

تخمین تخلخل در یک مخزن هیدروکربوری با استفاده از ترکیب الگوریتم شبیه‌ساز تبرید و شبکه عصبی

مصنوعی - مطالعه موردی

هادی فتاحی

گروه مهندسی معدن، دانشگاه صنعتی اراک، اراک

هوپاد سپهر

گروه مهندسی معدن، دانشگاه صنعتی اراک، اراک

تاریخ پذیرش: ۱۳۹۷/۱۱/۰۹

تاریخ دریافت: ۱۳۹۷/۰۵/۲۷

h.fattahi@arakut.ac.ir

چکیده

مطالعه و بررسی ذخایر هیدروکربوری فرآیندی است که نیازمند تعیین خصوصیات و مشخصات ذخیره و تغییرات آنها در ابعاد مختلف با استفاده از داده‌های در دسترس است. تخلخل یکی از خصوصیات اصلی ذخایر هیدروکربوری است که نشان دهنده حجم سیال منفذی و قابلیت حرکت کردن آن است. تخلخل اهمیت فراوانی در عملیات بهره‌برداری و مدیریت مخازن دارد. تعیین تخلخل توسط روش‌هایی مانند آنالیز مغزه مستلزم صرف زمان و هزینه گزافی می‌باشد و همچنین به علت نبود مغزه‌های کافی و تغییرات سنگ‌شناسی و ناهمگنی سنگ مخزن، تعیین این پارامتر توسط روش‌های معمول از دقت چندانی برخوردار نمی‌باشد. همچنین تاکنون روابط تجربی فراوانی نیز در مورد محاسبه تخلخل ارائه شده است، اما در بیشتر موارد استفاده از این روابط در مناطق مختلف نمی‌تواند مطلوب باشد. روش‌های هوش محاسباتی از روش‌های جدید، کم هزینه و دقیقی هستند که می‌توانند با استفاده از داده‌های چاه‌نگاری، تخلخل مخزن را در کمترین زمان ممکن بصورت غیرمستقیم تخمین بزنند. لذا در این مطالعه با استفاده از چاه‌نگارهای مختلف و یک روش ترکیبی هوش محاسباتی (شبکه عصبی مصنوعی بهینه شده با الگوریتم شبیه‌ساز تبرید) تخلخل را در یکی از مخازن هیدروکربوری جنوب غربی ایران (میدان مارون) بصورت غیرمستقیم تخمین زده شده است. جهت بکارگیری این روش ترکیبی هوش محاسباتی پایگاه داده متشکل از ۱۳۵۶ داده‌ی چاه‌نگاری، شامل وزن مخصوص، تخلخل نوترون، لاگ مقاومت ویژه الکترومغناطیسی، لاگ پرتو گاما و لاگ صوتی می‌باشد. نتایج مدل‌سازی این تحقیق نشان می‌دهد که روش ترکیبی هوش محاسباتی مذکور برای تخمین غیر مستقیم تخلخل در مخازنی که تخلخل از طریق مغزه اندازه‌گیری نشده دارای دقت و قابلیت بالایی است.

کلمات کلیدی: تخلخل، الگوریتم شبیه‌ساز تبرید، شبکه عصبی مصنوعی، مخزن هیدروکربوری، چاه‌نگارهای مختلف

مقدمه

افزایش تولید هستند (Rezaee et al., 2007). تخمین غیرمستقیم تخلخل از روی چاه‌نمودارها شامل چندین روش متفاوت می‌باشد که به سه دسته عمده تقسیم‌بندی می‌شوند: روش‌های تجربی، روش‌های آماری و روش‌های هوش محاسباتی. در روش تجربی معمولاً اندازه‌گیری پارامترهای مخزن با استفاده از نمونه‌های استوانه‌ای سنگ، جهت اعتبار پیش‌بینی‌های صورت گرفته شده می‌باشد که به عنوان داده‌های مورد نیاز جهت توسعه مدل‌های ریاضی مخزن استفاده می‌شوند. از بزرگترین معایب این روش، نبود یک روش اندازه‌گیری دقیق جهت تخمین تخلخل در مخزن است. از طرفی دیگر این مدل‌ها که برای سازندهای خاصی ساخته شده، قابلیت تعمیم یافتگی نداشته و برای سایر سازندها غالباً بسیار ضعیف عمل می‌نمایند. در روش‌های آماری رابطه‌ی ریاضی بین نمودارهای چاه‌نگاری و مقادیر خواص پتروفیزیکی (در این مطالعه تخلخل) برقرار می‌شود؛ که دقت این رابطه بر اساس روش‌های آماری رگرسیون مشخص می‌شود.

تخلخل یکی از پارامترهای بسیار مهم در مخازن هیدروکربوری محسوب می‌شود. بطوریکه این پارامتر عامل مهم نفت گیر تلقی شده و تخمین صحیح آن اطلاعات مفیدی از مخازن هیدروکربوری نظیر لیتولوژی، حجم سیال منفذی و تفسیر ژئوفیزیکی به دست می‌دهد، که در تصمیم‌گیری‌های بعدی که در مورد مخزن صورت می‌گیرد اهمیت بسزایی دارد. از طرفی درجه‌ی موفقیت بسیاری از فعالیت‌های مهندسی که روی مخزن انجام می‌شود بستگی به دقت روش‌های مورد استفاده در توصیف مخزن دارد. برای تعیین پارامترهای مخزن در صنعت دو روش معمول و کاربردی وجود دارد: آنالیز مغزه^۱ به عنوان روش مستقیم و ارزیابی داده‌های چاه‌نگاری^۲ به عنوان روش غیر مستقیم. اغلب برداشت داده‌ها در روش آنالیز مغزه در معدودی از چاه‌های یک میدان صورت می‌گیرد که یکی از دلایل آن ممکن است هزینه‌های غیراقتصادی در پروژه^۳ مد نظر باشد. به همین منظور تقریباً در اکثر چاه‌های یک میدان نمودارگیری^۳ در حین یا بعد از عملیات حفاری صورت می‌گیرد.

در حال حاضر تقریباً در تمامی میدانی نفتی و گازی دنیا به دنبال روش‌هایی برای دستیابی به پارامترهای مخزنی از روی اطلاعات چاه‌نگاری به منظور ارزیابی سازند، بهبود عملیات حفاری، کاهش ریسک هزینه حفاری و همچنین

