تخمین تراوایی مخازن هیدروکربنی به کمک شبکه های عصبی

احسان سعادت‌پور، دانشگاه صنعتی شریف، دانشکده مهندسی برق / مهندسي شيمي و نفت
محمد شاه‌ولی، دانشگاه صنعتی شریف، دانشکده مهندسی برق / مهندسي شيمي و نفت
امیرمنصور پزشک، دانشگاه صنعتی شریف، پژوهشکده الکترونیك
وحید تقي‌خاني، دانشگاه صنعتی شریف، دانشکده مهندسي شيمي و نفت

چکیده

در این مقاله از شبکه‌های عصبی که استفاده از آن در علوم برق و کامپیوتر و سیستم‌های کنترل هوشمند بسیار نمود پیدا کرده، برای تحلیل داده‌های مخزن هیدروکربنی که در مهندسی نفت اهمیت بسیاری دارد استفاده شده است.

تعیین تراوایی سنگ و توزیع آن در یک مخزن هیدروکربنی ناهمگن، مساله‌ای بدون راه حل مشخص و مستقیم است. روش‌های معمول شامل اندازه‌گیری ازمایشگاهی مغزه و چاه‌آزمايي مي‌باشد. متأسفانه، مغزه‌گيري از هر چاه در ميدان‌هاي بزرگ نفتي مانند ميدان‌هاي نفتي ايران و نيز فرآيند چاه‌آزمايي، بسيار هزينه‌بر هستند. هر چند به علت اطلاعات بسيار ارزشمندي كه تراوايي در اختيار ما قرار مي‌دهد، ضروري است كه با وجود گران بودن از تعدادي از چاه‌هاي مخزن مغزه‌گيري شود.

تا به امروز، محققان بسیاری تلاش کرده‌اند تا روابط پارامتری بین تراوایی و ویژگي‌هایی از مخزن هیدروکربنی که مستقیما قابل اندازه‌گیری هستند، مانند تخلخل و عمق بیابند. مهندسين نفت اغلب از تحليل رگرسيون[1] به عنوان ابزار اصلي براي به دست آوردن رابطه بين اين مقادير استفاده مي‌كنند. هرچند به علت طبيعت بسيار پيچيده مساله، روابط خطی یا غیرخطی ارایه شده دقیق و قابل اعتماد نیستند.

يك روش جايگزين براي مدل‌كردن پارامتري، استفاده از شبكه‌هاي عصبي مصنوعي[2] مي‌باشد. اين شبكه‌ها روش‌هاي تحليل بدون الگوريتم داده‌هاي حجيم آنالوگ را ميسر مي‌سازند. از آنجا كه تحليل داده‌ها و آموزش اين شبكه‌ها به صورت موازي و توزيع شده انجام مي‌گيرد، آنها توانايي تشخيص روابط بسيار پيچيده بين متغيرهاي متعدد ارائه شده به شبكه را دارند.

در این مطالعه، الگوریتم لونبرگ-مارکوارت برای تخمین تراوایی یک مخزن هیدروکربنی در ایران به کار گرفته شده است.

کلمات کلیدي: مخزن هیدروکربنی، شبکه عصبی، تراوایی، تخلخل، عمق

[1] Regression Analysis
[2] Artificial Neural Networks (ANN)

۱. مقدمه

يك مخزن هيدروكربني، از سنگ هاي رسوبي لايه اي تشكيل شده است كه در طي يك دوران طولاني رسوبگذاري شده و طي ميليون ها سال تحولات دياژنزي، دچار تغييرات ساختاري شده اند. اين فرآيندها، همراه با تغييرات دائمي و غيرخطي خواص فيزيكي مخزن در طول دوران هاي زمين شناسي مي‌باشند. تراوايي (نفوذپذيري)[1] يكي از مهمترين اين خواص است كه به صورت يك مسأله اساسي براي مهندسين نفت باقي مانده است. اطلاعات مربوط به سنگ متخلخل مخزن به ويژه تراوايی، به مهندسين نفت توانايي طراحي و مديريت مؤثر جهت توسعه ميدان هاي نفت و گاز را مي‌دهد

يكي از قديمي ترين راههاي تخمين تراوايي سازند، استفاده از ابزارهاي مغزه گيري و آوردن مغزه هاي ناحيه توليد مخزن به سطح زمين و اندازه گيري تراوايي اين نمونه ها تحت شرايط مشابه مخزن مي‌باشد. متأسفانه، مغزه‌گيري از هر چاه در ميدان هاي بزرگ نفتي مانند ميدان هاي نفتي ايران، بسيار هزينه بر و غير اقتصادي است. هر چند به علت اطلاعات بسيار ارزشمندي كه تراوايي در اختيار ما قرار مي‌دهد، ضروري است كه با وجود گران بودن از تعدادي از چاه‌هاي مخزن (حدود ۱۰ درصد) مغزه‌گيري شود.

