

ترکیب روش‌های عصبی، فازی و عصبی- فازی با استفاده از الگوریتم مورچگان پیوسته برای تشخیص رخساره‌های مخزن

رضا محبیان^۱، محمدعلی ریاحی^{۱*} و علی کدخدایی^۲

۱- موسسه ژئوفیزیک، دانشگاه تهران، ایران

۲- دانشکده علوم زمین، دانشگاه تبریز، ایران

تاریخ دریافت: ۹۶/۱/۲۰ تاریخ پذیرش: ۹۶/۷/۱۱

چکیده

تشخیص رخساره‌های مخزنی و تعیین نواحی با کیفیت مخزنی بالا نقش مهمی در مدل‌سازی مخزن و همچنین حفاری‌های آتی در میدان‌های در حال توسعه ایفا می‌کند. شاخص جریان‌ی یکی از شاخص‌هایی است که با توجه به تغییر خصوصیات مخزن تغییر کرده و می‌تواند نقش موثری در تقسیم‌بندی رخساره‌های مخزنی داشته باشد. مطالعه حاضر یک مدل بهینه‌یافته و پیشرفته را به‌وسیله ترکیب سیستم‌های هوشمند برای تخمین شاخص جریان‌ی در کل میدان پیشنهاد می‌دهد. این ماشین‌گروهی نتایج پیش‌بینی شده حاصل از سیستم‌های هوشمند عصبی، فازی و عصبی- فازی را با وزن‌های مشخص با هم ترکیب می‌کند، وزن‌های بهینه برای هر یک از این روش‌ها به‌وسیله الگوریتم مورچگان پیوسته تعیین می‌شود. در این مطالعه از داده‌های چاه و لرزه‌نگاری سه‌بعدی مربوط به یکی از میادین جنوب ایران برای اعمال روش‌ها استفاده شده است. در مرحله اول، نشانگرهای لرزه‌ای که ارتباط بیشتری با داده هدف (FZI) دارند با استفاده از برازش گام به گام انتخاب می‌شوند و در ادامه با استفاده از سیستم‌های هوشمند و ترکیب آن‌ها مکعب سه‌بعدی شاخص جریان‌ی در کل میدان تخمین زده می‌شود و در مرحله پایانی با استفاده از الگوریتم خوشه‌بندی C میانگین فازی (Fuzzy C-Mean) رخساره‌های مختلف مخزن از هم تفکیک داده می‌شوند. نتایج این مطالعه نشان‌دهنده کارایی بهتر ماشین‌گروهی با استفاده از الگوریتم مورچگان پیوسته (ACO_R) نسبت به هر یک از روش‌های منفرد می‌باشد.

کلمات کلیدی: رخساره‌های مخزنی، شاخص جریان‌ی، سیستم‌های عصبی- فازی، سیستم‌های عصبی، الگوریتم مورچگان پیوسته.

مقدمه

پارامترهای مخزن و نشان‌گرهای لرزه‌ای نقش مهم و تعیین‌کننده‌ای در توسعه میادین نفت و گاز ایفا می‌کند.

آنالیز رخساره‌های مخزن با استفاده از ارتباط بین

که از ماهیت داده‌ها استخراج می‌گردد و در مرحله پایانی این وزن‌ها (درجات عضویت) بر روی توابع خروجی اعمال شده و تجمیع می‌یابد. از محققینی که در این حیطة فعالیت کردند می‌توان دیاگو و همکاران را نام برد که برای تشخیص رخساره‌های مخزن از نمودارهای چاهی از قوانین فازی بهره گرفتند [۱۰]. علاوه بر این، روش عصبی- فازی که شکل بهبود یافته شده الگوریتم فازی می‌باشد یکی از الگوریتم‌های پیشرفته است که می‌تواند برای استخراج رخساره‌ها از آن بهره گرفته شود، در این الگوریتم پارامترهای سیستم فازی به وسیله شبکه عصبی بهینه خواهد شد. لازم به ذکر است که هر کدام از سیستم‌های مذکور دارای خصوصیات و مزایایی است که نمی‌توان به صورت کامل از آن غافل شد، از این رو در این تحقیق علاوه بر اجرای جداگانه هر یک از سیستم‌ها، کاربرد ترکیب این سیستم‌ها در تعیین رخساره‌های مخزن در ساختار یک ماشین گروهی مورد بررسی قرار خواهد گرفت. سیستم هوشمندی که برای ترکیب روش‌های مختلف در این تحقیق استفاده خواهد شد؛ از الگوریتم بهینه‌سازی کلونی مورچگان بهره خواهد برد، این الگوریتم در ابتدا برای فضای گسسته مورد استفاده قرار گرفت اما اخیرا با اعمال تغییراتی الگوریتم کلونی مورچگان برای فضای پیوسته^۱ ایجاد گردید که قدرت و کارایی خود را در این حوزه نسبت به الگوریتم‌های مشابه به اثبات رسانده است [۱۱]. از می‌توان به موارد زیر اشاره نمود:

- ۱- پارامترهای کمتر آن می‌باشد که همین امر باعث کاهش عدم قطعیت خواهد شد.
- ۲- کاهش زمان الگوریتم است، چون در الگوریتم‌های مشابه نیازمند دو یا چند نسل از کروموزوم‌ها هستند اما در ACO این مشکل وجود ندارد.

از این رو بررسی این موضوع از دیرباز مورد توجه محققین و مفسرین این حوزه قرار داشته است. از آن جمله می‌توان به موارد زیر اشاره نمود: کروالیور بخش‌های مختلف مخزن را با استفاده از تحلیل نشانگرهای لرزه‌ای در کنگلومرای کدو در میدان نفتی بونسیل به تصویر کشید [۱]. مایکلنا و همکاران از نقشه‌های شباهت که ورودی آن‌ها نشان‌گرهای لرزه‌ای بود برای بخش‌بندی مخزن بهره گرفتند [۲]. بارنز مجموعه‌ای از نشان‌گرهای لرزه‌ای از جمله فاصله، واریانس دامنه، واگرایی را بر اساس اصول الگوهای بازتابی چینه‌شناسی لرزه‌ای تلفیق نمود تا کلاس‌های رخساره لرزه‌ای را تولید نماید [۳]. وست و همکاران با به‌کارگیری نشانگرهای بافتی و شبکه عصبی، رخساره‌های لرزه‌ای را در محدوده مخزن تفکیک نمودند [۴]. نر و تری‌تال اطلاعات طیف دامنه لحظه‌ای به دست آمده از تحلیل‌های زیرباند لرزه‌ای را به عنوان ورودی نقشه‌های خودسازمانده کوهن جهت تولید نقشه سنگ‌شناسی لرزه‌ای و رخساره استفاده نمودند [۵]. فرزادی و هستامرتکنیک‌های تقسیم‌بندی سلسله مرتبه‌ای و تحلیل مولفه اصلی را برای تقسیم‌بندی نگاره‌های لرزه‌ای به رخساره‌های لرزه‌ای در مخزن میشریف واقع در جنوب خلیج فارس ترکیب کردند [۶]. بیسوال و همکاران از نشان‌گرهای بافتی برای شناسایی بالا آمدگی‌های کربناته در سواحل غربی هند بهره گرفتند [۷]. دزفولیان و همکاران از شبکه عصبی برای استخراج رخساره‌های مخزنی از نشان‌گرهای لرزه‌ای در میدان نفتی پارس جنوبی بهره گرفتند [۸]. همچنین یارمحمدی و کدخدایی رخساره‌های مخزنی مختلف را برای یک مخزن ماسه‌سنگی در محدوده میدان شاه دنیز به وسیله ارتباط بین داده لرزه‌ای و پارامترهای مخزنی استخراج کردند [۹]. در سال‌های اخیر استفاده از روش‌های فازی مورد توجه محققین قرار گرفته است، در روش فازی با استفاده از توابع عضویت و قوانین اگر- آنگاه برای هر یک از نشان‌گرها یک فاکتور وزن دهی محاسبه می‌شود

1. Ant Colony Optimization for Continuous Domains (ACO_c)

هوشمند شامل: سیستم‌های عصبی، فازی و عصبی- فازی بر روی این نشان‌گرها اعمال شده و شاخص جریان‌ی حاصل از آن‌ها برای کل میدان به‌دست می‌آید. در مرحله بعد، یک ماشین گروهی با استفاده از الگوریتم مورچگان پیوسته برای ترکیب نتایج حاصل از روش‌های پیشین ساخته می‌شود و در مرحله پایانی یک الگوریتم خوشه‌بندی C میانگین فازی بر روی خروجی حاصل از ماشین گروهی اعمال شده و رخساره‌های مختلف مخزن از هم تفکیک داده می‌شوند و در مرحله پایانی این نتایج با نتایج مقاطع نازک زمین‌شناسی مقایسه گردید.