1-Core Analysis
2- Well Logging Evaluation
3- Logging

سرعت موج برشی از داده‌های پتروفیزیکی واقع در نهشته‌های ماسه‌سنگی حوزه کارنارون استرالیا استفاده کردند یوه و وانگ (Yue and Wang 2007) از ماشین بردار پشتیبان برای پیش‌بینی ضخامت ماسه‌سنگ از روی شکل موج در یک میدان نفتی استفاده کردند. آنیفوز و همکاران (Anifowose, Labadin et al., 2015) با استفاده از مدل تعمیمی ماشین بردار پشتیبان نظرات کارشناسان مختلف را با هم ترکیب و بهینه‌ترین پارامترها را جهت پیش‌بینی تخلخل و نفوذپذیری ذخایر نفتی پیشنهاد کردند. نورافکن و کدخدائی ایلخچی (Nourafkan and Kadkhodaie-Ilkhchi, 2015) با استفاده از ترکیب سیستم استنتاجی فازی و الگوریتم بهینه مورچگان سرعت موج برشی میدان نفتی چشمه خوش در جنوب غربی ایران را تخمین زدند. ثب الشیخ و همکاران (Sebtosheikh, Motafakkerfard et al., 2015)، با استفاده از داده‌های نمودارهای چاه‌پیمایی و روش ماشین بردار پشتیبان به پیش‌بینی سنگ‌شناسی یک مخزن ناهمگن هیدروکربوری واقع در جنوب غربی ایران پرداختند. انصاری و غلامی (Ansari and Gholami 2015) مدل رگرسیون بردار پشتیبان توسعه یافته‌ای را برای پیش‌بینی اشباع شدگی نفت خام در شمال آمریکا ارائه نمودند. احمدی و همکاران (Ahmadi, Ahmadi et al., 2014) با استفاده از نمودارهای پتروفیزیکی و یک مدل ترکیبی مبتنی بر دو روش هوشمند منطق فازی و ماشین بردار پشتیبان بهینه شده توسط الگوریتم ژنتیک برای پیش‌بینی تخلخل و نفوذپذیری میدان نفتی شمال خلیج فارس ارائه دادند. بازیار و همکاران (Baziar, Gafoori et al., 2015) از ماشین بردار پشتیبان با سه تابع کرنل مختلف (تابع پایه‌ای شعاعی، سیگموئید و خطی) و شبکه عصبی مصنوعی پرسپترون چندلایه برای ساختن مدل‌هایی جهت پیش‌بینی نفوذپذیری در یک مخزن متراکم گازی در حوضه رسوبی واشاکا استفاده کردند. باقری‌پور و همکاران (Bagheripour, Gholami et al., 2015) با استفاده از بردار پشتیبان رگرسیونی سرعت موج برشی سنگ مخزن نفتی واقع در سازند آسماری را پیش‌بینی نمودند. غلامی و همکاران (Gholami and Moradzadeh 2012) از رگرسیون بردار رابط و الگوریتم ژنتیک (به عنوان بهینه‌ساز)، برای پیش‌بینی نفوذپذیری در یکی از مخازن کربناته جنوب ایران استفاده کردند. ثب الشیخ و همکاران (Sebtosheikh, Motafakkerfard et al., 2015) از روش ماشین بردار پشتیبان به پیش‌بینی سنگ‌شناسی مخزن هیدروکربوری در جنوب غربی ایران پرداختند. احمدی و همکاران (Ahmadi, Ebadi et al. 2014) با استفاده از کمترین مربعات ماشین برداری پشتیبان مقدار نفوذپذیری یک مخزن هیدروکربوری را پیش‌بینی نمود. آنیفوز و همکاران (Anifowose, Labadin et al., 2013) مقایسه‌ای مبتنی بر پیش‌بینی تخلخل و نفوذپذیری ذخایر نفت و گاز از میادین مختلف با ساختار زمین‌شناسی و سنگ‌شناسی متفاوت با استفاده از سه روش سیستم استنتاجی نروفازی تطبیقی و دو مدل ترکیبی (تابع عملگر ماشین بردار پشتیبان و تابع عملگر منطق فازی نوع دوم) انجام دادند. اسکندری و همکاران (Eskandari, Rezaee et al., 2004) برای پیش‌بینی سرعت موج برشی در یک مخزن کربناته واقع در جنوب غربی ایران از روش شبکه عصبی مصنوعی و رگرسیون چندمتغیره استفاده کردند. بوادو (Boadu 2001) با استفاده از مدل‌های پتروفیزیکی و شبکه‌های عصبی مصنوعی و اندازه‌گیری سرعت امواج برشی و فشاری در آزمایشگاه، اشباع‌شدگی نفت در سطوح ناشناخته را پیش‌بینی کردند. رجبی و همکاران (Rajabi, Bohloli et al., 2010) با استفاده از روش‌های هوشمند منطق فازی، الگوریتم ژنتیک و نروفازی سرعت امواج فشارشی، برشی و استونلی از نگارهای چاه‌پیمایی مربوط به مخزن

هدف کلی رگرسیون‌های چندگانه جهت یادگیری بیشتر پیرامون ارتباط میان چندین متغیر مستقل و یک متغیر وابسته می‌باشد. این روش نسبت به روش تجربی دقیق‌تر و به صرفه‌تر است اما باز هم دقیق نیست. اما امروزه روش‌های هوش محاسباتی برای مطالعه‌ی مخزن، به موضوع داغی در ژئومکانیک نفت تبدیل شده است. به علت اینکه در ژئومکانیک نفت بیشتر مدل‌های مطالعاتی غیرخطی هستند، لذا از سیستم‌های هوشمند جهت ارزیابی پارامترهای مختلف استفاده می‌شود. سیستم‌های هوشمند برخلاف دو روش دیگر، نیازی به مشخص کردن روابط ساختاری بین داده‌های ورودی و خروجی وجود ندارند و از دو روش فوق کاربردی‌تر و به صرفه‌تر است. امروزه سیستم‌های هوشمند در بدست آوردن ویژگی‌های سنگ مخزن از طریق نمودارهای چاه‌نگاری کاربرد فراوانی پیدا کرده است که به مهم‌ترین آنها اشاره می‌شود:


بازیار و همکاران (Baziar, Tadayoni et al., 2014) با استفاده از سه روش هوش محاسباتی شامل: سیستم استنتاجی نروفازی، ماشین بردار پشتیبان و شبکه عصبی پرسپترون چندلایه مقدار نفوذپذیری در یک مخزن متراکم گازی در حوضه واشاکا آمریکا را تخمین زدند. نوری طالقانی و همکاران (Nouri Taleghani, Saffarzadeh et al., 2013) از روش‌های هوشمند منطق فازی، شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی لاگ‌های پتروفیزیکی در میدان نفتی جنوب غربی ایران استفاده کردند. زوبدوایان‌پور و همکاران (Zoveidavianpoor, Samsuri et al., 2013) با استفاده از سیستم استنتاجی نروفازی تطبیقی و رگرسیون خطی چندگانه سرعت موج فشاری را از نگارهای چاه‌پیمایی در یک مخزن هیدروکربوری پیش‌بینی کردند. آسوده و باقری‌پور (Asoodeh and Bagheripour 2012) از روش‌های هوشمند با ایجاد رابطه‌ی کمی بین نگارهای چاه‌پیمایی و سرعت امواج صوتی برای پیش‌بینی سرعت امواج فشاری، برشی و استونلی بر روی سازند آسماری استفاده کردند. کدخدایی و همکاران (Kadkhodaie-Ilkhchi, Rezaee et al., 2009) نیز مقدار تخلخل در یک مخزن ماسه سنگی را با استفاده از سایر روش‌های هوشمند پیش‌بینی نمودند. معتمدیان و همکاران (Moatazedian, Rahimpour-Bonab et al., 2011) با استفاده از روش الگوریتم ژنتیک سرعت موج برشی و فشاری را در یک مخزن کربناته واقع در میدان ابودر و هندیشان پیش‌بینی و با مقادیر واقعی مقایسه کردند. غلامی و مرادزاده (Gholami and Moradzadeh 2012) از رگرسیون بردار پشتیبان برای پیش‌بینی نفوذپذیری استفاده کردند. آنیفوز و عبدالرحیم (Anifowose and Abdurraheem 2011) با استفاده از روش‌های هوشمند منطق فازی و ماشین بردار پشتیبان مقدار تخلخل و نفوذپذیری را پیش‌بینی نمودند. نظری و همکاران (Nazari, Kuzma et al., 2011) از رگرسیون برداری پشتیبان برای به دست آوردن نفوذپذیری از روی داده نگارهای چاه و اندازه‌گیری‌های مغزه استفاده نمودند. کدخدائی ایلخچی و همکاران (Kadkhodaie Ilkhchi, Rezaee et al., 2006) از تکنیک منطق فازی به ارزیابی نفوذپذیری و از نسبت سرعت موج فشاری به موج برشی برای تعیین نوع گروه‌های سنگی مخزن هیدروکربوری واقع در سازند کنگان سواحل جنوب غربی ایران استفاده کردند. ال‌انازی و همکاران (Al-Anazi and Gates 2010) به پیش‌بینی تخلخل در یک مخزن ناهمگون با استفاده از رگرسیون برداری پشتیبان پرداختند و نتایج آن را با نتایج به دست آمده از روش‌های شبکه عصبی پرسپترون چندلایه، شبکه عصبی رگرسیون عمومی و شبکه عصبی تابع پایه‌ای شعاعی مقایسه کردند. رضایی و همکاران (Rezaee, Ilkhchi et al., 2007) از روش‌های منطق فازی، نروفازی و شبکه‌ی عصبی مصنوعی به عنوان ابزارهای هوشمند برای تعیین

می‌پردازد. نورون کوچک‌ترین واحد یک شبکه عصبی مصنوعی است (Mitchell, 1997). ساختار یک نورون مصنوعی در (شکل ۱) نشان داده شده است. از اجتماع چند نورون که به طور موازی عمل می‌کنند، یک لایه به وجود می‌آید. هر لایه وظیفه خاصی دارد و با ترکیب لایه‌ها، شبکه عصبی مصنوعی به وجود می‌آید. در حالت کلی در شبکه‌های عصبی مصنوعی سه نوع لایه نورونی وجود دارد که عبارتند از: یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی. هر دو لایه از یک شبکه، به وسیله وزن‌ها و در واقع اتصالات با هم ارتباط می‌یابند. وزن‌ها در ابتدا به صورت تصادفی مقداردهی می‌شوند و سپس در طول فرآیند یادگیری با کاهش میزان خطا، اصلاح و مقادیر نهایی آن‌ها تعیین می‌شود. هیچ قاعده مشخص و دقیقی برای انتخاب و تعیین تعداد نورون‌ها در لایه پنهان شبکه وجود ندارد؛ بلکه در این مورد به طور عمده یک رویکرد تجربی صرف اتخاذ می‌شود.