روش معمول ديگر براي تخمين تراوايي مخزن، چاه آزمايي مي‌باشد. اطلاعات به دست آمده از آزمون هايي كه به طور دقيق روي چاه‌ها انجام مي‌گيرد، امكان محاسبه يك ميانگين حجمي از تراوايي سازند را مي‌دهد. به علت هزينه بالاي فرآيند چاه آزمايي (هزينه انجام آزمون به علاوة هزينه توقف توليد در حين انجام آزمون) عموماً فقط تعداد محدودي از آزمون ها در هر ميدان نفتي انجام مي‌گردد.

در ميدان هاي نفتي ايران، مقادير تخلخل[2] و تراوايي كه از نقاط مختلف ميدان به دست آمده‌اند موجود مي‌باشند. مهندسين نفت غالباً از تحليل رگرسيون[3] به عنوان ابزار اصلي براي به دست آوردن رابطه بين اين مقادير استفاده مي‌كنند. در اين روش ها، فرض بر اين است كه يك تابع خطي يا غيرخطي براي مدل كردن رابطه تراوايي و ديگر خواص سنگ كافي است.

يك روش جايگزين براي روش مدل كردن پارامتري، استفاده از شبكه هاي عصبي مصنوعي[4] مي‌باشد. در سال هاي اخير، شبكه هاي عصبي به عنوان ابزارهاي قدرتمندي براي مدل كردن سيستم هاي پيچيده مطرح شده اند. اين شبكه ها روش هاي تحليل بدون الگوريتم داده هاي حجيم آنالوگ را ميسر مي‌سازند. از آنجا كه تحليل داده‌ها و آموزش اين شبكه‌ها به صورت موازي و توزيع شده انجام مي‌گيرد، آنها توانايي تشخيص روابط بسيار پيچيده بين متغيرهاي متعدد ارائه شده به شبكه را دارند. هدف اين كار ايجاد ارتباط بين عمق سنگ، تخلخل به

---

[1] Permeability
[2] Porosity
[3] Regression Analysis
[4] Artificial Neural Networks (ANN)

دست آمده از لاگ و تراوايي حاصل از تحليل مغزه و استفاده از رابطه مذكور جهت پيش‌بيني مقادير تراوايي در چاه‌هايي كه مغزه‌گيري انجام نشده است، مي‌باشد.

۲. شبکه های عصبی مصنوعی

يكي از الهاماتي كه در مورد شبكه هاي عصبي از مغز انسان گرفته شده است اين است كه مغز براي محاسبات خود از ساختاري كاملا مغاير با ساختار كامپيوترها استفاده مي كند. بدين معني كه مغز از يك سري عناصر اصلي به نام نرون[۱] تشكيل يافته است كه عملكرد اين نرون‌ها و پاسخ آنها به صورت جمعي بستگي به ذخيره سازي و حفظ اطلاعات در تك تك نرون‌ها و نحوه ارتباط بين آنها دارد. هدف اين مقاله اين است كه با شبيه سازي اين نرون‌ها با مدل هاي رياضي شبكه اي تشكيل داده كه بتواند شبيه مغز انسان عمل كند و جهت حل مسائل پيچيده كه در اصل چيزي جز يادگيري نگاشت‌ها نيست از آن استفاده شود.

۲-۱ فرآیند آموزش شبکه عصبی

فرآيند آموزش عبارت است از تعيين پارامترهاي شبكه عصبي كه همان w_{ij} و b_i هستند به نحوي كه پس از اتمام اين فرآيند اين پارامترها طوري ثابت شده باشند كه با يك ورودي مشخص، پاسخ مطلوب را با حداقل خطا بدهند. دو كلاس عمدة شبكه‌هاي عصبي از لحاظ نحوة آموزش عبارتند از:

الف) آموزش با ناظر[۲] : در آموزش با ناظر يكسري بردار به عنوان ورودي به همراه مقدار يا مقادير خروجي مطلوب در اختيار شبكه گذاشته مي‌شود تا به وسيلة يك الگوريتم آموزش[۳] مقادير ضرائب وزن تنظيم شوند.

مي‌توان شبكه‌هاي چندلايه را به صورت آموزش با ناظر طوري آموزش داد كه يك سري داده از فضاي n بعدي را به يك سري ديگر از داده‌ها در فضاي m بعدي بنگارد.

ب) آموزش بدون ناظر[٤] : شبكه‌هاي عصبي خود سازمان[٥] بدون استفاده از مقادير هدف[٦] قادرند بردارهاي ورودي را دسته‌بندي كنند، به نحويكه بردارهايي كه مشابه يكديگر هستند در يك گروه قرار گيرند. شبكه طوري ضرائب وزن را تنظيم مي‌كند كه بردارهايي كه شباهت بيشتري دارند در يك گروه قرار بگيرند.