روش شبکه عصبی^۲ (BP-NN)

یک شبکه عصبی پس انتشار خطا یک تکنیک آموزشی نظارت شده است. این الگوریتم داده‌های ورودی را درون شبکه رو به جلو فرستاده و اختلاف بین خروجی محاسبه شده و خروجی ایده آل را برای داده‌های آموزشی محاسبه می‌کند. در مرحله بعد خطا دوباره به عقب در داخل شبکه برگردانده شده و وزن‌های بهینه در طی مراحل تکرار تعیین می‌شوند و این مراحل تا زمان نزدیک شدن مقادیر خروجی محاسبه شده به مقادیر ایده‌آل ادامه می‌یابد [۱۲]. مراحل آموزش شبکه عصبی پس از انتشار خطا در شکل ۱ نشان داده شده است.

سیستم فازی

سیستم استنتاج فازی فرآیند فرموله کردن نگاشت یک ورودی داده شده به خروجی با استفاده از منطق فازی است. سپس این نگاشت پایه‌ای را فراهم می‌کند که بر مبنای آن تصمیمات گرفته شده یا الگوها تشخیص داده شوند.

۳- الگوریتم مورچگان نوعی جستجوی تصادفی بر مبنای جمعیت می‌باشد که اولین و مهم‌ترین نقطه قوت آن این است که ذاتاً موازی است، بررسی موازی زیرفضاها باعث می‌شود که جستجوی فضا به نواحی که متوسط آماری تابع هدف در آنها زیاد است و امکان وجود نقطه بهینه مطلق در آنها بیشتر است سوق پیدا کند، در این روش با توجه به اینکه فضای جواب به‌طور همه جانبه جستجو می‌شود، امکان کمتری برای گرفتار شدن در نقطه بهینه محلی وجود خواهد داشت.

۴- الگوریتم مورچگان قابلیت حافظه موثرتری نسبت به الگوریتم‌های مشابه دارد.

هدف از این تحقیق اجرای سیستم‌های عصبی، فازی و عصبی- فازی و ترکیب نتایج این سیستم‌ها با استفاده از الگوریتم تجمعی هوشمند (ACO_R) برای تحلیل رخساره‌های مخزن می‌باشد، برای این منظور الگوریتم‌های مذکور بر روی داده واقعی (یکی از میادین نفتی جنوب ایران) اعمال خواهد شد و نتایج به‌دست آمده با نتایج حاصل از چاه اعتبارسنجی می‌گردد، همچنین نتایج به‌دست آمده از ماشین گروهی با نتایج روش‌های منفرد مقایسه شده تا توانمندی این روش نسبت به روش‌های پیشین نشان داده شود. در مرحله پایانی و بعد از استخراج شاخص جریان‌ی^۱ (FZI) در کل میدان به‌وسیله ماشین گروهی، رخساره‌های مخزنی به‌وسیله الگوریتم خوشه‌بندی C میانگین فازی^۲ (Fuzzy C-Mean) از هم تمیز داده شده و نتایج حاصل با مقاطع نازک زمین‌شناسی مقایسه می‌گردد.

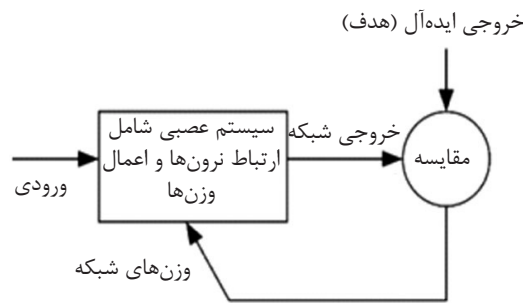
مواد و روش‌ها

متدولوژی پیشنهاد شده برای این تحقیق شامل ۳ قسمت اصلی می‌باشد. در مرحله اول، نشان‌گرهای لرزه‌ای بهینه‌ای که با داده هدف (FZI) حاصل از چاه رابطه قوی‌تری را دارند به‌وسیله برآزش گام به گام انتخاب می‌شوند. در مرحله دوم، روش‌های

1. Flow Zone Index

2. Fuzzy C-mean Clustering

3. Back-Propagation Neural Networks



شکل ۱ فلوجارت مراحل آموزش شبکه عصبی پس انتشار خطا (راهنمای متلب، ۲۰۰۴)

می‌کند، لایه سوم، لایه نرمال‌سازی می‌باشد سپس در لایه چهارم وزن‌های نرمال‌شده اعمال شده و در لایه پنجم با هم جمع می‌شوند، لایه‌های سوم، چهارم را جمع‌بندی^۲ و لایه پنجم را نافازی‌سازی^۳ می‌نامند.

ماشین گروهی و طراحی آن به‌وسیله سیستم‌های هوشمند

به‌طور کلی، یک ماشین گروهی^۵ (CMIS) شامل گروهی از سیستم‌های خبره است که خروجی‌های همه سیستم‌ها را باهم تلفیق می‌کند و بنابراین از مزایای تمام روش‌ها با مقداری محاسبه اضافی بهره می‌گیرد. روش‌های مختلفی برای ترکیب خروجی سیستم‌های هوشمند در ترکیب‌کننده وجود دارد. روش میانگین‌گیری کلی ساده، روش بسیار رایجی در این خصوص است [۱۷ و ۱۶]، ترکیب بهینه مشارکت (وزن)، علاوه بر این سیستم‌های هوشمند می‌تواند با الگوریتم ژنتیک نیز به‌دست آید [۱۹ و ۱۸]. رویکردی که در این مطالعه مورد استفاده قرار گرفته استفاده از الگوریتم‌های بهینه‌سازی هوش جمعی کلونی مورچه برای ترکیب روش‌های عصبی، فازی و عصبی-فازی در قالب یک ماشین گروهی هوشمند است. در زیر این الگوریتم شرح داده خواهد شد.


فرآیند استنتاج فازی شامل تمام مفاهیم استدلال فازی است: توابع عضویت، عمل‌گرهای منطقی و قوانین اگر-آنگاه. دو نوع سیستم استنتاج فازی وجود دارد که می‌توانند در منطق فازی اجراء شوند: نوع ممدانی [۱۳] و نوع سوگنو [۱۴]. یک سیستم فازی دارای اجزای زیر است:

- ۱- یک فازی‌ساز در ورودی که مقدار متغیرها را به یک مجموعه فازی تبدیل می‌کند.
 - ۲- پایگاه قواعد فازی که مجموعه‌ای از قواعد اگر-آنگاه است.
 - ۳- موتور استنتاج فازی که ورودی‌ها را با یک سری اعمال به خروجی تبدیل می‌کند.
 - ۴- دیفازی‌سازی که خروجی فازی را به یک عدد قطعی تبدیل می‌کند.
- شکل ۲ مراحل یک سیستم استنتاج فازی را نشان می‌دهد.

