

# استفاده از مدل هیبریدی $ACO_R$ -BP جهت تخمین سرعت موج برشی از نگارهای تخلخل

زیبا حسینی<sup>۱\*</sup>، سجاد قره‌چلو<sup>۲</sup> و علی کدخدائی<sup>۳</sup>

۱- گروه زمین‌شناسی، دانشکده علوم، دانشگاه فردوسی مشهد، ایران

۲- دانشکده زمین‌شناسی، پردیس علوم، دانشگاه تهران، ایران

۳- گروه زمین‌شناسی، دانشکده علوم طبیعی، دانشگاه تبریز، ایران

تاریخ دریافت: ۹۴/۹/۸ تاریخ پذیرش: ۹۵/۵/۲۳

## چکیده

توصیف مخزن یک گام مهم در اکتشاف و توسعه میادین نفت و گاز است. در این راستا، سرعت موج برشی و تراکمی می‌توانند داده‌های ارزشمندی را برای مطالعات پترواکوستیکی از یک مخزن هیدروکربنی فراهم آورند. سرعت موج تراکمی ( $V_p$ ) توسط ابزار صوتی که در تمامی چاه‌های نفت و گاز رانده می‌شود قابل محاسبه است، ولی داده‌های مربوط به سرعت موج برشی ( $V_s$ ) در تمامی چاه‌ها، به ویژه چاه‌های قدیمی وجود ندارد. در این پژوهش، با استفاده از نگارهای تخلخل (صوتی، نوترون و چگالی)، سرعت موج برشی به کمک روش هیبریدی  $ACO_R$ -BP برآورد شد. برای این هدف، از یک مجموعه کامل داده شامل ۳۱۹۰ نقطه اطلاعاتی وابسته به مخزن آسماری که دارای داده‌های سرعت موج برشی و نگارهای تخلخل بودند، استفاده شده است. مجموعه داده‌ها به دو قسمت شامل ۲۰۹۰ نقطه اطلاعاتی برای ساخت مدل و ۱۱۰۰ نقطه برای آزمون مدل تقسیم شدند. الگوریتم هیبرید به کار گرفته در این پژوهش توانایی بیشتری در شبیه‌سازی نسبت به هر یک از الگوریتم‌های جداگانه  $ACO_R$  و NN-BP دارد. نتیجه شبیه‌سازی در مرحله آزمون این مدل، مجدور میانگین مربعات خطا و ضریب همبستگی را به ترتیب حدود ۰/۰۶ و ۰/۹۷ محاسبه نمود. نتایج این پژوهش نشان می‌دهد که الگوریتم هیبریدی  $ACO_R$ -BP با وجود لیتولوژی ناهمگون سازند آسماری عملکرد بسیار موفق‌تری داشته است. این مطالعه بر روی داده‌های مربوط به دو چاه از میدان نفتی چشمه‌خوش انجام گرفته و قابل تعمیم به سایر چاه‌های توسعه‌ای خواهد بود.

**کلمات کلیدی:** سرعت موج برشی ( $V_s$ )، الگوریتم هیبریدی  $ACO_R$ -BP، نگارهای تخلخل، مخزن آسماری، میدان نفتی چشمه‌خوش.

## مقدمه

داده‌ها در ترکیب با داده‌های سرعت موج تراکمی ( $V_p$ ) اطلاعات مفیدتری در مطالعات پتروفیزیکی، ژئوفیزیکی و ژئومکانیکی ارائه می‌دهند [۱]. اندازه‌گیری سرعت موج برشی به صورت مستقیم در آزمایشگاه از روی مغزه‌های حفاری و یا از طریق اندازه‌گیری به کمک دستگاه DSI<sup>۱</sup> انجام می‌شود.

داده‌های سرعت موج برشی ( $V_s$ ) یکی از مهم‌ترین پارامترها جهت ارزیابی و توصیف مشخصات مخازن هیدروکربوری در صنعت نفت به شمار می‌رود. این