---

[1] Neuron
[۲] Supervised Training
[۳] Training Algorithm
[٤] Unsupervised Training
[٥] Self Organizing Neural Network
[٦] Target Values

به طور خلاصه مي‌توان گفت كه در فرآيند آموزش سه مرحله زير به ترتيب انجام مي‌شود:

۱. سيستم يادگيرنده توسط محيط تحريك مي‌شود.
۲. قانون آموزش با رجوع به نتيجه تحريك، پارامترهاي سيستم يادگيري را تغيير مي‌دهد.
۳. سيستم يادگيرنده به خاطر تغييراتي كه در ساختمان داخلي آن اتفاق افتاده پاسخ مناسب تري به محيط مي‌دهد.

شبكه هاي عصبي داراي اين خاصيت هستند كه از گذشته، تجربه و محيط بياموزند و رفتار خود را در حين يادگيري بهبود بخشند. قوانين آموزش توسط روابط بازگشتي كه عمدتا بصورت معادلات تفاضلي هستند بيان مي‌شوند. به اين روابط بازگشتي قوانين آموزش مي‌گويند و توسط آن ماتريس وزنها و بردارهاي بایاس شبكه عصبي تنظيم مي‌شوند و اين شبكه عصبي در خلال آموزش پس از هر بار تكرار الگوريتم آموزش از محيط، شرايط و هدف كار خود مطلع تر مي‌گردد.

۲-۲ الگوريتم پس انتشار **BP**[1]

چون الگوريتم BP از سري الگوريتم هاي آموزش با ناظر است، لذا فرض مي‌شود تعداد N الگوي مشخص به صورت زوج برداري (X(k), D(k)) وجود دارد. پس هر گاه كه يكي از الگوها وارد مي‌شود، ماتريس پاسخ واقعي شبكه يعني Y(k) دريافت مي‌شود و مي توان به راحتي ماتريس خطاي شبكه يا E(k) را بدست آورد و لذا براي دفعه Kام داريم:

$$E(k) = D(k) - Y(k) \qquad (۱)$$

شاخص اجرايي يا به عبارتي مشخصه اي كه تعداد خطاي شبكه را به صورت يك اسكالر بر مي‌گرداند، شاخص مجموع مربعات خطا انتخاب شده است كه براي دفعه k ام به صورت زير است:

$$\hat{F}(k) = \sum_{i=1}^{n(L)} e_i^2(k) = E(k) \times E(k)^T \qquad (۲)$$

نكته اي كه بايد حتماً به آن دقت شود اين است كه شاخص اجرايي فقط و فقط براي لاية آخر قابل دسترسي است چرا كه مقادير مطلوب فقط براي لاية آخر در دسترس هستند. ديگر آنكه همانطور كه ديده مي‌شود، $\hat{F}(k)$ يك تابع از هر الگو است و با هر بار تكرار تغيير مي كند. از طرفي چون الگوريتم يادگيري بصورت يك حلقه است بايد شاخصي وجود داشته باشد تا در انتهاي يك سيكل بررسي شود و اين شاخص باعث خروج از حلقه شود. براي اين الگوريتم شاخص $\hat{F}_{av}(c)$ چنين تعريف مي‌شود:

$$\hat{F}_{av}(c) = \frac{1}{N} \sum_{i=1}^{N} \hat{F}(cN - i) \qquad (۳)$$

اما براي هر دفعه تصحيح از $\hat{F}(k)$ استفاده مي‌شود نه $\hat{F}_{av}(c)$.

[1] Back Propagation

نكته اي كه پايه و اساس اين الگوريتم را تشكيل مي دهد پاسخ به اين سوال است كه چه عواملي در تغيير $\hat{F}(k)$ تأثير دارند؟ چون ورودي ها ثابت هستند و تغييري ندارند پس اين تغييرات $b_i^l(k), w_{ij}^l(k)$ هستند كه باعث تغيير در $\hat{F}(k)$ مي‌شود. حال اگر سهم هر يك از پارامترهاي شبكه در تغيير $\hat{F}(k)$ مشخص باشد يا به عبارت ديگر، نسبت تغييرات $\hat{F}(k)$ به تغييرات آن پارامتر پيدا شود و به بيان واضح تر $\frac{\partial \hat{F}(k)}{\partial w_{ij}^l(k)}$ و $\frac{\partial \hat{F}(k)}{\partial b_i^l(k)}$ را در اختيار داشته باشيم مي توان از دو فرمول زير استفاده كرده و پارامترهاي شبكه را طوري تغيير داد كه پاسخ به سمت مقدار مطلوب ميل كند:

$$\begin{cases} w_{ij}^l(k+1) = w_{ij}^l(k) - \alpha \dfrac{\partial \hat{F}(k)}{\partial w_{ij}^l(k)} \\ b_i^l(k+1) = b_i^l(k) - \alpha \dfrac{\partial \hat{F}(k)}{\partial b_i^l(k)} \end{cases} \qquad (۴)$$

در اين محاسبات α پارامتري است كه به آن نرخ يادگيري گفته مي‌شود.