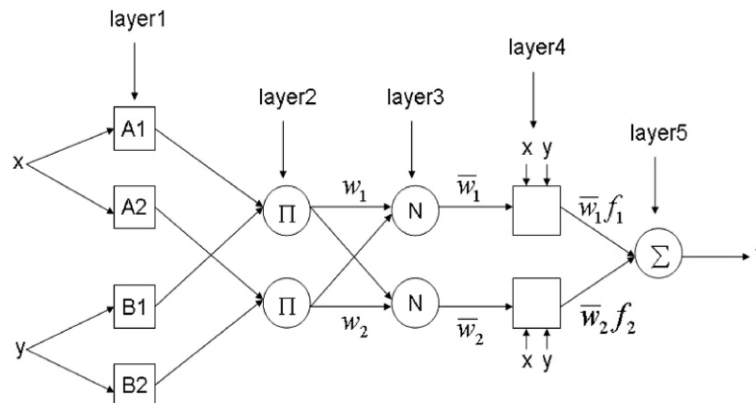
سیستم عصبی-فازی

سیستم‌های هیبرید عصبی-فازی مزایای سیستم‌های فازی و شبکه‌های عصبی را دارا می‌باشند. مدل‌سازی عصبی-فازی رفتار یک سیستم را با قوانین منطق فازی در داخل ساختار شبکه عصبی توصیف می‌کند [۱۵]. شکل ۳ ساختار شبکه عصبی-فازی را نشان می‌دهد. در شکل ۳، ۵ لایه مشاهده می‌شود، لایه اول، لایه فازی‌سازی^۱ که یک سیستم فازی را ایجاد می‌کند و با استفاده از توابع عضویت درجه عضویت هر یک از متغیرها را مشخص می‌کند، لایه دوم، لایه استنتاج‌کننده^۲ است که وزن‌های هر یک از توابع را استخراج

1. Fuzzification
2. Implication
3. Aggregation
4. Defuzzification
5. Committee Machine Inference System



شکل ۲ مراحل سیستم استنتاج فازی (فونگ، ۲۰۱۰)



شکل ۳ ساختار شبکه عصبی-فازی (Anfis)

فضا را که کاندید بهینه هستند نشان دهد، بنابراین نیازمند یک کرنل گاوسی است که مجموع وزن دار از چندین تابع گاوسی واحد g می‌باشد، رابطه ۱ این کرنل گاوسی را نشان می‌دهد.

$$G^i(x) = \sum_{l=1}^k \omega_l g_l^i(x) = \sum_{l=1}^k \omega_l \frac{1}{\sigma_l^i \sqrt{2\pi}} e^{-\frac{(x-\mu_l^i)^2}{2\sigma_l^i{}^2}} \quad (1)$$

در این رابطه w بردار وزن توابع گاوسی، μ بردار میانگین و σ واریانس تابع گاوسی i ام هستند. چنین تابع چگالی احتمالی ضمن این که امکان نمونه برداری ساده را فراهم می‌آورد، در مقایسه با یک تابع گاوسی واحد انعطاف پذیری بیشتری دارد. شکل ۴ یک نمونه تابع چگالی احتمال کرنل گاوسی را به همراه توابع گاوسی واحد نشان می‌دهد.

الگوریتم کلونی مورچه برای مسائل بهینه‌سازی پیوسته


الگوریتم مورچگان پیوسته^۱ یک الگوریتم بهینه‌سازی مبتنی بر کلونی مورچه است که توسط سوچا و دوریگنو پیشنهاد شده است. این الگوریتم سعی دارد متاهوریستیک الگوریتم مورچگان در فضای گسسته^۲ (ACO) را دنبال کند. ساختار آن به کاربر اجازه حل مسائل بهینه‌سازی ترکیبی (گسسته-پیوسته) را می‌دهد. قانون الگوریتم مورچگان پیوسته (ACO_R) در انتخاب مقادیر متغییر در فضای جستجو با توزیع احتمال پیوسته بیان می‌شود. ایده اصلی این الگوریتم استفاده از یک توزیع احتمال پیوسته با استفاده از یک تابع چگالی احتمال^۳ (PDF)، به جای استفاده از یک توزیع احتمال گسسته است. برای این منظور الگوریتم تابع گاوسی را به کار می‌گیرد. اما یک تابع گاوسی به تنهایی نمی‌تواند دو نقطه از

1. Ant Colony Optimization Routing Algorithm
 2. Ant colony Optimization
 3. Probabilistic Density Function

مخزن مورد مطالعه در این میدان سازند عرب (سرمه) می‌باشد. در مجموع ۴۰۰ نمونه داده مورد استفاده واقع شد که ۳۰۰ نمونه برای ساخت مدل و ۱۰۰ نمونه برای اعتبارسنجی آن به کار برده شد. همان‌طور که گفته شد در مرحله اول برای پیدا کردن مناسب‌ترین نشان‌گرها که بیشترین رابطه را با تابع هدف (شاخص جریان‌ی) دارد از الگوریتم برآزش گام به گام استفاده شد که نتایج این عملیات در جدول ۱ آورده شده است. همان‌طور که در جدول دیده می‌شود با اضافه کردن نشان‌گر ۴ خطای اعتبارسنجی شروع به بالا رفتن می‌کند و این نشان‌دهنده این مطلب است که نشان‌گرهای بهینه برای این عملیات نشان‌گرهای اکوستیک امیدانس (خروجی اینورژن)، انتگرال قدرمطلق دامنه و فرکانس میانگین می‌باشند. برای اجرای این عملیات از نرم‌افزار همسن راسل استفاده گردید. در مرحله بعدی، نشانگرهای انتخاب شده به‌عنوان داده ورودی به هر یک از شبکه‌های عصبی، فازی و عصبی-فازی داده شد و مدل سه‌بعدی شاخص جریان‌ی برای هر کدام از روش‌ها به‌صورت جداگانه حاصل گردید. (اعمال روش‌ها در این قسمت در محیط برنامه‌نویسی Matlab صورت پذیرفت.

ترکیب روش‌ها با استفاده از ماشین گروهی^۱ (الگوریتم مورچگان پیوسته)

در این قسمت از مطالعه، یک ماشین گروهی (CM) با استفاده از الگوریتم مورچگان پیوسته (ACO_R) برای ترکیب نتایج روش‌های عصبی، فازی و عصبی-فازی ساخته می‌شود. روش ACO_R به‌عنوان یک تکنیک بهینه‌سازی تجمعی قادر خواهد بود وزن‌های هر یک از روش‌های منفرد را برای استفاده در سیستم گروهی به‌دست آورد و در نهایت با تلفیق این روش‌ها با وزن‌های متناسب نتیجه پایانی حاصل می‌گردد.



شکل ۴ نمونه‌ای از توابع واحد گاوسی و تابع کرنل گاوسی

راه حل‌ها در الگوریتم مورچگان پیوسته در آرشیو ذخیره می‌شوند. در شروع الگوریتم آرشیو، با تولید K راه حل تصادفی مقدار دهی می‌شود. در آرشیو K راه حل $\{s_1, s_2, \dots, s_1, \dots, s_k\}$ به‌همراه مقادیر تابع هدفشان $\{f(s_1), f(s_2), \dots, f(s_k)\}$ نگهداری می‌شوند، راه حل‌ها در آرشیو به‌ترتیب کیفیت‌شان نگهداری می‌شوند. بنابراین برای یک مسئله کمینه‌سازی داریم:

$$f(s_1) \leq f(s_2) \leq \dots \leq f(s_2) \leq \dots \leq f(s_k) \quad (2)$$

و هر راه حل وزنی متناسب با کیفیتش دارد یعنی طبق رابطه ۳ خواهیم داشت:

$$\omega_1 \geq \omega_2 \geq \dots \geq \omega_l \geq \dots \geq \omega_k \quad (3)$$

وزن راه حل‌ها با استفاده از رابطه ۴ به‌دست می‌آید:

$$\omega_l = \frac{1}{q^k \sqrt{2\pi}} e^{-\frac{(l-1)^2}{2q^2 k^2}} \quad (4)$$

مطابق رابطه ۴ وزن، مقدار یک تابع گاوسی با میانگین ۱ و واریانس q^k است و q پارامتر الگوریتم است. زمانی که q کوچک است راه حل‌هایی با رتبه بالاتر ترجیح بیشتری دارند.

نتایج و بحث

اعمال روش‌ها بر روی داده واقعی در یکی از میدان‌های نفتی ایران

هدف اصلی این مطالعه ساخت ماشین گروهی بهینه با استفاده از الگوریتم مورچگان برای تشخیص رخساره‌های مخزنی می‌باشد، بدین‌منظور از داده‌های لرزه‌ای سه‌بعدی و داده‌های ۴ چاه مربوط به یکی از میدانی نفتی ایران استفاده گردید.