کرنباتی درآبادان جنوب غربی ایران (سازند سروک) را پیش‌بینی کردند. اما یکی از روش‌های هوش محاسباتی، شبکه عصبی مصنوعی می‌باشد که یک روش داده کاوی قوی است. هرچند این روش یک روش کارآمد برای مدل‌سازی پدیده‌های مختلف است ولی کاستی‌هایی هم دارد که برخی از کاربردهایش را محدود می‌کند. یکی از چالش‌های اصلی شبکه عصبی مصنوعی، نحوه به روز رسانی و بهینه‌سازی وزن‌های شبکه در هنگام آموزش است. در همین راستا، در تحقیق حاضر برای رفع این کاستی، از الگوریتم شبیه‌ساز تبرید (با الهام از فرآیند تبرید مواد) به عنوان استراتژی جستجو برای یافتن مقدار بهینه وزن‌ها و بایاس‌های شبکه استفاده شده است. ترکیب شبکه عصبی مصنوعی با الگوریتم شبیه‌ساز تبرید منجر به ایجاد مدلی می‌شود که می‌تواند مقدار تخلخل را در یک مخزن هیدروکربوری با دقت مطلوبی تخمین بزند.

مروری اجمالی بر روش‌های بکار گرفته شده در این تحقیق شبکه عصبی مصنوعی

شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده است و مانند مغز انسان به پردازش اطلاعات



شکل ۱- ساختار یک نورون مصنوعی (Dmuth and Beale 2000).

توابع تحریک در شبکه عصبی مصنوعی

عملیات اصلی یک شبکه عصبی مصنوعی مشتمل بر جمع ورودی‌های وزن‌دار شده و اعمال تابع تحریک به این مجموعه، برای تعیین خروجی شبکه است. برای نرون‌های ورودی، این تابع واحد بوده و خروجی نرون برابر با ورودی آن است. اگرچه انتخاب یکسان تابع تحریک تمام نرون‌های یک لایه الزامی نیست، ولیکن معمولاً تابع تحریک نرون‌های یک لایه یکسان انتخاب شده و در اکثر موارد از تابع تحریک غیرخطی استفاده می‌شود. با توجه به توانایی‌های محدود شبکه‌های تک لایه، برای اینکه حداکثر استفاده از شبکه‌های چندلایه انجام شود نیاز به تابع تحریک غیرخطی است. عبور اطلاعات از دو یا چندلایه که در آنها نرون‌ها با تابع تحریک خطی عمل می‌نمایند به همان نتیجه‌ای منتهی می‌شود که با یک شبکه یک‌لایه میسر است زیرا که ترکیب توابع خطی همواره تابع خطی است. در حقیقت در شبکه‌های عصبی مصنوعی، موج ورودی توسط تابع تحریک پردازش شده و موج خروجی را تولید می‌کند. در این زمینه توابع تحریک متعددی وجود دارند که در زیر به اختصار بیان می‌شوند (Wasserman 1989).

تابع تحریک پله‌ای بصورت زیر تعریف می‌شود:

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq 0 \\ -1 & \text{if } \text{net} < 0 \end{cases} \quad \text{رابطه ۱:}$$

مشاهده می‌شود که خروجی این تابع ۱ یا -۱ است.

تابع تحریک خطی که با رابطه زیر بیان می‌شود، معمولاً در لایه خروجی شبکه‌ها استفاده می‌شود:

رابطه ۲: $f(\text{net}) = \text{net}$

معمولاً از این تابع در شبکه عصبی مصنوعی انتشار برگشتی^۴ استفاده می‌شود. علت اصلی استفاده از این تابع تحریک ارتباط ساده بین مقدار تابع و مشتق تابع در هر نقطه دلخواه است که در آموزش شبکه عصبی مصنوعی برای به حداقل رساندن مقدار خطا بکار گرفته می‌شود. تابع تحریک سیگموئید دارای پاسخی در محدوده صفر تا یک و یا پاسخی در محدوده -۱ تا ۱ است. تابع تحریک سیگموئید در محدوده صفر تا یک با رابطه زیر بیان می‌شود که σ پارامتر ثابتی است که برای تغییر شیب منحنی بکار می‌رود.

$$f(x) = \frac{1}{1 + e^{-\sigma x}} \quad \text{رابطه ۳:}$$

همچنین تابع تحریک سیگموئید با پاسخ در محدوده -۱ تا ۱ با رابطه زیر بیان می‌شود.


$$f(x) = \frac{1 - e^{-\sigma x}}{1 + e^{-\sigma x}} \quad \text{رابطه ۴:}$$

این تابع تحریک به‌طور قابل ملاحظه‌ای به تابع هیپربولیک که ورودی به نرون را به محدوده‌ای بین ۱ تا -۱ نگاشت می‌کند نزدیک بوده و اغلب بجای آن در شبکه‌های عصبی مصنوعی بکار گرفته می‌شود.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad \text{رابطه ۵:}$$

بایاس و آستانه تحریک

در بسیاری از موارد کمال مطلوب این است که سلول‌های لایه‌های پنهان و خروجی، از طریق وزن‌هایی به یک سلول عصبی واحد که دارای ورودی نبوده ولیکن همیشه دارای خروجی است مربوط شوند. این عمل اثری شبیه تنظیم حد سلول عصبی پرسپترون را داشته و تابع تحریک را مطابق (شکل ۲) در



شکل ۲- تأثیر بایاس بر تابع تحریک سلول عصبی مصنوعی.

امتداد محور ورودی منتقل می‌نماید. با استفاده از بایاس سرعت و دقت آموزش شبکه افزایش می‌یابد. وزن‌های مربوط به سلول عصبی بایاس همانند سایر وزن‌های شبکه تربیت شده و مبدأ وزن به‌جای اینکه خروجی یک سلول عصبی مصنوعی در لایه قبلی باشد، همیشه +۱ است.

این صورت گفته می‌شود که هر نرون از لایه پنهان به نرون خروجی مرتبط شده‌است. ترتیب نرون‌ها در لایه‌ها و طریقه ارتباط در داخل لایه‌ها و بین لایه‌ها ساختار شبکه نامیده می‌شود. بسیاری از شبکه‌های عصبی مصنوعی دارای یک لایه ورودی بوده و پاسخ هر واحد برابر با ورودی اعمال شده از خارج شبکه است. شبکه‌های عصبی مصنوعی به‌صورت یک یا چند لایه گروه‌بندی می‌شوند. در نرون‌های لایه ورودی محاسبه‌ای انجام نمی‌گیرد، بنابراین این نرون‌ها به‌عنوان لایه محسوب نمی‌شود. معمولاً تعداد لایه‌های یک شبکه، برابر تعداد ارتباط‌های وزن‌دار بین شبکه‌ها است زیرا وزن‌ها حامل اطلاعات بسیار مهمی است. یکی از روش‌های تقسیم بندی انواع شبکه‌ها براساس تعداد لایه‌هاست که در ذیل به اختصار بیان می‌شود.