بنابراين آنچه مورد نظر است $\frac{\partial F(k)}{\partial w_{ij}^L(k)}$ يا $\frac{\partial F(k)}{\partial b_i^L(k)}$ مي باشد كه براي يافتن اين مشتقات از قانون زنجيره اي استفاده مي‌شود.

۳-۲ الگوريتم لونبرگ-مارکوآرت[1]

الگوريتم BP با وجود معمول بودنش داراي دو ضعف عمده و اساسي است. اول سرعت كم همگرايي آن و دوم ساكن شدن و متوقف شدن پارامترهاي شبكه به دليل به دام افتادن آنها در نقاط مينيمم محلي قبل از پايان يادگيري كامل شبكه. لذا در اينجا روش آموزشي مارکوآرت ارايه خواهد شد. اين روش نسبت به روش BP صدها برابر سريعتر است. ويژگي ديگر اين روش كاهش شديد تعداد نرون هاي لايه مخفي در ساختار شبكه است.

روش آموزش مارکوآرت تقريبي از روش گوس ـ نيوتن است:

$$\nabla z = -\underbrace{\left[\nabla_z^2 J(z)\right]}_{M\times M}^{-1} \times \underbrace{\nabla_Z J(z)}_{M\times 1} \qquad (۵)$$

M : تعداد كل پارامترهاي شبكه

N : تعداد كل الگوها

$n(L)$: تعداد نرون هاي لايه آخر

$$\underbrace{\nabla_z^2 J(z)}_{M\times M} = \underbrace{J^T(z)}_{M\times(N\cdot n(L))} \cdot \underbrace{J(z)}_{(N\cdot n(L))\times M} + \underbrace{R(z)}_{M\times M} \qquad (۶)$$

$$\underbrace{\nabla_Z J(z)}_{M\times 1} = \underbrace{J^T(z)}_{M\times(N\cdot n(L))} \cdot \underbrace{E(z)}_{(N\cdot n(L))\times 1} \qquad (۷)$$

[1] Levenberg-Marquardt

براي الگوريتم مورد نظر ما $R(z) \cong 0$ است. و لذا مي توان گفت:

$$\nabla z = -\left[J^T(z) \cdot J(z)\right]^{-1} \times \left[J^T(z) \cdot E(z)\right] \qquad (۸)$$

که رابطه فوق براي استفاده به صورت زير تصحيح مي‌شود:

$$\nabla z = -\left[J^T(z) \cdot J(z) + \eta I\right]^{-1} \times \left[J^T(z) \cdot E(z)\right] \qquad (۹)$$

η ضريب يادگيري ماركوآرت نام دارد و هر چه اين ضريب غيرمنفي بزرگتر انتخاب شود روش به روش BP نزديكتر مي‌شود و هر چه كوچكتر انتخاب شود اين روش به روش گوس ـ نيوتن نزديكتر خواهد شد و سرعت يادگيري نيز با η هاي كوچكتر بيشتر مي‌شود.

۳. انتخاب و آماده‌سازي داده‌ها براي آموزش شبكه عصبي

بدون شك يكي از مهمترين بخش‌هاي مربوط به ايجاد و توسعة شبكه‌هاي عصبي، انتخاب داده‌ها است. نخستين مسأله بررسي صحت داده‌هاي موارد انتخاب شده براساس گزارش‌ها مي‌باشد. در صورتي كه در گزارشات مربوط به مغزه قيد شده باشد كه شرايط گرفتن مغزه غيراستاندارد بوده است و تغييرات ثانويه‌اي حين عمليات مغزه‌گيري و انتقال ايجاد شده است (مثلاً شكستگي مغزه حين عمليات كه ممكن است از آن تعبير به حضور ترك بشود) دادة مربوطه كنار گذاشته مي‌شود.

اين داده‌ها كه براي استفاده در فرايند آموزش شبكة عصبي انتخاب مي‌شوند را مستقيماً نمي‌توان مورد استفاده قرار داد. چرا كه اين كار فرايند آموزش را مشكل‌تر مي‌كند و كارايي شبكه را مي‌كاهد. لذا يك سري نرمال سازي روي داده‌ها انجام مي‌شود. در نرمال‌سازي سعي مي‌شود كه داده‌ها در يك بازة متقارن (مثلاً بين ۱+ تا ۱-) و متوسط نزديك به صفر و انحراف معيار استاندارد نزديك به يك، توزيع شوند.