جدول ۱ لیست نشان‌گرهای انتخاب شده برای تخمین شاخص جریان (FZI)

خطای اعتبارسنجی	خطای آموزش	نشان‌گرهای بهینه	هدف
۱/۳۱	۱/۲۰	مقاومت صوتی (خروجی معکوس‌سازی)	شاخص جریان (FZI)
۱/۲۹	۱/۱۵	انتگرال قدرمطلق دامنه	شاخص جریان (FZI)
۱/۲۴	۱/۰۴	فرکانس میانگین	شاخص جریان (FZI)
۱/۵۳	۱/۰۰	پلاریته ظاهری	شاخص جریان (FZI)

برای مقادیر متفاوت پارامترها اجرا گردید و نتایج آن در جدول ۲ نشان داده شده است. همان‌طور که از نتایج نیز مشهود است با تغییر پارامترها مقادیر میانگین مربعات خطا و همبستگی بین نتایج واقعی و پیش‌بینی شده، تغییر چندانی نمی‌کند که این امر نشان‌دهنده استقلال نتایج نهایی از جواب‌های اولیه می‌باشد. در پایان، خروجی ماشین گروهی با استفاده از ضرایب استخراج شده به وسیله الگوریتم مورچگان برای نتایج هر یک از روش‌های عصبی، فازی و عصبی-فازی حاصل گردید. تخمین نهایی برای محاسبه شاخص جریان (FZI) با استفاده از ضرایب به دست آمده به صورت معادله ۶ حاصل گردید. شکل ۵ مراحل استخراج شاخص جریان از داده لرزه‌ای به وسیله ماشین گروهی را به صورت شماتیک نشان می‌دهد.

$$FZI_{CMIS} = 0.15FZI_{PNN} + 0.24FZI_F + 0.61FZI_{NF} \quad (6)$$

تابع برازش میانگین مربعات خطا که در این مطالعه جهت بهینه‌سازی توسط روش ACO_R مورد استفاده قرار گرفته است در معادله ۵ نشان داده شده است:

$$MSE_{CMIS} = \sum_{i=1}^k \frac{1}{k} (\beta_1 O_{1i} + \beta_2 O_{2i} + \beta_3 O_{3i} - l_i)^2 \quad (5)$$

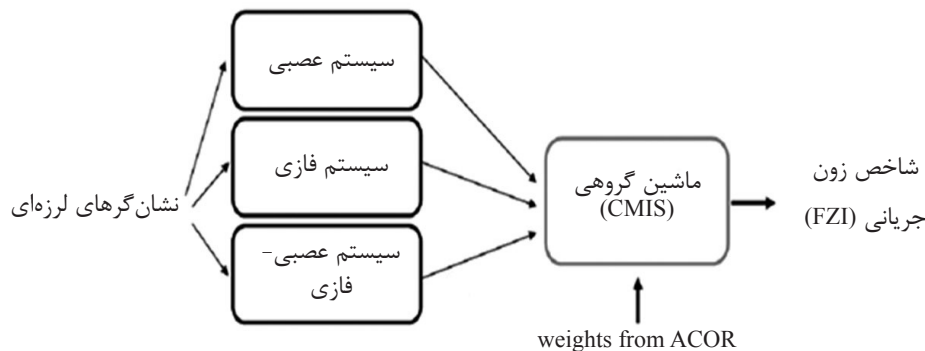
این تابع مقدار MSE^۱ را برای مدل CMIS^۲ نشان می‌دهد که β_1 ، β_2 و β_3 به ترتیب ضرایب وزنی متناظر با خروجی روش‌های عصبی، فازی و عصبی-فازی هستند. پارامترهای O_i و L_i نشان‌دهنده مقادیر خروجی و هدف می‌باشند و K تعداد داده‌های آزمون (۱۰۰ نمونه) را نشان می‌دهد. پارامترهای استفاده شده در الگوریتم مورچگان به صورت زیر می‌باشند: تعداد متغیرهای تصمیم: ۳ متغیر، سایز اولیه جمعیت: ۱۰، سایز نمونه: ۵۰، فاکتور تشدید: ۰/۵، نسبت فاصله به انحراف: ۱، بیشترین تعداد تکرار: ۱۰۰ تکرار همچنین الگوریتم بهینه‌سازی مورچگان

جدول ۲ اجرای الگوریتم بهینه‌سازی مورچگان برای پارامترهای مختلف

MaxIt	nPoP	nSample	Q	zeta	MSE	R
۱۰	۵	۱۰	۰/۶	۰/۹	۰/۱۹۶۷	۰/۹۶۰۷۳
۲۰	۱۰	۳۰	۰/۵۵	۰/۹۵	۰/۲۰۱۴	۰/۹۵۹۱۶
۳۰	۲۵	۴۰	۰/۵	۱	۰/۱۹۶۶	۰/۹۶۰۵۲
۴۰	۳۵	۵۰	۰/۴۵	۱/۱	۰/۱۹۵۶	۰/۹۶۴۳۱
۵۰	۴۵	۶۰	۰/۴	۱/۲	۰/۱۹۵۸	۰/۹۵۹۴۱
۱۰۰	۱۰	۵۰	۰/۵	۱	۰/۱۹۵۱	۰/۹۶۵۴۲

1. Mean Square Error

2. Committee Machine Inference System



شکل ۵ شکل شماتیک استخراج شاخص جریانی از داده لرزه‌ای با استفاده از ماشین گروهی

همان‌طور که در نتایج مشهود است روش عصبی-فازی دقت بیشتری را نسبت به دو روش دیگر از خود نشان می‌دهد. در ادامه با اعمال روش ماشین گروهی و به‌دست آوردن وزن‌های بهینه نتایج حاصل از روش‌های مذکور با یکدیگر ترکیب گردیدند. وزن‌های حاصل که با استفاده از الگوریتم مورچگان برای هر یک از روش‌های عصبی، فازی و عصبی-فازی بر روی داده نمونه حاصل گردید به ترتیب مقادیر ۰/۲۴، ۰/۱۵ و ۰/۶۱ می‌باشند. میانگین مربعات خطا برای روش ماشین گروهی (CMIS) برای داده نمونه برابر با ۰/۱۵۰ می‌باشد که با ضریب همبستگی^۱ (CC) ۰/۹۶۵ متناظر می‌باشد. همان‌طور که مشاهده می‌شود نتایج حاصل از ماشین گروهی بهبود قابل توجهی در تخمین شاخص جریانی از نشان‌گرهای لرزه‌ای نشان می‌دهد و کارایی بهتر از هر کدام از روش‌های منفرد دارا می‌باشد. بعد از تایید کارایی ماشین گروهی به روش الگوریتم مورچگان از این روش برای تبدیل داده لرزه‌ای سه‌بعدی به شاخص جریانی در مخزن سرمه (عرب) استفاده شد. نقشه حاصل از شاخص جریانی به‌دست آمده از این روش در جهات مختلف در شکل ۸ نشان داده شده است.

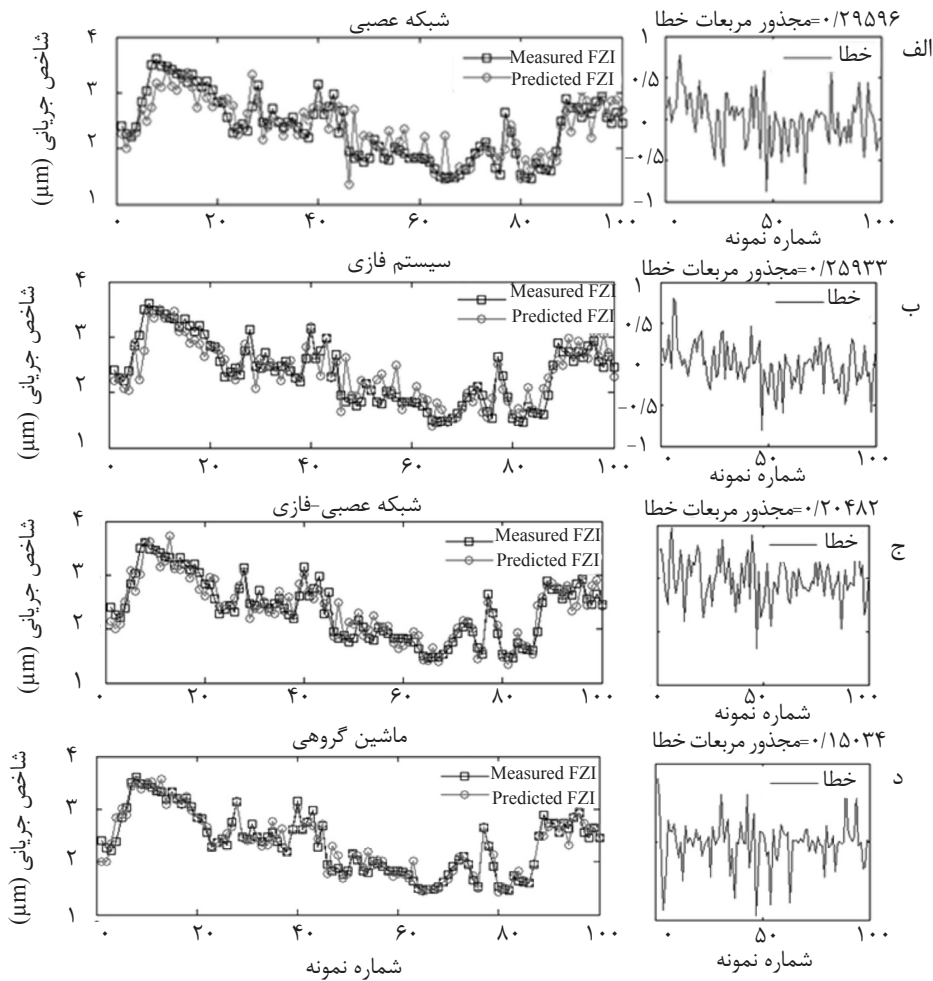
معادله نهایی با استفاده از روش Least Square Method نیز حل شد و ضرایب آن در محیط نرم‌افزار Matlab محاسبه گردید، نتایج حاصل برای این روش و همچنین روش الگوریتم مورچگان پیوسته در جدول ۳ نشان داده شده است. همان‌طور که دیده می‌شود در روش LSQ وزن بیشتری به روش‌های PNN و Fuzzy داده شده است در حالی که در روش ACOR نسبت به LSQ وزن داده شده به Nero-Fuzzy افزایش یافته است.