شبکه تک لایه

شبکه تک‌لایه شامل یک لایه با ارتباط‌های وزن‌دار است. اغلب نرون‌های لایه اول به صورت نرون‌های ورودی عمل کرده و علائمی را که از خارج شبکه دریافت می‌کنند به نرون‌های خروجی شبکه تحویل می‌دهند. در شبکه تک‌لایه نرون‌های لایه ورودی به‌طور کامل به واحدهای خروجی مرتبط می‌شوند، ولیکن ارتباطی بین نرون‌های لایه ورودی وجود نداشته و همچنین نرون‌های لایه خروجی به یکدیگر مرتبط نشده‌اند.

شبکه چند لایه

یک شبکه چندلایه شامل یک و یا بیش از یک لایه پنهان بین نرون‌های لایه ورودی و خروجی است. عموماً مجموعه‌ای از وزن‌ها بین دو لایه مجاور هم وجود دارد که شامل لایه ورودی، پنهان و یا خروجی است. اگرچه شبکه‌های چندلایه در مقایسه با شبکه‌های تک‌لایه قادر به حل مسائل پیچیده‌تری هستند اما آموزش اینگونه شبکه‌ها مشکل‌تر است، با آموزش چنین شبکه‌هایی مسائلی قابل حل است که با شبکه‌های تک‌لایه امکان‌پذیر نیست (Wasserman, 1989).

با توجه به اینکه مقادیر ورودی به گره‌های لایه ورودی، از طریق محاسبه تعیین نمی‌شوند، هیچ بایاسی به لایه ورودی اختصاص داده نمی‌شوند. به‌عبارت دیگر در شبکه‌های عصبی مصنوعی همواره یک دسته از مقادیر به لایه ورودی داده شده و از شبکه انتظار می‌رود که دسته نتایج را به ازای آنها تولید نماید. بنابراین مقادیر گره‌های لایه ورودی نمی‌توانند تحت تأثیر مقادیر بایاس قرار گیرند، زیرا توسط شبکه محاسبه نمی‌شوند. از آنجایی که ورودی‌ها مقادیر معینی هستند، هیچ بایاسی برای لایه ورودی در نظر گرفته نمی‌شود. افزایش بایاس موجب افزایش ورودی نرون می‌گردد. مثلاً در یک تابع تحریک پله‌ای چنانچه بایاس در نظر گرفته شود، پاسخ تابع تحریک به‌صورت زیر تبدیل می‌شود.

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq 0 \\ -1 & \text{if } \text{net} < 0 \end{cases}$$

رابطه ۶:

البته می‌توان بایاس را در نظر نگرفت و یک مقدار ثابت آستانه را همیشه در نرون در نظر گرفت، در این‌صورت پاسخ تابع تحریک به‌صورت زیر تبدیل می‌شود.

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq \theta \\ -1 & \text{if } \text{net} < \theta \end{cases}$$

رابطه ۷:

ساختار شبکه‌های عصبی مصنوعی

عموماً نرون‌های یک لایه به‌طور یکسان عمل می‌کنند. پارامتر اصلی در تعیین رفتار یک نرون، تابع تحریک مربوط به آن و رابط‌های وزن‌داری است که اطلاعات از طریق آنها دریافت و یا ارسال می‌شود. در هر لایه، نرون‌ها دارای تابع تحریک یکسان بوده و طریقه ارتباط آنها به سایر نرون با هم یکسان است. در شبکه‌های عصبی مصنوعی، نرون‌های یک لایه یا به‌طور کامل با یکدیگر مرتبط بوده و یا این ارتباط وجود ندارد. اگر هر نرون از یک لایه (مثلاً از نرون‌های لایه پنهان) به نرونی از لایه دیگر (مثلاً لایه خروجی) مرتبط باشد، در

آموزش شبکه عصبی مصنوعی

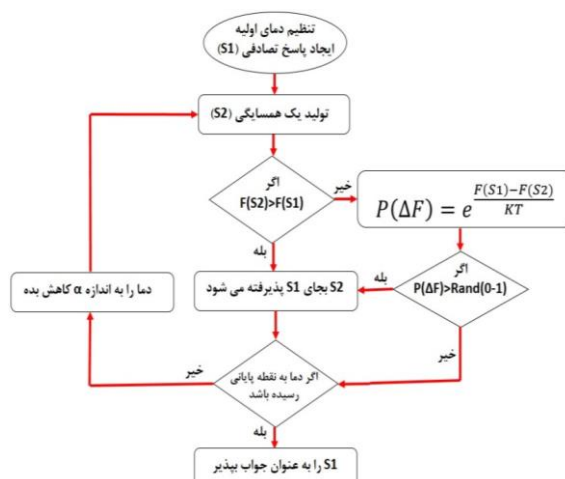
شبکه عصبی مصنوعی با استفاده از مجموعه داده‌های واقعی، الگوریتم‌های آموزشی را به کار می‌گیرد تا ارتباطات پنهانی میان داده‌های ورودی و خروجی را از طریق ضرایب وزنی، بایاس‌ها و توابع اعمالی به خروجی‌های هر لایه، ایجاد شود. الگوریتم‌های آموزشی متنوعی جهت آموزش شبکه عصبی مصنوعی به کار گرفته شده است. از مهمترین الگوریتم‌های آموزشی می‌توان از الگوریتم پس انتشار نام برد. اساس کار این الگوریتم حرکت بر روی بردار گرادینان تابع مربعات خطای شبکه می‌باشد که این بردار نیز به نوبه خود به وسیله مشتق‌گیری زنجیره‌ای از تابع خطا نسبت به تک‌تک پارامترهای شبکه به دست می‌آید. اگرچه امروزه استفاده از این روش برای آموزش شبکه عصبی مصنوعی رایج است اما الگوریتم‌های بهینه‌سازی مبتنی بر گرادینان و الگوریتم پس انتشار خطا، در سیستم‌های غیرخطی، مشکل افتادن در دام مینیمم محلی را دارند. از این رو استفاده از الگوریتم‌های تکاملی برای آموزش شبکه‌های عصبی مصنوعی مورد توجه محققان مختلف قرار گرفته است. در این تحقیق از الگوریتم شبیه‌ساز تبرید به عنوان یک جایگزین برای آموزش شبکه عصبی مصنوعی استفاده شده است، که در ادامه این الگوریتم شرح داده می‌شود.

الگوریتم شبیه‌ساز تبرید

تبرید در لغت به معنای باز پخت می‌باشد ولی در اصطلاح، یک فرایند فیزیکی برای بالا بردن دمای جسم تا رسیدن آن به نقطه ذوب و سپس سرد کردن آن طی شرایط مشخص می‌باشد که در طول این فرایند انرژی جسم به

حدافل می‌رسد. الگوریتم شبیه‌ساز تبرید اولین بار توسط کرکپاتریک و همکاران (Kirkpatrick, Gelatt et al., 1983) معرفی شد. الگوریتم شبیه‌ساز تبرید در واقع فرآیندی در مهندسی مواد است که برای استحکام بخشیدن به فلزات انجام می‌شود و هدف آن این است که ساختار بلوری جسم را با کمترین انرژی ممکن ایجاد کند. از لحاظ طبیعی اگر ماده‌ای ساختار مولکولی به گونه‌ای باشد که انرژی برای از دست دادن نداشته باشد یا این انرژی بسیار کم باشد، طبیعتاً جسم بسیار محکم خواهد بود. برای فرایند تبرید ماده (فلز) را ابتدا ذوب می‌کنند، این کار باعث می‌شود تا مولکول‌های ماده آزادانه هر ساختاری را می‌توانند داشته باشند و سپس دما بسیار آرام کاهش پیدا می‌کند به گونه‌ای که جسم در هر دمایی در حالت تعادل ترمودینامیکی قرار می‌گیرد. این کار تا زمانی انجام می‌شود که دیگر جسم ساختار مولکولی ثابتی به خود بگیرد و با کاهش دما ساختار مولکولی تغییر نکند (Rosen and Harmonosky, 2005).