در اين مطالعه داده‌ها بين ۰/۸+ تا ۰/۸- نرمال‌سازي شدند. بنابر آنچه در منابع آمده است، بهتر است داده‌ها را در بازه‌اي كوچكتر از دامنة توابع فعالسازي نرمال نمود. اين كار از آن جهت است كه اگر يك تابع غيرخطي متداول كه به عنوان تابع فعالسازي در نظر گرفته مي‌شود، مثلاً توابع تانژانت سيگموئيد و يا لگاريتم سيگموئيد، آرگومان ورودي $(\sum w_i x_i)$ با قدر مطلق بزرگ داشته باشد، خروجي نرون‌ها در كرانه‌هاي بردِ تابع فعالسازي قرار مي‌گيرد. تكرار اين روال موجب به وجود آمدن وزنه‌هايي با قدر مطلق بزرگ مي‌شود. چرا كه قدر مطلق آرگومان تابع فعالسازي $(\sum w_i x_i)$ تا حدي بايد بزرگ شود كه بتواند خروجي مطلوب را توليد نمايد.

اين وضيت همانطور كه گفته شد موجب توليد وزنه‌هايي با قدر مطلق بزرگ مي‌شود و اصطلاحاً گفته مي‌شود كه شبكه «اشباع»[۱] شده است. اشباع شدن شبكه در حين آموزش موجب مي‌شود كه الگوريتم اصلاح وزنه‌ها هر قدر هم سعي در اصلاح وزنه‌ها نمايد تا شبكة مطلوب را

[۱] Saturated Network

به دست آورد، نتواند تغيير مشخصي در وزنه‌هاي بزرگ ايجاد نمايد. لذا در فرايند آموزش اخلال ايجاد مي‌شود.
همانطور كه شكل (۱) نشان مي‌دهد، مقادير تراوايي توزيع ناهمگني دارند و مقادير تراوايي در نواحي به خصوصي تجمع كرده‌اند.

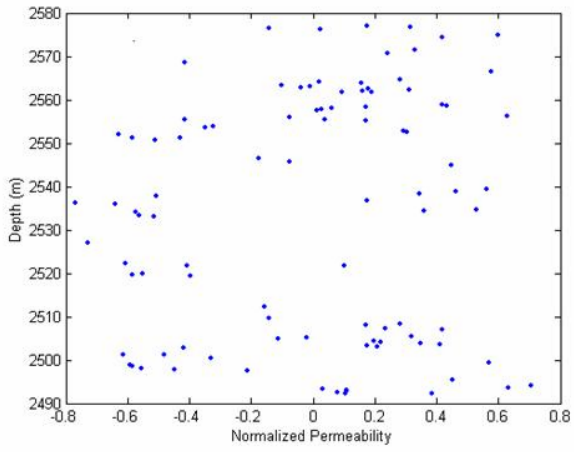

شكل (۱) تراوايي نرمال شده برحسب عمق

استفاده از داده‌هاي تراوايي به همين شكل اوليه منجر به توليد شبكه‌اي مي‌شود كه قادر به پيش‌بيني مناسب تراوايي در نواحي كه داده‌هاي بيش‌تري تجمع كرده‌اند، است. در نتيجه در پيش‌بيني تراوايي در جاهائي كه تجمع داده‌ها كمتر بوده است با تخمين بدي مواجه مي‌شويم. جهت رفع اين مشكل داده‌هاي موجود را بالانس مي‌كنيم. ابتدا بازة ۰/۸+ تا ۰/۸- را به هشت بازه مساوي (طول هر بازه ۰/۲) تقسيم مي‌نماييم. طبيعي است كه با توجه به توضيحات داده شده، برخي بازه‌ها تجمع بيشتري از لحاظ ميزان داده‌ها دارند و برخي بازه‌هاي ديگر داده‌هاي كمتري را در خود جاي داده‌اند.
براي بالانس كردن داده‌ها، يك تعداد مشخص از داده‌هاي تراوايي براي هر بازه در نظر گرفته مي‌شود. بازه‌هايي كه تعداد داده‌هايشان بيشتر است، به صورت تصادفي تعدادي از داده‌هايشان كنار گذاشته مي‌شود. به اين ترتيب به يك سري داده كه توزيع يكنواختي دارد مي‌رسيم. حال داده‌ها براي ورود به شبكه و شروع فرآيند آموزش آماده است.
تكنيك ديگري كه در آموزش شبكه به ويژه در مواردي كه داده‌هاي محدودي در اختيار است، مي‌تواند مفيد باشد، تكنيك جابجايي[۱] است. در اين تكنيك پس از آنكه آموزش شبكه با همة توضيحاتي كه داده شد انجام شد، از وزنه‌هاي حاصل به عنوان وزنه‌هاي اولية دور دوم آموزش شبكه استفاده مي‌شود و در عين حال در اين دور جديد آموزش، جاي داده‌هاي آزمون و تأييد

[۱] Shuffling

عوض مي‌شوند. يعني داده‌هاي تأييد قبلي به عنوان داده‌هاي آموزش جديد و داده‌هاي آموزش قبلي به جاي داده‌هاي تأييد فعلي استفاده مي‌شود. وظيفة داده‌هاي آزمون ثابت است.