بحث و نتایج

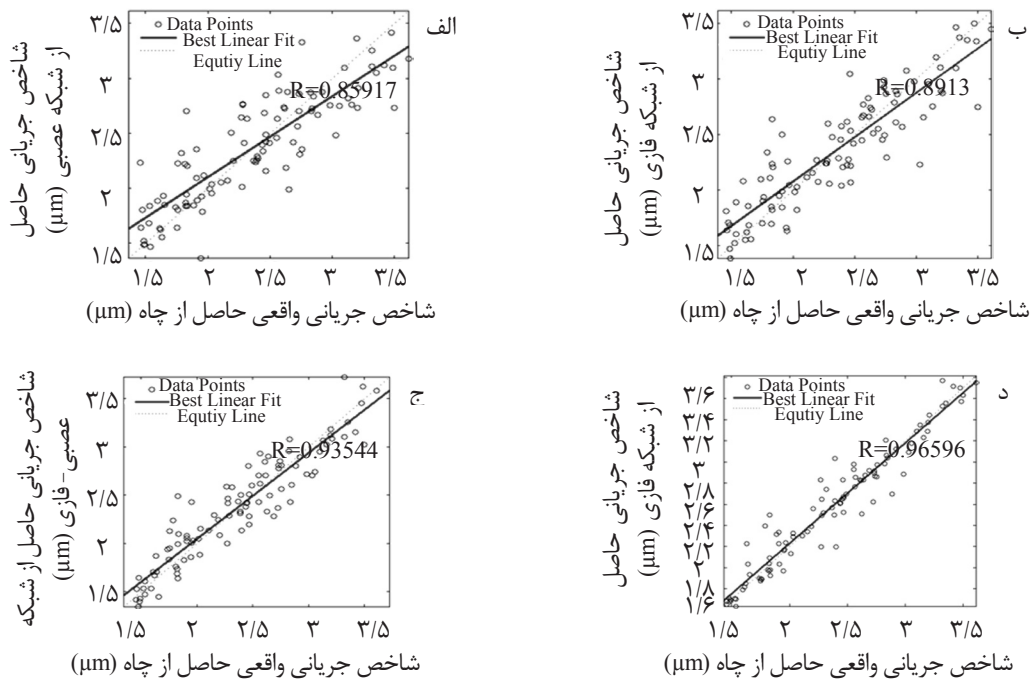
مقایسه گرافیکی و مقادیر ضریب همبستگی و بین شاخص جریانی (FZI) تخمین زده شده از هر یک از روش‌های عصبی، فازی، عصبی-فازی و ماشین گروهی برای داده نمونه در شکل‌های ۶ و ۷ نشان داده شده است. در شکل ۶ خطوط مربع شکل مقادیر پیش‌بینی شده و نمودار دایره شکل مقادیر واقعی را نشان می‌دهد. براساس نتایج حاصل از جدول ۴ و شکل‌های ۶ و ۷، مقدار میانگین مربعات خطا (MSE) برای روش‌های عصبی، فازی و عصبی-فازی به ترتیب ۰/۲۹۵، ۰/۲۵۹ و ۰/۲۰۴ می‌باشد که این مقادیر با ضرایب ۰/۸۵۹، ۰/۸۹۱ و ۰/۹۳۵ به ترتیب متناظر می‌باشند.

جدول ۳ مقایسه ضرایب حاصل برای هر یک از روش‌های عصبی، فازی و عصبی-فازی با استفاده از روش LSQ و ACO_R

	عصبی	فازی	عصبی-فازی
LSQ	۰/۲	۰/۲۵	۰/۵۵
ACOR	۰/۱۵	۰/۲۴	۰/۶۱



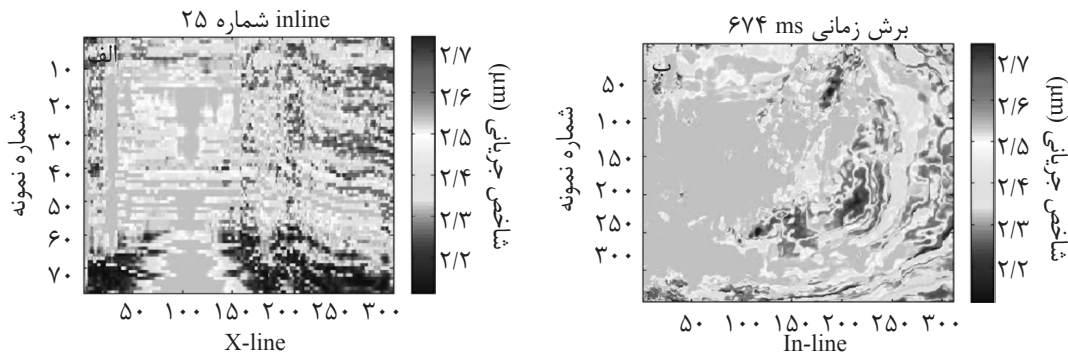
شکل ۶ نتایج تخمین زده شده شاخص جریان و خطای تخمین برای هر یک از روش‌های شبکه عصبی، فازی، عصبی-فازی و ماشین گروهی بر روی داده تست



شکل ۷ ضریب همبستگی بین شاخص جریان تخمین زده شده و اندازه‌گیری شده برای داده تست با استفاده از روش‌های الف) شبکه عصبی، ب) سیستم فازی، ج) سیستم عصبی-فازی و د) سیستم ماشین گروهی

جدول ۴ مقایسه ضریب همبستگی و میانگین مربعات خطا روش‌های هوشمند برای تخمین شاخص جریان

روش	ضریب همبستگی (CC)	میانگین مربعات خطا (MSE)
PNN	۰/۸۵۹	۰/۲۹۵
MFIS	۰/۸۹۱	۰/۲۵۹
ANFIS	۰/۹۳۵	۰/۲۰۴
CFIS	۰/۹۶۵	۰/۱۵۰



شکل ۸ نقشه‌های حاصل از شاخص جریانی به‌دست آمده از روش ماشین گروهی، الف) مربوط به inline شماره ۲۵ و ب) مربوط به ۶۷۴ ms time slice

جریانی اعمال گردید. شکل ۱۰ نتیجه حاصل بعد از اعمال این الگوریتم را نشان می‌دهد، همان‌طور که در شکل نیز مشخص است، ۶ رخساره مخزنی در این ناحیه در کل داده سه‌بعدی لرزه‌ای به خوبی تمیز داده شده است. در ادامه برای اعتبارسنجی، نتایج حاصل با نتایج حاصل از مقاطع نازک زمین‌شناسی مخزن سرمه مقایسه گردید. تعداد ۱۸۰ مقطع نازک مورد ارزیابی قرار گرفت با بررسی این مقاطع نازک و همچنین مطالعات مغزه همان‌طور که در جدول ۵ مشخص شده است براساس مقادیر تخلخل، تراوایی و همچنین محدوده شاخص جریانی تعداد ۶ رخساره (کلاس) حاصل شد که تعداد کلاس‌های حاصل و همچنین محدوده شاخص جریانی به‌دست آمده با تعداد و مقادیر تخمین زده شده به‌وسیله روش C میانگین فازی هم‌خوانی دارد، علاوه براین در شکل ۱۱ برای روشن‌تر شدن این بحث داده‌های حاصل از تست‌های مربوطه به‌همراه محدوده تخلخل و تراوایی هر کدام از رخساره‌ها و همچنین تصویر مقطع نازک مرتبط با هر رخساره قرار داده شده است.