فلوچارت این الگوریتم بصورت (شکل ۳) می‌باشد. همان طور که مشاهده می‌شود اساس این الگوریتم بر مبنای جستجوی محلی است. بنابراین طراحی روش‌های جستجوی محلی مناسب با توجه به شرایط و محدودیت‌های مسائل شبیه‌سازی شده در این الگوریتم، از اهمیت بسیار بالایی برخوردار است.



شکل ۳- فلوچارت الگوریتم شبیه‌ساز تبرید.

زیاد در صورتی که زمان کافی برای حل مساله موجود باشد، بهتر به نظر می‌رسد، با این حال باید دمای اولیه الگوریتم با توجه به بزرگی مساله تعیین شود.

در این الگوریتم همسایگی جواب‌ها بصورت معاوضه توالی دو فعالیت مجاور انجام می‌شود. به این صورت که هر یک از عناصر سطر اول جواب با یک احتمالی انتخاب شده و در صورت نداشتن رابطه پیشینازی با عنصر سمت راست آن، جابجا می‌شوند. با اعمال فرایندهای این الگوریتم بر پاسخ‌های موجود، پاسخ جدیدی در همسایگی آن به وجود می‌آید که بصورت کلی دو حالت دارد، یا این پاسخ جدید بهتر باشد حتماً آن پذیرفته می‌شود، اما اگر پاسخ جدید بدتر باشد بصورت مشروط و با یک احتمالی پذیرفته می‌شود. هر چقدر دما بالاتر باشد احتمال پذیرش پاسخ‌های بد نیز بالاتر می‌رود، و هر چه دما کاهش پیدا می‌کند در مقابل پذیرش پاسخ‌های بد مقاومت می‌شود و آزادی

ارتباط این فرایند با مسائل بهینه‌سازی در این است که در این مسائل ابتدا دامنه گسترده‌ای از جواب‌های اولیه در اختیار قرار دارد ولی با استفاده از این فرایند و تعریف یک پارامتر مجازی (مانند دما) می‌توان دامنه جواب‌ها را کوچکتر کرد و در واقع در هر دما با کمتر کردن میزان تغییرات بهترین جواب ممکن در آن دما پیدا می‌شود. هر چه دما بیشتر باشد آزادی عمل بیشتر خواهد بود و تغییرات بنیادی در جواب‌ها رخ خواهد داد. همچنین در دمای بالا احتمال پذیرش جواب‌های بد بیشتر خواهد بود، با کاهش دما دامنه این تغییرات کاهش پیدا می‌کند و احتمال پذیرش جواب‌های بد نیز کاهش پیدا می‌کند. سپس به نقطه‌ای می‌رسد که دیگر پاسخ‌ها تغییراتی ندارند. در این الگوریتم انتخاب دمای اولیه مناسب نقش بسیار مهمی در موفقیت الگوریتم دارد. انتخاب دمای اولیه بسیار بزرگ موجب کندی الگوریتم و از طرفی دمای اولیه کم موجب قرارگیری در نقاط بهینه محلی می‌شود. استفاده از دمای اولیه

پیش‌بینی تخلخل با استفاده از شبکه عصبی مصنوعی بهینه شده با الگوریتم شبیه‌ساز تبرید

میدان مورد مطالعه

میدان نفتی مارون، دومین میدان بزرگ نفتی ایران و یکی از بزرگ‌ترین میدان‌های نفتی جهان به شمار می‌آید. این میدان در جنوب فروافتادگی دزفول شمالی و در بخش میانی این زون ساختاری در امتداد طاق‌دیس‌های آغاچاری و رامین قرار گرفته است. این میدان بزرگ نفتی در سال ۱۳۴۲ خورشیدی به روش لرزه‌نگاری دوبعدی کشف شد و با حفر اولین چاه، وجود هیدروکربور در مخزن آسماری آن تأیید شد. این میدان در مخزن آسماری دارای طول ۶۷ کیلومتر و عرض متوسط ۵/۵ کیلومتر می‌باشد که بیشترین و کمترین عرض آن به ترتیب ۷ و ۳/۵ کیلومتر می‌باشد. از لحاظ موقعیت جغرافیایی، این میدان نسبت به میدان‌های مجاور از شمال توسط میدان رامین، از شرق توسط میدان کوپال، از غرب و شمال غرب توسط میدان‌های شادگان و اهواز و از جنوب توسط میدان رامشیر محدود می‌شود (Gorjian, Memarian et al., 2012). رخنمون سطحی این میدان، سازند آغاچاری بوده و سازندهای آسماری و گروه‌های بنگستان و خامی، مخازن نفتی موجود در این میدان هستند. میدان مارون دارای ساختمانی طاق‌دیس است که با جهت شمال غرب - جنوب شرق به‌خصوص در قسمت‌های غربی و مرکزی مشخص می‌شود. شواهد سطحی زیادی از طاق‌دیس مارون وجود ندارد و لذا تعیین دقیق سازوکار چین‌خوردگی بدون داده‌های لرزه‌ای سه‌بعدی بسیار مشکل است. تنها شواهد سطحی این طاق‌دیس لایه‌هایی از سازند آغاچاری می‌باشند که رخنمون یافته‌اند. (شکل ۴) تصویری هوایی از موقعیت دو طاق‌دیس مارون و آغاچاری و عوارض ناشی از برون‌زدگی آن‌ها را نشان می‌دهد. این میدان یک طاق‌دیس تقریباً نامتقارن است که دارای شیب متوسط ۶۰-۴۵ درجه در یال جنوب غربی و ۲۵ الی ۴۵ درجه در یال شمال شرقی است. همچنین دارای پیچشی در وسط ساختار است که طی آن روند میدان تقریباً ۲۰ درجه از جهت N۴۵W در شمال غرب به سمت N۶۵W در جنوب غرب تغییر می‌کند (Rolf, Mohammed et al., 2006). در میدان مارون به دلیل وقوع دو رخداد مهم تکتونیکی به‌صورت چین‌خوردگی که آثار اصلی کوهزایی زاگرس است و خمش که بعدها در اثر حرکت تحت تأثیر نیروهای تراکمی ایجاد شده و ادامه آن تا به امروز تغییر شیب را در یال‌های این مخزن بسیار متنوع نموده، در نتیجه میزان شعاع انحنا در طول ساختمان در مقاطع مختلف با هم متفاوت گردیده است. در این مقاله جهت مدلسازی از نگارهای چاه‌نگاری بدست آمده از این میدان استفاده می‌شود.

عمل و ریسک‌پذیری اولیه دیگر وجود نخواهد داشت. احتمال پذیرش جواب از رابطه زیر به کمک مقدار تابع هدف در نقاط مختلف به دست می‌آید: اختلاف تابع هدف در نقاط همسایه:

$$\Delta f = f(x^{new}) - f(x) \quad \text{رابطه ۸:}$$

در این رابطه اگر $\Delta f > 0$ باشد به معنی این است که نقطه جدید بدتر از نقطه قبلی است و احتمال پذیرش جواب از رابطه زیر به دست می‌آید، در غیر این صورت پاسخ جدید پذیرفته می‌شود.

$$P = e^{-\frac{\Delta f}{T}} \quad \text{احتمال پذیرش پاسخ جدید:}$$

در این رابطه مقدار T هرچقدر کمتر باشد احتمال پذیرش پاسخ جدید به سمت صفر میل می‌کند و هر چه هم دما بیشتر باشد احتمال پذیرش به سمت یک میل می‌کند، یعنی هر جوابی را می‌پذیرد.

در مورد Δf هر چه مقدار آن بیشتر باشد یعنی هرچه پاسخ جدید بدتر باشد، احتمال پذیرش آن کمتر می‌شود. اگر هم Δf صفر شود احتمال پذیرش یک می‌شود که به این معناست که پاسخ جدید صد در صد پذیرفته می‌شود (Park, Jeon et al. 2001).