۴. آموزش شبكه

شبكه مي‌بايست هم در پيش‌بيني مقاديري كه در آموزش به كار برده شده است و هم در پيش‌بيني مقاديري كه در آموزش استفاده نشده است، موفق عمل نمايد. لذا داده‌ها به سه دسته تقسيم مي‌شوند:

۱. داده هاي آموزش[۱]
۲. داده‌هاي تأييد[۲]
۳. داده‌هاي آزمون[۳].

از داده‌هاي آموزش براي تعيين وزنه‌ها استفاده مي‌شود. داده‌هاي تأييد اگر چه در حين آموزش مورد استفاده قرار مي‌گيرند، اما در تعيين وزنه‌ها نقش مستقيمي ندارند. وظيفة داده‌هاي تأييد اينست كه بر قابليت تعميم[۴] شبكه به موازات آموزش شبكه نظارت داشته باشد.

بعد از آنكه همة داده‌هاي آموزش يك دور كامل به شبكه ارائه شدند، با استفاده از وزنه‌هاي حاصل، داده‌هاي تأييد وارد شبكه شده و مقادير تراوايي مربوطه محاسبه مي‌شوند. مقادير تراوايي محاسبه شده توسط شبكه هم براي داده‌هاي آموزش و هم براي داده‌هاي تأييد با مقادير اصلي مقايسه شده و مقادير خطاي داده‌هاي آموزش و تأييد محاسبه مي‌شوند. اين خطاها (خطاي داده‌هاي آموزش و تأييد) بعد از هر دور كامل ارائه داده‌هاي آموزش به شبكه مجدداً محاسبه مي‌شود. مشاهده مي‌شود كه از يك مرحله به بعد خطاي داده‌هاي تأييد رو به افزايش مي‌گذارد. اين بدان معناست كه شبكه قدرت تعميم خود را رفته رفته از دست مي‌دهد و در واقع به حفظ كردن داده‌هاي آموزش مي‌پردازد، بدون آنكه قادر به دريافت ارتباط صحيح بين داده‌هاي ورودي و خروجي باشد. لذا بعد از آنكه شبكه بعد از يك سري دفعات متوالي خطاي تأييد بيشتري توليد نمود، فرآيند آموزش مي‌بايست متوقف شود و وزنه‌هاي مربوط به كمترين خطاي تأييد، به عنوان بهترين نتيجة مربوط به آموزش در نظر گرفته شود. در صورتي كه ميزان خطاها مطلوب نباشد، دور جديدي از آموزش بايستي آغاز شود.

پس از آنكه خطاي مربوط به داده‌هاي آموزش و داده‌هاي تأييد به ميزان مطلوب رسيد، از داده‌هاي آزمون كه هيچ‌گونه استفاده‌اي تا اين مرحله از كار از آنها به عمل نيامده است، براي سنجيدن نهايي قابليت تعميم شبكه استفاده مي‌شود. اين دسته داده به شبكة آموزش ديده (كه ضرايب وزن مطلوب آن تعيين شده است) وارد مي‌شوند و خروجي آنها محاسبه شده و با

---

[۱] Training Data
[۲] Validation Data
[۳] Test Data
[۴] Generalization

مقادير اصلي مقايسه مي‌شود. خطاي حاصله (خطاي داده‌هاي آزمون) در صورتي كه ميزان مطلوبي داشته باشد كار به اتمام رسيده است.
حال مي‌توان شبكة آموزش ديده را براي پيش‌بيني تراوايي در چاههايي كه مغزه‌گيري انجام نشده است به كار برد.