در مرحله پایانی، از روش خوشه‌بندی C میانگین فازی برای تفکیک رخساره‌های مخزنی از مکعب سه‌بعدی شاخص جریانی که در مرحله قبل تولید شده بود، استفاده گردید. یکی از نکات مهم در استفاده از الگوریتم خوشه‌بندی C میانگین فازی تعیین بهینه تعداد کلاسترها می‌باشد. در این مطالعه برای تعیین تعداد واحدهای جریانی هیدرولیکی بهینه از روش نمودار تجمعی شاخص جریانی استفاده گردید، که این نمودار برای داده نمونه در شکل ۹ نشان داده شده است، همان‌طور که در شکل ۹ دیده می‌شود ۶ واحد جریان هیدرولیکی که نشان‌دهنده ۶ رخساره مجزا در مخزن سرمه (عرب) می‌باشد براساس نمودار تخمین زده شده است.

$$HFU 1: \text{Log FZI} < -0.61,$$

$$HFU 2: -0.61 < \text{Log FZI} < 0.54,$$



$$HFU 3: 0.54 < \text{Log FZI} < 1.13,$$

$$HFU 4: 1.13 < \text{Log FZI} < 1.96,$$

$$HFU 5: 1.96 < \text{Log FZI} < 2.51,$$

$$HFU 6: \text{Log FZI} > 2.51$$

بعد از تعیین تعداد کلاس‌های بهینه الگوریتم C میانگین فازی بر روی مکعب سه‌بعدی شاخص

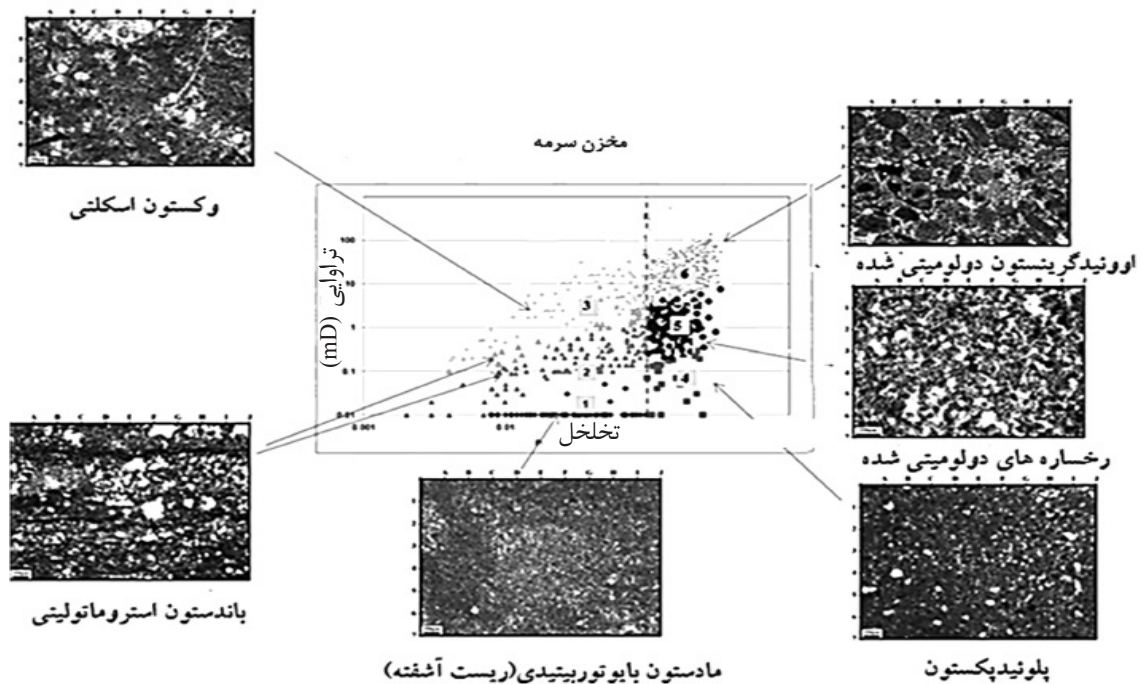


شکل ۱۰ رخساره‌های استخراج شده بعد از اعمال الگوریتم FCM بر روی داده سه‌بعدی FZI در محل چاه A، همان‌طور که در شکل دیده می‌شود ۶ رخساره با رنگ‌های مختلف از هم تمییز داده شده است

شکل ۹ نمودار تجمعی شاخص جریانی (FZI)، براساس این نمودار، تعداد ۶ واحد جریانی هیدرولیکی شناسایی گردید

جدول ۵ تقسیم‌بندی رخساره‌های مخزنی در محدوده مخزن سرمه، با استفاده از مطالعات مغزه

	میانگین تخلخل	میانگین تراوایی (mD)	Log FZI Range
Facies1	۰/۰۳۹	۰/۰۱۷	Log FZI < -۰/۶۱
Facies2	۰/۲۰۲	۰/۱۱۶	-۰/۶۱ < Log FZI < ۰/۵۴
Facies3	۰/۱۹	۱/۲۸۴	۰/۵۴ < Log FZI < ۱/۱۳
Facies4	۰/۲۰۷	۴/۴۸۸	۱/۱۳ < Log FZI < ۱/۹۶
Facies5	۰/۰۹۱	۱۳/۵۸۴	۱/۹۶ < Log FZI < ۲/۵۱
Facies6	۰/۰۹	۱۱۷/۲۱۲	Log FZI > ۲/۵۱



شکل ۱۱ رخساره‌های مخزنی حاصل با استفاده از مقاطع نازک، همان‌طور که در شکل مشخص شده هر محدوده دارای تخلخل و تراوایی به‌خصوص مر بوط به یک رخساره می‌باشد که تصویر مقطع نازک مرتبط با آن نیز با فلش نشان داده شده است

نتیجه گیری

روش‌های دیگر همراه است. همچنین نتایج این مطالعه نشان می‌دهد که روش C میانگین فازی روشی کارا و قابل اعتماد برای استخراج و تشخیص رخساره‌های مخزنی از داده سه‌بعدی شاخص جریان می‌باشد. با استفاده از این روش ۶ رخساره در مخزن مورد مطالعه مشخص شد که تطابق خوبی با نتایج مقاطع نازک زمین‌شناسی نشان داد. نتایج حاصل نشان داد که متدولوژی استفاده شده در این تحقیق که از ترکیب نتایج روش‌ها به‌وسیله ماشین گروهی و روش C میانگین فازی بهره می‌برد می‌تواند به‌عنوان روشی قابل اعتماد و کارا برای استخراج رخساره‌های مخزنی مورد استفاده قرار گیرد.

در این مطالعه سیستم‌های هوشمند شامل سیستم‌های عصبی، فازی و عصبی-فازی برای استخراج شاخص‌های جریانی از داده لرزه‌ای سه‌بعدی در یکی از میادین کربناته در ایران مورد استفاده قرار گرفتند. نتایج این تحقیق نشان داد ترکیب نتایج به‌دست آمده از سیستم‌های هوشمند به‌وسیله یک ماشین گروهی که از الگوریتم مورچگان بهره می‌برد می‌تواند دقت تخمین پارامترهای مخزنی را به نحو چشمگیری افزایش دهد. براساس نتایج حاصل روش ماشین گروهی دقتی بالاتر از هر کدام از روش‌های منفرد برای تخمین شاخص جریانی دارا می‌باشد و اجرای آن با خطای کمتری نسبت به