در حالت کلی برای این فرآیند بر طبق توابع هدف نقاط، تغییرات لازم اعمال می‌شوند:

- ۱- اگر $\Delta f \leq 0$ باشد، آنگاه x^{new} جایگزین x می‌شود.
- ۲- اگر $\Delta f > 0$ باشد، آنگاه x^{new} با احتمال P جایگزین x می‌شود. این فرآیند در هر دما تکرار می‌شود به این گونه که در یک دما بارها جواب‌ها در همسایگی یکدیگر تشکیل می‌شوند و سپس با احتمالات مربوطه پذیرفته می‌شوند و سپس کمی دما کاهش پیدا می‌کند و دوباره این چرخه ادامه پیدا می‌کند. پس از طی مراحل فوق، دما کاهش می‌یابد و همین روند دوباره طی می‌شود تا زمانی که به دمای نهایی برسد. این الگوریتم برخلاف دیگر الگوریتم‌ها ریسک‌پذیر است یعنی پاسخ‌های بد نیز با یک احتمالی قابل پذیرش هستند. لذا روند کار این الگوریتم بصورت جمع‌بندی شده بصورت زیر خواهد بود:

- ۱- تولید پاسخ اولیه بصورت تصادفی و ارزیابی آن
- ۲- در نظر گرفتن پاسخ اولیه به عنوان بهترین پاسخ
- ۳- تنظیم دمای اولیه (T_0)
- ۴- تولید یک پاسخ تصادفی در همسایگی پاسخ فعلی
- ۵- پذیرش پاسخ جدید در صورتی که بهتر باشد
- ۶- پذیرش احتمالی پاسخ در صورتی که پاسخ جدید بدتر باشد
- ۷- به روزرسانی بهترین پاسخ یافته شده
- ۸- تکرار مراحل ۴ تا ۷
- ۹- کاهش دما و بازگشت به مرحله ۴ (در صورت نیاز)



شکل ۴- تصویر هوایی از برون‌زد دو طاق‌دیس مارون و آغاچاری.

صوتی بعنوان ورودی و تخلخل (گرفته شده از آنالیز مغزه) بعنوان خروجی مدل استفاده شده است. در این تحقیق تعداد کل داده‌ها ۱۳۵۶ داده می‌باشد که از این تعداد به طور تصادفی، ۸۰ درصد داده‌ها برای آموزش مدل و ۲۰ درصد داده‌ها برای آزمون آن استفاده شده است. نمونه‌ای از داده‌های استفاده شده برای مدل‌سازی در (جدول ۱) آورده شده است.

ساختار داده‌ها (ورودی‌ها و خروجی) برای مدل‌سازی

جهت ارائه راهکار جدید برای تخمین غیرمستقیم تخلخل در یکی از مخازن هیدروکربوری جنوب غربی ایران (میدان مارون) و اثبات توانایی روش ترکیبی مدل شبکه عصبی مصنوعی بهینه شده با الگوریتم شبیه‌ساز تبرید، از نگارهای وزن مخصوص، تخلخل نوترون، نمودار الکترومغناطیسی، پرتوگاما و نمودار

جدول ۱- نمونه‌ای از داده‌های استفاده شده برای مدل‌سازی

شماره داده	پارامترهای ورودی					پارامتر خروجی
	وزن مخصوص (gr/cc)	تخلخل نوترون (v/v)	لاگ الکترومغناطیسی (ohm.m)	اشعه گاما (API)	لاگ صوتی (μs/ft)	
۱	۲/۵۶۵۷	۰/۱۰۰۶	۲۶/۳۵۰۰۹	۵۱/۲۴۹۷	۶۷/۶۴۳۴	۰/۱۰۹۳
۲	۲/۵۶۵۷	۰/۰۸۸۱۲	۲۷/۱۷۵۴	۵۲/۴۴۱۹	۶۷/۶۸۶۷	۰/۰۸۲۵
۳	۲/۵۹۱۶	۰/۰۷۵۳۱	۲۵/۷۳۶۹	۵۲/۷۴۴۱	۶۸/۶۲۷۱	۰/۰۸۶۶
۴	۲/۶۰۴۸	۰/۰۶۳۱۴	۲۴/۱۴۳۷	۵۱/۶۳۶۳	۶۶/۳۸۸۱	۰/۱۰۶۸
۵	۲/۶۱۴۰۷	۰/۰۵۳۷۲	۲۳/۳۱۳۳	۴۸/۲۹۷۸	۶۲/۹۵۷۱	۰/۰۴۹۲

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2$$

رابطه ۱۱:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}$$

رابطه ۱۲:

که در این روابط y_i مقدار اندازه‌گیری شده و y'_i مقدار تخمین زده شده می‌باشد. لازم به توضیح است که معیار میانگین مربعات خطا (MSE) و مجذور میانگین مربعات خطا (RMSE) بیانگر خطای بین مقادیر اندازه‌گیری شده و تخمین زده شده می‌باشد و هر چه مقدار آن کم‌تر باشد عملکرد مدل از قابلیت بالاتری برخوردار است.

نتایج حاصل از مدل‌سازی شبکه عصبی مصنوعی بهینه شده با

الگوریتم شبیه‌ساز تبرید

در این تحقیق برای به روزرسانی و بهینه‌سازی وزن‌های شبکه در هنگام آموزش، از الگوریتم بهینه‌سازی شبیه‌ساز تبرید استفاده شده است. فلوچارت این مدل ترکیبی در شکل ۵ نشان داده شده است.

پیش پردازش داده‌ها و شاخص‌های آماری جهت ارزیابی عملکرد

مدل

برای مدل‌سازی و ورود داده‌ها، اکثراً لازم است که دامنه تغییرات داده‌ها مشابه یکدیگر باشند که در اصطلاح این عمل را، نرمال‌سازی داده‌ها می‌نامند. نرمال‌سازی داده‌ها در این مطالعه توسط رابطه زیر انجام گرفته است که این رابطه دامنه داده‌ها را در بازه [۰ ۱] قرار می‌دهد.

$$p_n = \frac{p - p_{\min}}{p_{\max} - p_{\min}}$$

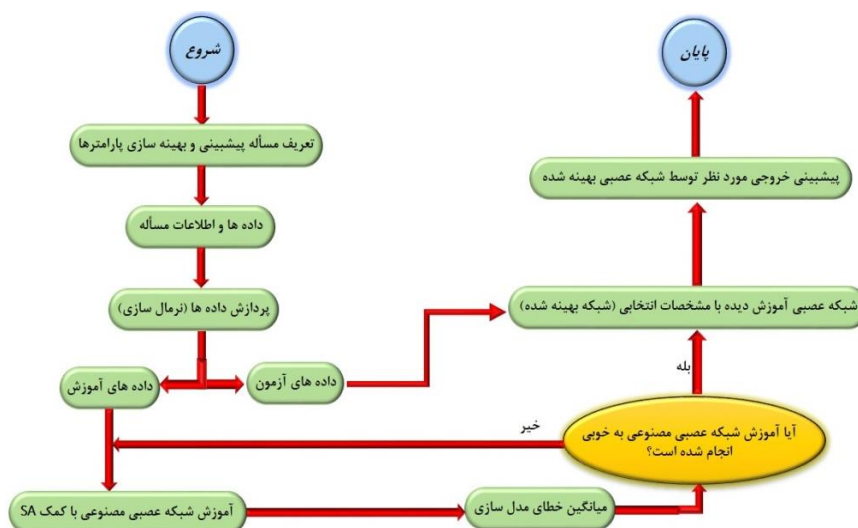
رابطه ۹:

که در آن: p_n داده نرمال شده، p داده حقیقی، p_{\min} کمینه داده حقیقی و p_{\max} بیشینه داده حقیقی هستند.

هم‌چنین در این تحقیق برای ارزیابی عملکرد مدل، از سه شاخص آماری استفاده شده است که روابط مربوطه به شرح ذیل می‌باشند:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n}}$$

رابطه ۱۰:




شکل ۵ - فلوچارت شبکه عصبی مصنوعی بهینه‌شده توسط الگوریتم شبیه‌ساز تبرید.