۵. ارائه و تحليل نتايج

فرآيند يادگيري به اين صورت انجام مي‌گيرد كه ابتدا حدس اوليه اي براي اوزان و مقادير بایاس شبكه انجام مي‌گيرد. سپس با استفاده از يك قانون يادگيري اين مقادير تصحيح مي‌شوند و آن قدر اين دفعات تكرار ادامه مي‌يابند كه اوزان و بایاس‌ها ثابت شوند يا اختلاف آنها در دفعات به حداقل برسد. اگر شبكه مناسبي طراحي كرده باشيم (از نظر ساختار) و قانون يادگيري مناسبي هم انتخاب كرده باشيم و حدس اوليه خوبي هم از طرف رايانه به صورت اتفاقي زده شده باشد، مي‌توان گفت كه حتماً در كمتر از ۱۰۰ دفعه تكرار (در بسياري از موارد حتي كمتر از ۵۰ تا) به جواب خواهيم رسيد. در غير اين صورت، در انتهاي هر مرحله كه تعداد دفعات تكرار در فرآيند يادگيري به ۱۰۰ مي‌رسد نتيجه نمايش داده خواهد شد.
تابع عملكرد (هزينه) استفاده شده MSE مي‌باشد يعني ميانگين مجموع خطاها براي داده هاي آموزشي كه در عين حال معيار خيلي دقيقي هم براي آموزش شبكه نمي تواند باشد. واضح است كه هر چه خطا روي خود داده هاي آموزشي كمتر باشد شبكه آموزش بهتري ديده است، اما اين اصل هميشه برقرار نيست، چرا كه در بسياري از موارد ديده شده است كه شايد $MSE=10^{-4}$ بوده است اما شبكه عصبي مورد نظر به داده هاي آزمون اصلاً پاسخ خوبي نداده است. اين دقيقاً به خاطر نوساني شدن رفتار شبكه است.
شبكه دو لايه مياني دارد كه در لايه اول ۸ نرون با تابع تبديل tansig و در لايه دوم هم ۶ نرون با تابع تبديل tansig قرار گرفته است. لايه خروجي هم يك نرون دارد كه تابع آن خطي يا purelin است.
پس از اجرای کد نوشته شده به زبان MATLAB و با در نظر گرفتن روش‌ها و موارد ذکر شده در قسمت های قبلی، نتیجه قابل قبولی آن چنان که در زیر آمده است، به دست آوردیم:

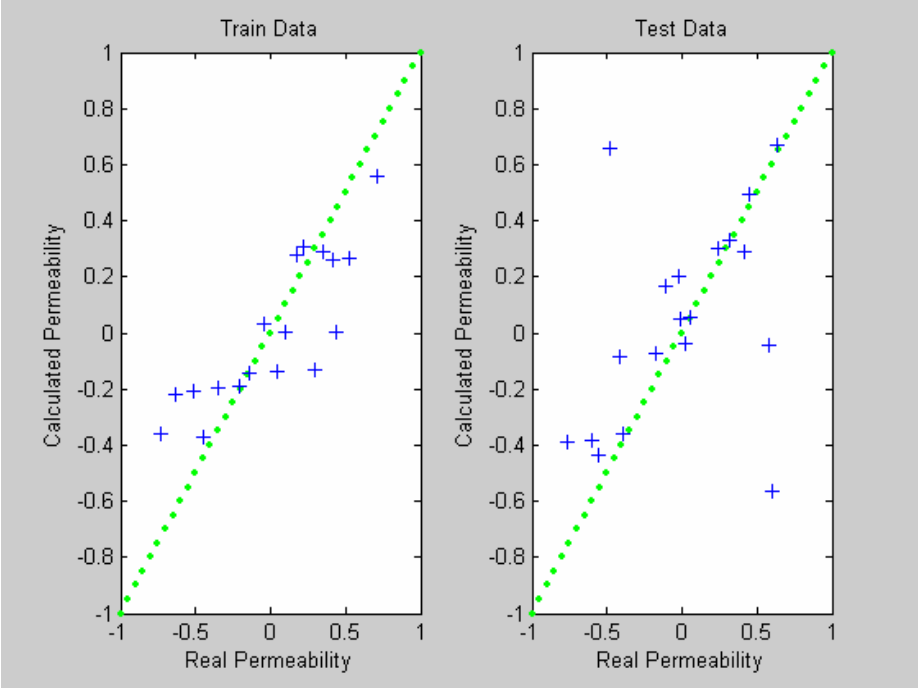

شکل (۲) مقادير تراوايي واقعي (نرمال شده) در برابر مقادير تراوايي محاسبه شده (نرمال شده)

خطاي مطلق متوسط[۱] بهترين شبكة آموزش داده شده برابر با ۱۲,۷% است. خطاي[۲] داده‌هاي آموزش براي شبكه مذكور ۴,۳% ، خطاي داده‌هاي تأييد ۱۵,۳% و خطاي داده‌هاي آزمون ۱۸,۶% مي‌باشد. می‌توان در شکل (۳) روند سیکل[۳]های طی شده تا رسیدن به شبکه مطلوب را مشاهده نمود.

