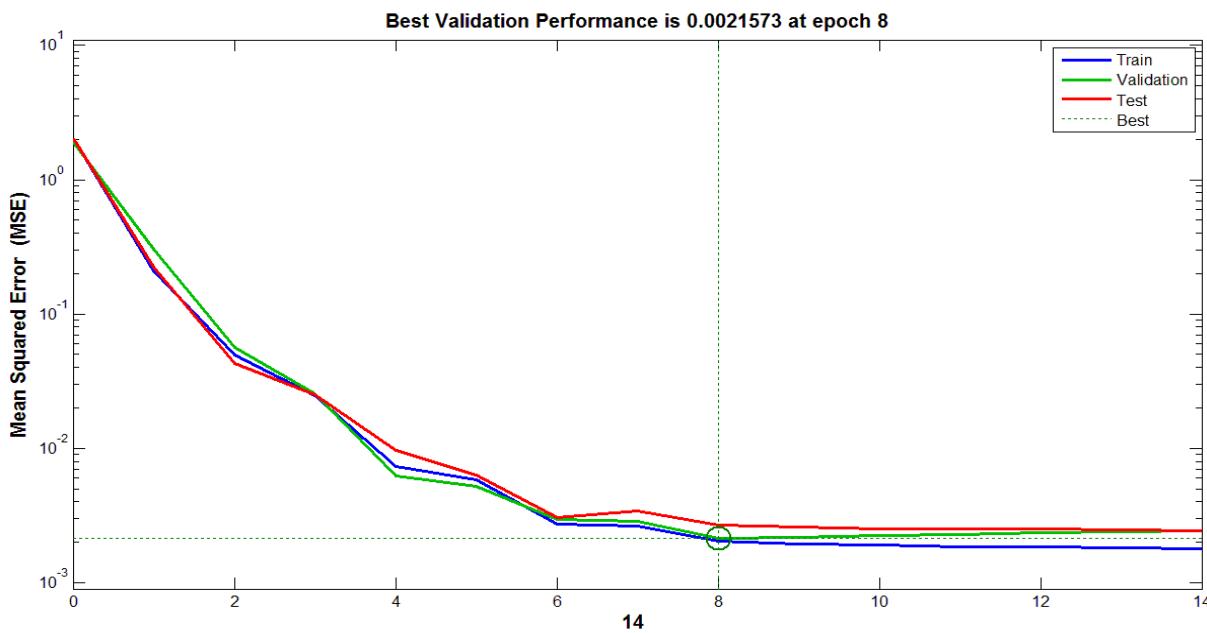
که در معادله ۲ تراوایی پیش‌بینی شده، $K_{i,exp}$ تراوایی واقعی و $K_{i,calc}$ تراوایی پیش‌بینی شده.

در مطالعه انجام شده MSE جهت بررسی عملکرد آموزش شبکه استفاده گردید در صورتی که ضریب همبستگی جهت بررسی عملکرد پیش‌بینی شبکه عصبی مورد استفاده قرار گرفت. همچنین وضعیت آموزش شبکه عصبی در شکل ۴ نشان داده شده است.



شکل ۴: وضعیت آموزش شبکه عصبی

شکل ۵ عملکرد شبکه عصبی را نشان می دهد. همان طور که در شکل ۵ نشان داده شده است، با گذشت Epoch ۸ مراحل آموزش جهت جلوگیری از پدیده over fitting متوقف می گردد.