در محدوده مورد مطالعه تخمین زده شده. همچنین (شکل‌های ۶ و ۷) همبستگی بین مقادیر اندازه‌گیری شده و تخمین زده شده در مجموعه داده‌های آموزش و آزمون را نشان می‌دهند. بعلاوه مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی شیب‌ساز تیرید در مراحل آموزش و آزمون در (شکل‌های ۸ و ۹) نشان داده شده است.


در این تحقیق به کمک سعی و خطا، برای انجام بهترین مدل‌سازی، آنالیز حساسیت روی پارامترهای مدل از جمله تابع فعال‌سازی و ساختار مدل (تعداد لایه‌های پنهان و تعداد نورون‌های هر لایه) در شبکه عصبی مصنوعی انجام شده است که بخشی از آنالیز حساسیت مدل ترکیبی در (جدول ۲) نشان داده شده است. همانطور که (جدول ۲) نشان می‌دهد با انجام آنالیز حساسیت، ساختار بهینه مدل مشخص و با استفاده از آن، می‌توان تداخل را بصورت غیرمستقیم

جدول ۲- بخشی از آنالیز حساسیت مدل ترکیبی شبکه عصبی مصنوعی بهینه شده با الگوریتم شیب‌ساز تیرید.


ساختار مدل	توابع فعال‌سازی	MSE (آزمون)	MSE (آموزش)	RMSE (آزمون)	RMSE (آموزش)
۹-۱	logsig-tansig	۰/۰۶۱۶۲	۰/۰۶۲۲۷	۰/۲۴۸۲	۰/۲۴۹۵
۵-۱۰-۱	logsig-tansig-logsig	۰/۰۵۴۶۱	۰/۰۶۲۳۶	۰/۲۵۵۱	۰/۲۵۵۱
۷-۷-۱	logsig-logsig-tansig	۰/۰۱۵۶۴	۰/۰۱۵۵۹	۰/۲۴۸۶	۰/۲۵۰۸
۷-۱	logsig-tansig	۰/۰۱۶۴۵	۰/۰۱۵۹۳	۰/۲۴۸۲	۰/۲۴۹۵
۸-۱	logsig-logsig	۰/۰۱۶۶۲	۰/۰۱۵۴۴	۰/۲۵۸۲	۰/۲۴۶۷
۷-۹-۱	logsig-tansig-tansig	۰/۰۱۶۶۱	۰/۰۱۴۸۲	۰/۲۳۳۷	۰/۲۴۹۷
۱۰-۱۰-۱	logsig-logsig-tansig	۰/۰۱۴۹۴	۰/۰۱۴۳	۰/۱۲۲۲	۰/۱۱۹۶




شکل ۶- همبستگی بین مقادیر اندازه‌گیری و تخمین زده شده تخلخل در مجموعه داده‌های آموزش.



شکل ۷- همبستگی بین مقادیر اندازه‌گیری شده و تخمین زده شده در مجموعه داده‌های آزمون.



شکل ۸- مقایسه بین مقادیر اندازه‌گیری و پیش‌بینی شده برای مجموعه داده‌های آموزش.



شکل ۹- مقایسه بین مقادیر اندازه‌گیری و پیش‌بینی شده برای مجموعه داده‌های آزمون.

مدل‌سازی ایفا می‌نماید. مقادیر پارامترهای استفاده شده برای الگوریتم بهینه‌سازی شبیه‌ساز تبرید در (جدول ۳) آورده شده است. نتایج حاکی از آن است که این مدل قابلیت بالایی در برآورد تخلخل با استفاده از مجموعه پارامترهای ورودی ذکر شده را دارد و می‌تواند برای پروژه‌های دیگر با شرایط مشابه، به طور مطلوبی مورد استفاده قرار گیرد.

لازم به ذکر است پارامترهای الگوریتم شبیه‌ساز تبرید شامل دمای اولیه (T_0)، نرخ کاهش دما (α)، تعداد همسایگی و تعداد حلقه‌های بیرونی و درونی الگوریتم است که مجهول می‌باشند و باید به صورت دستی و با سعی و خطای فراوان تنظیم شوند که این فرآیند بسیار زمان‌بر است. همچنین مقدار خطای مدل‌سازی به کم یا زیاد شدن این پارامترها بسیار حساس است. به همین خاطر انتخاب درست پارامترهای مذکور نقش برجسته و مهمی را در عملکرد مطمئن

جدول ۳- مقادیر پارامترهای الگوریتم بهینه‌سازی شبیه‌ساز تبرید.

پارامتر	مقدار
تعداد تکرار حلقه اصلی	MaxIt
تعداد تکرار حلقه داخلی	MaxSubIt
دمای اولیه	T0
نرخ کاهش دما	Alpha
اندازه جمعیت	nPop
تعداد همسایگی	nMove
تعداد تکرار حلقه اصلی	MaxIt

بحث و نتیجه گیری

در این مقاله از الگوریتم شبیه‌ساز تبرید برای آموزش شبکه عصبی مصنوعی استفاده شد. اگرچه امروزه برای آموزش شبکه عصبی مصنوعی از روش‌های رایج مانند الگوریتم‌های بهینه‌سازی مبتنی بر گرادینان و الگوریتم پس انتشار خطا استفاده می‌کنند اما در سیستم‌های غیرخطی، احتمال افتادن در دام مینیمم محلی زیاد وجود دارد. از این رو استفاده از الگوریتم شبیه‌ساز تبرید برای آموزش شبکه عصبی مصنوعی در این تحقیق این مشکل را حل کرده است.

در این مقاله از نگاره‌های چاه‌نگاری وزن مخصوص، تخلخل نوترون، نمودار الکترومغناطیسی، پرتوگاما و نمودار صوتی بعنوان ورودی و تخلخل (گرفته شده از آنالیز مغزه) بعنوان خروجی مدل استفاده شد و از سه معیار ضریب همبستگی، میانگین خطای مربعات و مجذور میانگین خطای مربعات برای مقایسه و رسیدن به جواب بهتر استفاده شد. آنالیز خطاها نشان داد روش ترکیبی پیشنهادشده دقت و قابلیت بالایی در تخمین تخلخل مخزن هیدروکربوری مدنظر را دارد.

تشکر و قدردانی

نویسندگان این مقاله از پرسنل محترم شرکت ملی مناطق نفت‌خیز جنوب (اداره زمین‌شناسی) بخاطر همکاری صمیمانه‌ای که داشتند، کمال تشکر و قدردانی را دارند.

تخلخل یکی از پارامترهای مهم و اساسی در ارزیابی خصوصیات پتروفیزیکی مخازن هیدروکربوری محسوب می‌شود. امروزه در صنعت نفت این پارامتر با استفاده از روش تزریق گاز هلیوم بر نمونه‌های مغزه (پلاگ) به دست می‌آید. با این وجود مغزه گیری عملی دشوار و پرهزینه است. بعلاوه امکان مغزه گیری در برخی چاه‌ها (مانند چاههای افقی) وجود ندارد. بعلاوه تاکنون روابط تجربی فراوانی در مورد محاسبه تخلخل ارائه شده است اما در بیشتر موارد، نتایج به دست آمده از این روابط در مناطق مختلف مطلوب نیست. یک روش جایگزین، استفاده از روش‌های هوشمند می‌باشد. در این پژوهش از روش هوشمند ترکیبی شبکه عصبی مصنوعی با الگوریتم شبیه‌ساز تبرید برای تخمین تخلخل مخزن هیدروکربوری استفاده شد.

در این مقاله برای مدل‌سازی در ابتدا بانک اطلاعاتی مجموعه داده‌های تصحیح شده که شامل ۱۳۵۶ داده اطلاعات از میدان نفتی مارون بودند به طور تصادفی در دو بخش داده‌های آموزش (۸۰ درصد کل داده‌ها) و داده‌های آزمون (۲۰ درصد کل داده‌ها) تقسیم شدند. برای تخمین تخلخل از نرم‌افزار متلب برای این مدل‌سازی استفاده شد. داده‌های ورودی و خروجی (داده‌های مدل) در نرم‌افزار متلب فراخوانی شدند سپس تمامی حالات و مقادیر ممکن و قابل آزمایش (نسبت‌های مختلف داده‌های آموزش و آزمون) مورد بررسی و تحلیل قرار گرفت.