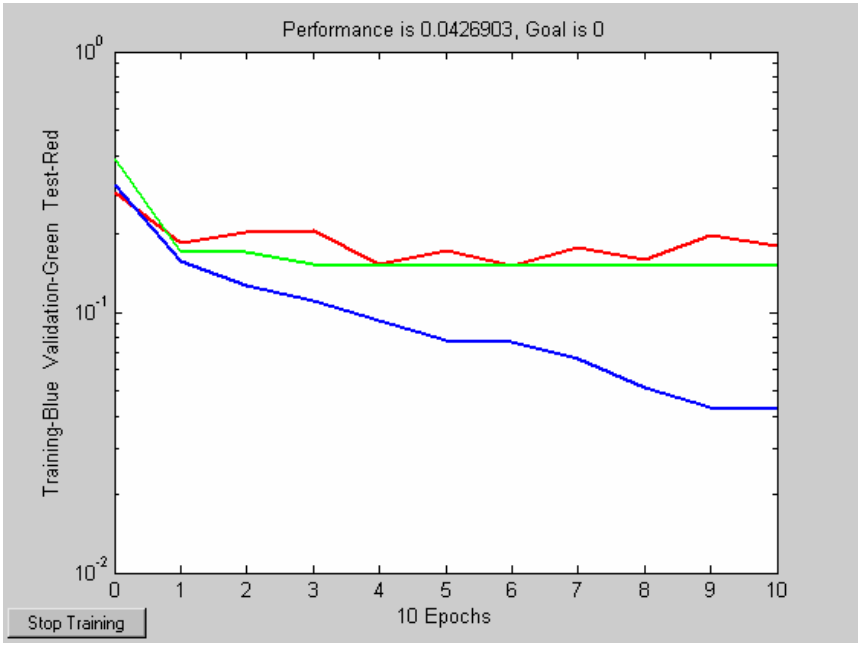

شکل (۳) نمایش تابع هزینه در حین آموزش شبکه

[۱] Absolute Mean Average Error
[2] Mean Square Error
[3] Epoch

۶. بحث و نتیجه گیری

۱. این تحقیق نشان می دهد که شبکه های عصبی پیش‌خور، توانایی تخمین تراوایی با استفاده از داده های حاصل از مغزه‌گیری و نمودارگیری چاه را دارند.

۲. این طرح همچنین با ملزومات عملياتي و واقعي نيز همخواني دارد. چرا كه در همه چاهها، لاگ گرفته مي‌شود و همانطور كه پيشتر نيز ذكر شد در تعداد معدودي از چاهها مغزه‌گيري انجام مي‌گيرد. لذا با در اختيار داشتن شبكه آموزش ديده مطلوب، مي‌توان به تخمين تراوايي در چاههايي كه صرفاً لاگ دارند اقدام نمود. در نتيجه در هر چاه تخميني از تراوايي حاصل مي‌شود كه با استفاده از اين مقادير مي‌توان مدل بهتر و قابل اطمينان‌تري براي مخزن جهت شبيه‌سازي فراهم نمود.

۳. هنگامي كه ورودي‌ها را وارد كنيم، فرآيند آموزش شبكه عصبي طراحي شده شروع مي‌شود. اين فرآيند به عوامل بسيار زيادي حساس است و ساختار شبكه عصبي مانند تعداد نرون‌ها در هر لايه، تعداد لايه ها و توابع مورد استفاده و قوانين يادگيري مورد استفاده جزو عوامل بسيار تأثير گذار در امر يادگيري هستند و بايستي بسيار خوش شانس باشيم كه شبكه عصبي در اولين طراحي پاسخ مناسبي بدهد چرا كه هيچ نوع فرمول يا قانون مشخصي براي تعيين بهترين طراحي بسته به نوع كاربرد وجود ندارد و طراحي مناسب فقط بر پايه سعي و خطا استوار است. به زبان بهتر طراحي يك فرآيند تجربي است.

۴. در مورد شبكه هاي عصبي مواردي وجود دارد كه MSE كوچك و يا حتي صفر است اما شبكه به داده هاي آزمون پاسخ خوبي نمي دهد كه اين به خاطر نوساني شدن رفتار شبكه است.

۷. مراجع

Gurney, K.: “An Introduction to Neural Networks”, UCL Press Limited, London, 1997.

Hopfield, J.J., Tank, D.W.: “Neural computation of decisions in optimization problems”, Biological Cybernetics, 1985, 52: 141-152.

Athichanagorn, S., Horne, R.N.: “Automatic parameter estimation from well test data using artificial neural networks”, SPE 30556, 1995.

Mohaghegh, S.D., Arefi, R., Ameri, S., Rose, D.: “Design and development of an artificial neural network for estimation of formation permeability”, SPE 28237, 1994.

Mohaghegh, S.D.: “Virtual Intelligence Applications in Petroleum Engineering: Part 1–Artificial Neural Networks”, SPE 58046, JPT (September 2000) 64.