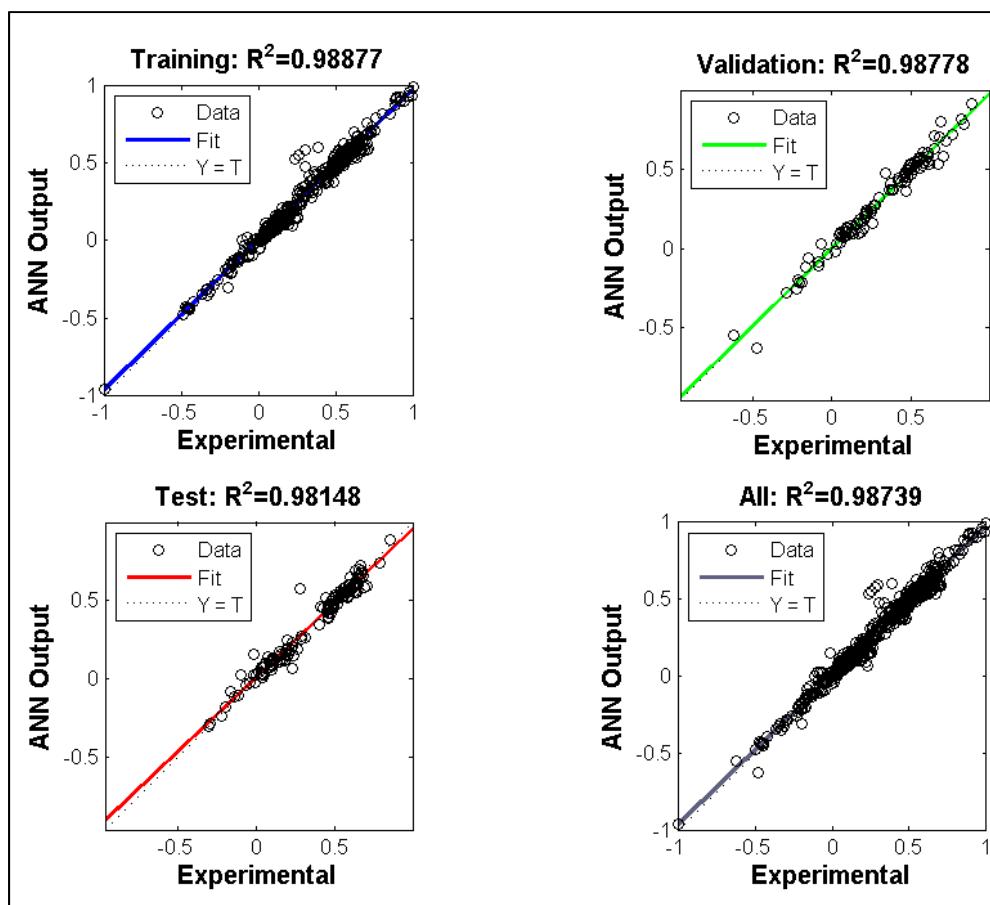
شکل ۵: عملکرد شبکه عصبی

جدول ۲ مقادیر خطا و دقت مراحل آموزش، اعتبارسنجی و آزمایش شبکه عصبی مورد استفاده در این مطالعه را نشان می‌دهد. به طور کلی میزان R^2 بالاتر از ۰,۹ نشانگر عملکرد بالا و دقت خوب مدل تهیه شده می‌باشد. مقادیر R^2 بین ۰,۸ تا ۰,۹ اشاره به عملکرد قابل قبول شبکه دارد و در نهایت مقادیر R^2 کمتر از ۰,۸ نشان دهنده عدم توانایی مدل جهت پیش‌بینی مقادیر مورد نظر می‌باشد [۳۱]. نتایج نشان داده شده در جدول ۲ همگی گویای دقت، انعطاف‌پذیری و تعیین‌پذیری بالا شبکه طراحی شده در توانایی پیش‌بینی تراوایی محزن می‌باشد.

جدول ۲: مقادیر خطای دقت مدل‌های آنلاین توسط شبکه عصبی

	Train	Validation	Test
MSE	0.002	0.0022	0.0027
R^2	0.98877	0.98778	0.98148

همچنین شکل ۶ رگرسیون داده‌ها در ۴ حالت آموزش، اعتبارسنجی، تست و برای همه داده‌ها نشان می‌دهد.