مراجع

- [1]. Carr D. and Oliver K. L., "Surface-bounded reservoir compartmentalization in the caddo conglomerate, boonsville (bend conglomerate) gas field, fort worth basin, Texas," AAPG Bulletin, Issue 5, Annual Convention of the American Association of Petroleum Geologists, Inc. and the Society for Sedimentary Geology: Global Exploration and Geotechnology; 19-22 May; San Diego, CA, United States, 1996.
- [2]. Michelena R. J., Gonzalez E. and Capello De P. M., "Similarity analysis: a new tool to summarize seismic attributes information," The Leading Edge, Vol. 17 (4), pp. 545-548, 1998.
- [3]. Barnes A., "Attributes for automating seismic facies analysis," SEG Annual Meeting, 6-11 August, Calgary, Alberta, 2000.
- [4]. West B., May S., Eastwood J. and Rossen C., "Interactive seismic facies classification of stack and AVO data using textural attributes and neural networks," SEG Annual Meeting, 9-14 September, San Antonio, Texas, 2002.
- [5]. Taner M. T. and Treitel S., "Harmonic attributes," Submitted to SEG 2004 Annual Symposium, SEG Int'l Exposition and 74th Annual Meeting, Denver, Colorado, 10-15 Oct. 2004.
- [6]. Farzadi P. and Hesthammer J., "Diagnosis of the Upper Cretaceous palaeokarst and turbidite systems from the Iranian Persian Gulf using volume-based multiple seismic attribute analysis and pattern recognition," Petroleum Geoscience 13 (3), pp. 227-240, DOI: 10.1144/1354-079306-710, August 2007.
- [7]. Biswal H. S. K., Sood A. and Rangachari V., "Identification of reservoir facies within a carbonate and mixed carbonate-siliciclastic sequence: Application of seismic stratigraphy, seismic attributes, and 3D visualization," The Leading Edge, Vol. 27, Issue 1, pp. 18-29, January 2008
- [8]. Dezfoolian M. A., Riahi M. A. and Kadkhodaie-Ilkhchi A., "Conversion of 3D seismic attributes to reservoir hydraulic flow units using a neural network approach: an example from the Kangan and Dalan carbonate reservoirs," the world's largest non-associated gas reservoirs, near the Persian Gulf, Earth Sci. Res. J, Vol. 17 (2), pp. 75-85, 2013.

- [9]. Yarmohammadi S. and Kadkhodaie-Ilkchi A., "Seismic reservoir characterization of a deep water sandstone reservoir using hydraulic and electrical flow units: a case study from the Shah Deniz gas field, the South Caspian Sea," J. Pet. Sci. Eng, Vol. 118, pp. 52-60, 2014.
- [10]. Diogo M., Ramos L. and André A., "Facies identification by fuzzy inference," 13th International Congress of the Brazilian Geophysical Society & EXPOGEF, Rio de Janeiro, Brazil, doi.org/10.1190/SBGf2013, 26–29 August 2013.
- [11]. Socha K. and Dorigo M., "Ant colony optimization for continuous domains," European Journal of Operational Research, Vol. 185, No. 3, pp. 1155–1173, 2008.
- [12]. Bhatt A. and Helle H. B., "Committee neural networks for porosity and permeability prediction from well logs," Geophysical Prospecting, Vol. 50, pp. 645-660, 2002.
- [13]. Mamdani E. H. and Assilian S., "An experiment in linguistic synthesis with a fuzzy logic controller," International Journal of Man-Machine Studies Vol. 7, pp. 1-13, 1975.
- [14]. Sugeno M., "Industrial applications of fuzzy control," Elsevier Science, Amsterdam, 1985.
- [15]. Nikravesh M. and Aminzadeh F., "Soft computing and intelligent data analysis in oil exploration. part1: introduction: fundamentals of soft computing," Elsevier, Berkeley, USA. p.744, 2003.
- [16]. Naftaly U., Intrator N. and Horn D., "Optimal ensemble averaging of neural networks," Computation in Neural Systems, Vol. 8, pp. 283-296, 1997.
- [17]. Chen C. H. and Lin Z. S., "A committee machine with empirical formulas for permeability Prediction," Computers & Geosciences, Vol. 32, pp. 485-496, 2006.
- [18]. Lim J. S., "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.
- [19]. Kadkhodaie A., Rahimpour-Bonab H. and Rezaee M. R., "A committee machine with intelligent systems for estimation of total organic carbon content from petrophysical data: an example from the Kangan and Dalan reservoirs in south pars gas field, Iran," Computers & Geosciences, Elsevier Publications, Vol. 35, pp. 459-474, 2009.



Petroleum Research

Petroleum Research 2018(April -May), Vol. 28, No. 98. ۳۸-۳۴

DOI: 10.22078/pr.2017.2743.2269

Integrating Neural, Fuzzy Logic, and Nero-fuzzy Approaches Implementing Ant Colony Optimization Routing Algorithm to Determine Reservoir Facies

Reza Mohebian¹, Mohammad Ali Riahi^{1*} and Ali Kadkhodaie²

1. Institute of Geophysics, University of Tehran, Iran

2. Earth Science Department, Faculty of Natural Science, University of Tabriz, Tabriz, Iran

mariahi@ut.ac.ir

Received: April/09/2017

Accepted: October/03/2017

Abstract

Determining the reservoir facies and areas with high-quality reservoirs play a pivotal role in reservoir modeling as well as future drilling in developing oilfields. As an index which varies in line with changes in the reservoir characteristics, Flow Zone Indicator (FZI) could be an influential factor in dividing the facies. The present study attempts to propose an advanced, optimized model through integrating the intelligent systems to estimate the FZI in the whole oilfield. This Committee Machine (CM) integrates the predicted results obtained from the intelligent neural, fuzzy logic, and Nero-Fuzzy systems with defined weights. Optimized weights for each method are determined using the Ant Colony Optimization Routing (ACOR) Algorithm. In this study, to apply the methods, well log and seismic data were used from one of the oilfields in South Iran. At the first stage, seismic attributes which were far more associated with the target data (FZI) were selected by stepwise regression. Subsequently, a 3D cube flow indicator in the whole field was estimated with intelligent systems. Finally, various reservoir facies were classified by the means of Fuzzy C-Mean Algorithm. The results illustrate that the committee machine which utilizes ACOR outperforms other individual systems acting alone.

Keywords: Reservoir Facies, Committee Machine (CM), Fuzzy Logic, Nero-Fuzzy Systems, Ant Colony Optimization Routing (ACOR).

Introduction

What significantly contributes to the development of oil and gas fields is the analysis of facies taking into consideration the relationship between the reservoir parameters and seismic attributes. A glance over the literature suggests that investigating such an issue has enjoyed the close attention of researchers in the realm for long; to name but a few, Carr and Oliver (1996) depicted different parts of reservoir analyzing seismic attributes in Caddo Conglomerate in the Boonsville (Bend Conglomerate) gas field [1]. Michelena, et al. (1988) benefited from self-organizing maps with seismic attributes inputs to delineate the reservoir facies [2]. Moreover, to produce seismic facies classes, Barnes (2000) combined a set of seismic attributes, including amplitude variance, spacing, parallelism, continuity, divergence and hummockiness based on the descriptions of the seismic stratigraphic reflection patterns [3]. Additionally, West et al. (2002) classified seismic facies of stack and AVO data using the textural attributes and neural network. From amongst those researchers studying this field, Rastegarnia and Kadkhodaie (2013) can be named. They followed the fuzzy rules and integrated the seismic attributes to estimate the reservoir parameters. What is more, Diago, Ramos, and Andre (2013) benefited from fuzzy rules to recognize reservoir facies from well diagram [8]. Following them, Also, Yarmohammadi et al. (2014) delineated high porosity and permeability zones using the seismic-derived FZI data at Shah Deniz sandstone packages. The present study seeks to apply neural, fuzzy, neuro-fuzzy systems, and combine the obtained results using ACOR to analyze the reservoir facies. To do so, the afore-mentioned algorithms will be applied on the real data (i.e.,

one of the Iranian Southern offshore gas fields) and the results will be validated against the well log data. Moreover, the results obtained from the CMIS will be compared with those of single approaches so as to shed light on its superior efficiency and robustness over others. At the final stage, having extracted the FZI in the whole field by the CMIS, reservoir facies will be delineated by FCM clustering algorithm and the results will be compared with thin sections analyses.

Methodology

The proposed methodology for this study comprises of three stages. At the first stage, the optimum seismic attributes that correspond more strongly with the target data (FZI) are selected by stepwise regression algorithm. Second, intelligent approaches such as neural, fuzzy, and neuro-fuzzy systems are applied to the seismic attributes, and the achieved FZI cube are calculated for the whole field. Next, to combine the results obtained from the previous approaches, a CMIS will be employed using ACOR. At the final stage, an FCM is applied to the CMIS outputs, and various facies are delineated.