منابع

- Ahmadi, M.-A., Ahmadi, M. R., Hosseini, S. M., Ebadi, M. 2014, Connectionist model predicts the porosity and permeability of petroleum reservoirs by means of petro-physical logs: Application of artificial intelligence, *Journal of Petroleum Science and Engineering*, Vol. 123, p. 183-200.
- Ahmadi, M. A., Ebadi, M., Marghmaleki, P. S., Fouladi, M. M. 2014, Evolving predictive model to determine condensate-to-gas ratio in retrograded condensate gas reservoirs, *Fuel*, Vol. 124, p. 241-257.
- Al-Anazi, A., Gates, I. 2010, Support vector regression for porosity prediction in a heterogeneous reservoir: A comparative study, *Computers and geosciences*, Vol. 36, p. 1494-1503.
- Anifowose, F., Abdulraheem, A. 2011, Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization, *Journal of Natural Gas Science and Engineering*, Vol. 3, p. 505-517.
- Anifowose, F., Labadin, J., Abdulraheem, A. 2015, Improving the prediction of petroleum reservoir characterization with a stacked generalization ensemble model of support vector machines, *Applied Soft Computing*, Vol. 26, p. 483-496.
- Anifowose, F. A., Labadin, J., Abdulraheem, A. 2013, Prediction of petroleum reservoir properties using different versions of adaptive neuro-fuzzy inference system hybrid models, *Int. J. Comput. Inf. Syst. Ind. Manage. Appl*, Vol. 5, p. 413-426.
- Ansari, H. R., Gholami, A. 2015, An improved support vector regression model for estimation of saturation pressure of crude oils, *Fluid Phase Equilibria*, Vol. 402, p. 124-132.
- Asoodeh, M., Bagheripour, P. 2012, Prediction of compressional, shear, and stoneley wave velocities from conventional well log data using a committee machine with intelligent systems, *Rock Mechanics and Rock Engineering*, Vol. 45, p. 45-63.
- Bagheripour, P., Gholami, A., Asoodeh, M., Vaezzadeh-Asadi, M. 2015, Support vector regression based determination of shear wave velocity, *Journal of Petroleum Science and Engineering*, Vol. 125, p. 95-99.
- Baziar, S., Gafoori, M. M., Pour, M., Mehdi, S., Bidhendi, M. N., Hajiani, R. 2015, Toward a Thorough Approach to Predicting Klinkenberg Permeability in a Tight Gas Reservoir: A Comparative Study, *Iranian Journal of Oil & Gas Science and Technology*, Vol. 4, p. 18-36.
- Baziar, S., Tadayoni, M., Nabi-Bidhendi, M., Khalili, M. 2014, Prediction of permeability in a tight gas reservoir by using three soft computing approaches: A comparative study, *Journal of Natural Gas Science and Engineering*, Vol. 21, p. 718-724.
- Boadu, F. K. 2001, Predicting oil saturation from velocities using petrophysical models and artificial neural networks, *Journal of Petroleum Science and Engineering*, Vol. 30, p. 143-154.
- Dmuth, H., Beale, M. 2000, *Neural Network Toolbox for use with Matlab, User's Guide*, Natick, MA, p.
- Eskandari, H., Rezaee, M., Mohammadnia, M. 2004, Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir South-West Iran, *CSEG recorder*, Vol. 42, p. 48.
- Gholami, R., Moradzadeh, A. 2012, Support vector regression for prediction of gas reservoirs permeability, *Journal of Mining and Environment*, Vol. 2, p. 41-52.

- Gorjian, M., Memarian, H., Moosavi, M., Mehrgini, B. 2012, Dynamic properties of anhydrites, marls and salts of the Gachsaran evaporitic formation, Iran, *Journal of Geophysics and Engineering*, Vol. 10, p. 015001.
- Kadkhodaie-Ilkhchi, A., Rezaee, M. R., Rahimpour-Bonab, H., Chehrizi, A. 2009, Petrophysical data prediction from seismic attributes using committee fuzzy inference system, *Computers & Geosciences*, Vol. 35, p. 2314-2330.
- Kadkhodaie Ilkhchi, A., Rezaee, M., Moallemi, S. A. 2006, A fuzzy logic approach for estimation of permeability and rock type from conventional well log data: an example from the Kangan reservoir in the Iran Offshore Gas Field, *Journal of Geophysics and Engineering*, Vol. 3, p. 356-369.
- Kirkpatrick, S., Gelatt, C. D., Vecchi, M. P. 1983, Optimization by simulated annealing, *science*, Vol. 220, p. 671-680.
- Mitchell, T. M. (1997). *Machine learning*. WCB, McGraw-Hill Boston, MA.
- Moatazedian, I., Rahimpour-Bonab, H., Kadkhodaie-Ilkhchi, A., Rajoli, M. 2011, Prediction of shear and Compressional Wave Velocities from petrophysical data utilizing genetic algorithms technique: A case study in Hendijan and Abuzar fields located in Persian Gulf, *Geopersia*, Vol. 1, p. 1-17.
- Nazari, S., Kuzma, H. A., Rector III, J. W. (2011). Predicting permeability from well log data and core measurements using support vector machines. 2011 SEG Annual Meeting, Society of Exploration Geophysicists.
- Nouri Taleghani, M., Saffarzadeh, S., Karimi Khaledi, M., Zargar, G. 2013, Development of an Intelligent System to Synthesize Petrophysical Well Logs, *Iranian Journal of Oil & Gas Science and Technology*, Vol. 2, p. 11-24.
- Park, M. G., Jeon, J. H., Lee, M. C. (2001). Obstacle avoidance for mobile robots using artificial potential field approach with simulated annealing. *Industrial Electronics, 2001. Proceedings. ISIE 2001. IEEE International Symposium on, IEEE*.
- Rajabi, M., Bohloli, B., Ahangar, E. G. 2010, Intelligent approaches for prediction of compressional, shear and Stoneley wave velocities from conventional well log data: A case study from the Sarvak carbonate reservoir in the Abadan Plain (Southwestern Iran), *Computers & Geosciences*, Vol. 36, p. 647-664.
- Rezaee, M. R., Ilkhchi, A. K., Barabadi, A. 2007, Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia, *Journal of Petroleum Science and Engineering*, Vol. 55, p. 201-212.
- Rezaee, M. R., Kadkhodaie-Ilkhchi, A., Alizadeh, P. M. 2007, Intelligent approaches for the synthesis of petrophysical logs, *Journal of Geophysics and Engineering*, Vol. 5, p. 12.
- Rolf, B., Mohammed, W., Mohsen, P. 2006, A preliminary study of casing collapse in Iran Hydroquest Report, Schlumberger Oil Company, p.
- Rosen, S. L., Harmonosky, C. M. 2005, An improved simulated annealing simulation optimization method for discrete parameter stochastic systems, *Computers & Operations Research*, Vol. 32, p. 343-358.
- Sebtosheikh, M. A., Motafakkerfard, R., Riahi, M.-A., Moradi, S., Sabety, N. 2015, Support vector machine method, a new technique for lithology prediction in an Iranian heterogeneous carbonate reservoir using petrophysical well logs, *Carbonates and Evaporites*, Vol. 30, p. 59-68.
- Sebtosheikh, M. A., Motafakkerfard, R., Riahi, M. A., Moradi, S. 2015, Separating Well Log Data to Train Support Vector Machines for Lithology Prediction in a Heterogeneous Carbonate Reservoir, *Iranian Journal of Oil & Gas Science and Technology*, Vol. 4, p. 1-14.
- Wasserman, P. D. (1989). *Neural computing: theory and practice*. New York, Van Nostrand Reinhold.
- Yue, Y., Wang, J. 2007, SVM method for predicting the thickness of sandstone, *Applied Geophysics*, Vol. 4, p. 276-281.
- Zoveidavianpoor, M., Samsuri, A., Shadizadeh, S. R. 2013, Adaptive neuro fuzzy inference system for compressional wave velocity prediction in a carbonate reservoir, *Journal of Applied Geophysics*, Vol. 89, p. 96-107.