شکل ۶: نمودار رگرسیون دادها

۴- نتیجه گیری:

در این مطالعه با به کارگیری شبکه عصبی به عنوان روشی نوین سعی در پیش بینی میزان تراوایی با استفاده از داده های چاه پیمایی گردید. شبکه چند لایه پرسپترون با الگوریتم پس انتشار که توسط روش لونبرگ-مارکوات آموزش دیده شده، در این مطالعه مورد استفاده قرار گرفت. ساختار شبکه به صورت ۱-۱۱-۵-۱۰-۱۱ بوده که بیانگر لایه ورودی با تعداد ۱۰ نورون، لایه های پنهان با تعداد ۱۱ و ۵ نورون و در نهایت لایه خروجی با یک نورون می باشد. ارتباط نزدیکی که میان نتایج آموزش و آزمایش در شکل ها نشان داده شد گویای دقت و تعمیم پذیری بالای شبکه می باشد. همچنین این پژوهش نشان می دهد که طراحی و آموزش صحیح شبکه عصبی می تواند آن را به عنوان یکی از مهمترین و بهترین روش های جایگزین جهت پیش بینی تراوایی مخزن مطرح کند.

5- Nomenclature:

ANN	Artificial neural network
CGR	Computed gamma ray
IC	Induction conductivity
NPHI	Neutron porosity
ROHB	Bulk density
DT	Sonic transit time
MSE	Mean square error
S_w	Water saturation

References:

- [^۱] A. Al-Anazi and I. D. Gates, "A support vector machine algorithm to classify lithofacies and model permeability in heterogeneous reservoirs," *Engineering Geology*, vol. 114, pp. 267-277, 2010.
- [^۲] J.-S. Lim, "Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea," *Journal of Petroleum Science and Engineering*, vol. 49, pp. 182-192, 2005.
- [^۳] S. Mohaghegh, R. Arefi, S. Ameri, K. Aminiand, and R. Nutter, "Petroleum reservoir characterization with the aid of artificial neural networks," *Journal of Petroleum Science and Engineering*, vol. 16, pp. 263-274, 1996.
- [^۴] S. Karimpouli, N. Fathianpour, and J. Roohi, "A new approach to improve neural networks' algorithm in permeability prediction of petroleum reservoirs using supervised committee machine neural network (SCMNN)," *Journal of Petroleum Science and Engineering*, vol. 73, pp. 227-232, 2010.
- [^۵] S. O. Olatunji, A. Selamat, and A. Abdulraheem, "A hybrid model through the fusion of type-2 fuzzy logic systems and extreme learning machines for modelling permeability prediction," *Information Fusion*.
- [^۶] G. B. Arpat, F. Gümrak, and B. Yeten, "The neighborhood approach to prediction of permeability from wireline logs and limited core plug analysis data using backpropagation artificial neural networks," *Journal of Petroleum Science and Engineering*, vol. 20, pp. 1-8, 1998.
- [^۷] M. Saemi, M. Ahmadi, and A. Y. Varjani, "Design of neural networks using genetic algorithm for the permeability estimation of the reservoir," *Journal of Petroleum Science and Engineering*, vol. 59, pp. 97-105, 2007.
- [^۸] Y. Huang, T. D. Gedeon, and P. M. Wong, "An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs," *Engineering Applications of Artificial Intelligence*, vol. 14, pp. 15-21, 2001.
- [^۹] M. Jamialahmadi and F. G. Javadpour, "Relationship of permeability, porosity and depth using an artificial neural network," *Journal of Petroleum Science and Engineering*, vol. 26, pp. 235-239, 2000.
- [^{۱۰}] E. A. El-Sebakhy, O. Asparouhov, A.-A. Abdulraheem, A.-A. Al-Majed, D. Wu, K. Latinski, and I. Raharja, "Functional networks as a new data mining predictive paradigm to predict permeability in a carbonate reservoir," *Expert Systems with Applications*, vol. 39, pp. 10359-10375, 2012.
- [^{۱۱}] S. O. Olatunji, A. Selamat, and A. Abdulraheem, "Modeling the permeability of carbonate reservoir using type-2 fuzzy logic systems," *Computers in Industry*, vol. 62, pp. 147-163, 2011.
- [^{۱۲}] G. R. Coates and J. L. Dumanoir, "A NEW APPROACH TO IMPROVED LOG-DERIVED PERMEABILITY," 1973.
- [^{۱۳}] W. W. Johnson, "Permeability Determination From Well Logs and Core Data," presented at the Permian Basin Oil and Gas Recovery Conference, Midland, Texas, 19.^{۹۴}
- [^{۱۴}] H. Kaydani, A. Mohebbi, and A. Baghaie, "Permeability prediction based on reservoir zonation by a hybrid neural genetic algorithm in one of the Iranian heterogeneous oil reservoirs," *Journal of Petroleum Science and Engineering*, vol. 78, pp. 497.^{۱۰۱۱},^{۱۰۴}-.
- [^{۱۵}] M. BEYKI, B. H. RAHIMPOUR, G. HOSSEINYAR, and A. PIRAYEHGAR, "IDENTIFICATION OF WELL LOGS WITH SIGNIFICANT IMPACT ON PREDICTION OF OIL AND GAS RESERVOIRS PERMEABILITY USING STATISTICAL ANALYSIS OF RSE VALUES," *JOURNAL OF SCIENCE (UNIVERSITY OF TEHRAN) (JSUT)*, 2009.
- [^{۱۶}] S. Mohaghegh, R. Arefi, S. Ameri, and D. Rose, "Design and Development of An Artificial Neural Network for Estimation of Formation Permeability," *SPE Computer Applications*, vol. 7, pp. 151-154, 12/01/1995 1995.