Committee Machine with Intelligent Systems (CMIS)

Generally speaking, a CMIS consists of a group of intelligent systems which combine the outputs of each system and therefore reaps the benefits of all work with little additional computation. Thus, the model could outperform the best single network. A schematic diagram of CMIS is presented in the Figure 5.

There are different ways to integrate the intelligent systems output in the combiner. The simple ensemble averaging method is the most popular one (Naftaly et al., 1997; Chen & Lin, 2006) [14, 15].

Proper combination of the intelligent systems contribution (weight) in a CMIS could be achieved by a Genetic Algorithm (Lim, 2005 [16]; Chen & Lin, 2006 [15]; Kadkhodaie et al., 2009 [17]). One of the innovations this study benefits from is the use of ACOR to combine neural, fuzzy, and neuro-fuzzy models in the form of a CMIS. Such an algorithm is explained as follows:




Figure 1: schematic diagram of CMIS (Kadkhodaie et al., 2009)

Discussion and Results

Graphical comparison and correlation coefficient (CC) between predicted and measured FZI values from neural, fuzzy, and neuro-fuzzy approaches and CMIS on sample data are demonstrated in figures 2a-d and

3a-d, respectively. In Figure 2, predicted values and real values are in red and black respectively.

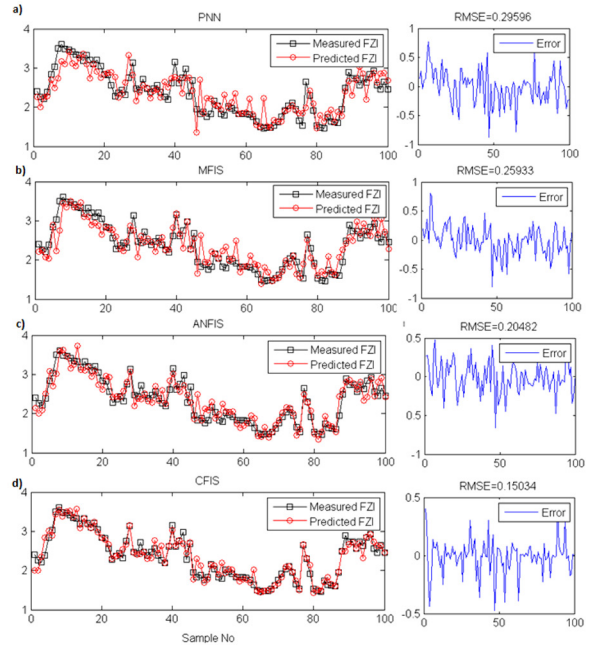


Figure 2: Predicted FZI and measurement error from neural, fuzzy, and neuro-fuzzy approaches and CMIS on sample data.

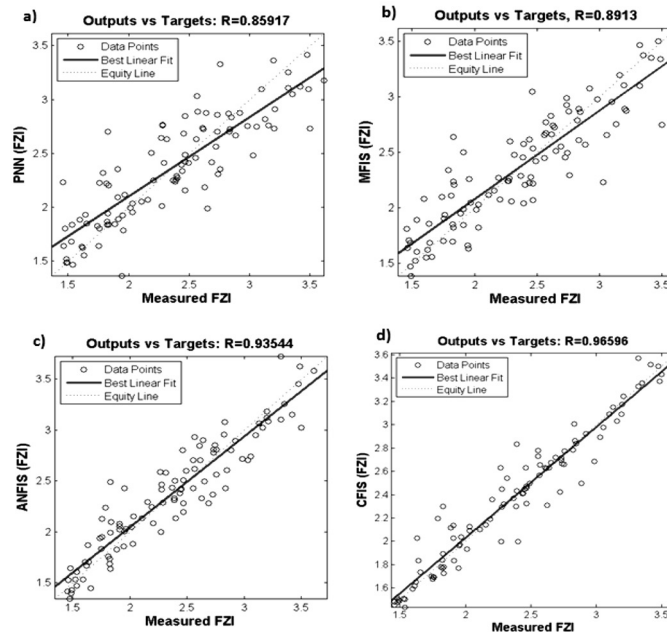


Figure 3: Correlation coefficient between predicted and measured FZI values from sample data using a) PNN b) MFIS c) ANFIS d) CFIS

Conclusion

The present study applied intelligent systems including neural, fuzzy, and neuro-fuzzy approaches to estimate FZI from 3D seismic attributes in one of the carbonate offshore gas fields, Southern Iran. The study demonstrated that integrating the outputs achieved from intelligent systems using a CMIS, which benefits from ACOR, can lead to a significant improvement in the accuracy of estimation of reservoir parameters. Based on the results obtained, CMIS provides more accurate estimation of FZI in comparison with that of individual systems. What is more, it is concluded that FCM clustering is a reliable and efficient approach in the prediction and identification of the reservoir facies from 3D FZI cube. Utilizing this approach, 6 facies in the studied gas field, whose data correspond strongly with thin sections analyses, were determined. Put it in the nutshell, it is concluded that the proposed methodology in this study, which benefits from the integration of results achieved from CMIS and FCM clustering algorithm, can be utilized as a reliable and efficient approach to delineate the reservoir facies.

References

- [1]. Carr D. and Oliver K. L., "*Surface-bounded reservoir compartmentalization in the caddo conglomerate, boonsville (bend conglomerate) gas field, fort worth basin, Texas,*" AAPG Bulletin, Issue 5, Annual Convention of the American Association of Petroleum Geologists, Inc. and the Society for Sedimentary Geology: Global Exploration and Geotechnology; 19-22 May; San Diego, CA, United States, 1996.
- [2]. Michelena R. J., Gonzalez E. and Capello De P. M., "*Similarity analysis: a newtool to summarize seismic attributes information,*" The Leading Edge, Vol. 17 (4), pp. 545-548, 1998.
- [3]. Barnes A., "*Attributes for automating seismic facies analysis,*" SEG Annual Meeting, 6-11 August, Calgary, Alberta, 2000.
- [4]. West B., May S., Eastwood J. and Rossen C., "*Interactive seismic facies classification of stack and AVO data using textural attributes and neural networks,*" SEG Annual Meeting, 9-14 September, San Antonio, Texas, 2002.
- [5]. Taner M. T. and Treitel S., "*Harmonic attributes,*" Submitted to SEG 2004 Annual Symposium, SEG Int'l Exposition and 74th Annual Meeting, Denver, Colorado, 10-15 Oct. 2004.
- [6]. Farzadi P. and Hesthammer J., "*Diagnosis of the Upper Cretaceous palaeokarst and turbidite systems from the Iranian Persian Gulf using volume-based multiple seismic attribute analysis and pattern recognition,*" Petroleum Geoscience 13 (3), pp. 227-240, DOI: 10.1144/1354-079306-710, August 2007.
- [7]. Biswal H. S. K., Sood A. and Rangachari V., "*Identification of reservoir facies within a carbonate and mixed carbonate-siliciclastic sequence: Application of seismic stratigraphy, seismic attributes, and 3D visualization,*" The Leading Edge, Vol. 27, Issue 1, pp. 18-29, January 2008.
- [8]. Diogo M., Ramos L. and André A., "*Facies identification by fuzzy inference,*" 13th International Congress of the Brazilian Geophysical Society & EXPOGEF, Rio de Janeiro, Brazil, doi.org/10.1190/SBGf2013, 26-29 August 2013.
- [9]. Socha K. and Dorigo M., "*Ant colony optimization for continuous domains,*" European Journal of Operational Research, Vol. 185, No. 3, pp.

1155–1173, 2008.

[10]. Bhatt A. and Helle H. B., "*Committee neural networks for porosity and permeability prediction from well logs,*" *Geophysical Prospecting*, Vol. 50, pp. 645-660, 2002.

[11]. Mamdani E. H. and Assilian S., "*An experiment in linguistic synthesis with a fuzzy logic controller,*" *International Journal of Man-Machine Studies* Vol. 7, pp. 1-13, 1975.

[12]. Sugeno M., "*Industrial applications of fuzzy control,*" Elsevier Science, Amsterdam, 1985.

[13]. Lim J. S., "*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.

[14]. Kadkhodaie A., Rahimpour-Bonab H. and Rezaee M. R., "*A committee machine with intelligentsystems for estimation of total organic carbon content from petrophysical data: an example from the kangan and dalan reservoirs in south pars gas field, Iran,*" *Computers & Geosciences*, Elsevier Publications, Vol. 35, pp. 459-474, 2009.