- [¹⁷] J. Wiener, J. Rogers, and B. Moll, "Predict permeability from wireline logs using neural networks," *Petroleum Engineer International*, vol. 68, 1995.
- [¹⁸] S. Mohaghegh, B. Balan, and S. Ameri, "State-Of-The-Art in Permeability Determination From Well Log Data: Part 2-Verifiable, Accurate Permeability Predictions, the Touch-Stone of All Models," presented at the SPE Eastern Regional Meeting, Morgantown, West Virginia, 1995.
- [¹⁹] K. Aminian, H. I. Bilgesu, S. Ameri, and E. Gil, "Improving the Simulation of Waterflood Performance With the Use of Neural Networks," presented at the SPE Eastern Regional Meeting, Morgantown, West Virginia, 2000.
- [²⁰] K. Aminian, B. Thomas, H. Bilgesu, S. Ameri, and A. Oyerokun, "Permeability distribution prediction," in *SPE paper, proceeding of SPE Eastern regional conference, October*, 2001.
- [²¹] P. M. Wong, M. Jang, S. Cho, and T. D. Gedeon, "Multiple permeability predictions using an observational learning algorithm," *Computers & Geosciences*, vol. 26, pp. 907-913, 2000.
- [²²] K. Aminian and S. Ameri, "Application of artificial neural networks for reservoir characterization with limited data," *Journal of Petroleum Science and Engineering*, vol. 49, pp. 212-222, 2005.
- [²³] P. Tahmasebi and A. Hezarkhani, "A fast and independent architecture of artificial neural network for permeability prediction," *Journal of Petroleum Science and Engineering*, vol. 86-87, pp. 118-126, 2012.
- [²⁴] G. Arpat, F. Gümrah, and B. Yeten, "The neighborhood approach to prediction of permeability from wireline logs and limited core plug analysis data using backpropagation artificial neural networks," *Journal of Petroleum Science and Engineering*, vol. 20, pp. 1-8, 1998.
- [²⁵] S. Mohaghegh, "Virtual intelligence and its applications in petroleum engineering," *Journal of Petroleum Technology, Distinguished Author Series*, 2000.
- [²⁶] C. M. Bishop, *Neural networks for pattern recognition*: Oxford university press, 1995.
- [²⁷] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators," *Neural Networks*, vol. 2, pp. 359-366, 1989.
- [²⁸] C.-H. Chen and Z.-S. Lin, "A committee machine with empirical formulas for permeability prediction," *Computers & Geosciences*, vol. 32, pp. 485-496, 2006.
- [²⁹] M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm," *Neural Networks, IEEE Transactions on*, vol. 5, pp. 989-993, 1994.
- [³⁰] S. S. Haykin, *Neural networks: a comprehensive foundation*: Prentice Hall Englewood Cliffs, NJ, 2007.
- [³¹] P. Coulibaly and C. K. Baldwin, "Nonstationary hydrological time series forecasting using nonlinear dynamic methods," *Journal of Hydrology*, vol. 307, pp. 164-174, 2005.