۱. Dipole Shear Sonic Imager

\*مسئول مکاتبات  
آدرس الکترونیکی  
ziba.hosseini@mail.um.ac.ir

[۱]. آسوده و باقری‌پور در سال ۲۰۱۳، با استفاده از یک سیستم هوشمند هیبریدی که ترکیبی از الگوریتم جستجوی مستقیم و الگوریتم ژنتیک بوده به دقت خوبی سرعت موج برشی را برآورد نمودند [۷]. آخوندی و همکارانش در سال ۲۰۱۴ سرعت موج برشی را با استفاده از ترکیب نتایج رگرسیون چند متغیره خطی و شبکه عصبی مصنوعی در مخزن آسماری پیش‌بینی کردند. نتایج پژوهش آنها نشان داد که سرعت موج تراکمی (Vp)، نگار نوترون (NPHI) و نگار چگالی (RHOB) ورودی‌های موثرتری نسبت به نگارهای گاما (GR) و مقاومت (LLD) هستند و عملکرد مدل با به‌کارگیری سه ورودی موثرتر (Vp، NPHI و RHOB) بهتر می‌شود [۸]. ملکی و همکارانش نیز در سال ۲۰۱۴ و همچنین باقری‌پور و همکارانش در سال ۲۰۱۵، سرعت موج برشی را از روی داده‌های پتروفیزیکی تخمین زدند. آنها از دو مدل SVR و الگوریتم پس انتشار خطا (NN-BP) برای این منظور استفاده نمودند که پژوهش آنها بیانگر برتری مدل SVR در ارائه سریع و دقیق‌تر نتایج بوده است [۹ و ۱۰]. نورافکن و کدخدائی در سال ۲۰۱۵، کارایی مدل هیبریدی الگوریتم کلونی مورچه-منطق فازی (ACOFIS) را در برآورد سرعت موج برشی در میدان چشمه‌خوش بررسی کردند. نتایج پژوهش آنها نشان داد که مدل هیبریدی عملکرد بهتری از مدل‌های منفرد سیستم هوشمند دارد [۱۱]. روند پژوهش‌های اخیر بیانگر ارائه مدل‌هایی توانمندتر جهت پیش‌بینی سریع‌تر و دقیق‌تر سرعت موج برشی می‌باشد. در این راستا، پژوهش حاضر می‌کوشد با ارائه مدل هیبریدی از بهینه‌سازی کلونی مورچه-الگوریتم پس انتشار خطا (ACO<sub>R</sub>-BP)، به این مهم دست یابد. مجموعه داده‌های پژوهش، متعلق به دو چاه وابسته به مخزن آسماری در میدان چشمه‌خوش است که توسط شرکت نفت مناطق مرکزی ایران تهیه شده‌اند. این مطالعه جهت شبیه‌سازی سرعت موج برشی، در سایر چاه‌های توسعه‌ای میدان مورد

دستگاه DSI یک ابزار جدید برای اندازه‌گیری سرعت موج برشی است که اطلاعات آن برای همه چاه‌ها و به‌خصوص چاه‌های قدیمی در دسترس نیست. از طرفی اندازه‌گیری بر روی نمونه‌های مغزه بسیار زمان‌بر و پرهزینه می‌باشد و برای همه چاه‌ها نیز نمونه‌های مغزه تهیه نمی‌شود. در سال‌های اخیر سیستم‌های هوشمند به‌عنوان ابزار قدرتمندی جهت پیش‌بینی پارامترهای ارزشمند، لاگ‌ها و سایر اطلاعات مفید در صنعت نفت مورد استفاده قرار گرفته‌اند. این سیستم‌ها از داده‌های در دسترس که با صرف هزینه کم‌تری تهیه می‌شوند، به عنوان ورودی برای تخمین پارامتر مورد نظر بهره می‌گیرند. داده‌های پتروفیزیکی از دسته داده‌هایی هستند که نه تنها در دسترس بوده و با صرف هزینه کم‌تری تهیه می‌شوند، بلکه در بیشتر موارد به‌طور پیوسته در تمامی طول چاه ثبت می‌شوند [۲]. از این‌رو جهت شبیه‌سازی سرعت موج برشی، مطالعات اخیر بیشتر از سیستم‌های هوشمند و داده‌های پتروفیزیکی بهره گرفته‌اند. اسکندری و همکارانش در سال‌های ۲۰۰۳ و ۲۰۰۴ از روش‌های رگرسیون چند متغیره و شبکه عصبی مصنوعی برای پیش‌بینی سرعت موج برشی استفاده کردند [۴ و ۳]. رضایی و همکارانش در سال ۲۰۰۷ و همچنین رجبی و همکارانش در سال ۲۰۱۰ روش‌های منطق فازی و عصبی-فازی را برای پیش‌بینی سرعت موج برشی به کار بردند. آنها در پژوهش خود به این نتیجه دست یافتند که هر دوی این مدل‌ها قابلیت پیش‌بینی بسیار خوبی دارند و قابل تعمیم به سایر چاه‌های میدان مورد مطالعه هستند [۶ و ۵]. معتضدیان و همکارانش در سال ۲۰۱۱ سرعت موج برشی و تراکمی را با مقایسه دو سیستم هوشمند الگوریتم ژنتیک و رگرسیون چند متغیره، از روی داده‌های پتروفیزیکی تخمین زدند. نتایج مطالعه آنها نشان داد که الگوریتم ژنتیک عملکرد بهتری نسبت به رگرسیون چند متغیره در پیش‌بینی سرعت موج برشی و تراکمی دارد

آسماری در این میدان به ۶ زون مخزنی تقسیم می‌شود که زون‌های ۲ و ۴ از نظر قابلیت بهره‌دهی دارای بهترین شرایط مخزنی هستند. زون ۲ کربناته با ۱۰ m ماسه‌سنگ در قاعده و زون ۴ ماسه‌سنگی است [۱۲].

### روش تحقیق

الگوریتم هیبریدی  $ACO_R$ -BP ترکیبی از الگوریتم‌های کلونی مورچه و پس انتشار خطا می‌باشد. بنابراین شناخت هریک از این الگوریتم‌ها کمک شایانی به درک عملکرد الگوریتم هیبریدی می‌نماید. در این بخش ابتدا نحوه کار هریک از این الگوریتم‌ها به صورت جداگانه و سپس کاربرد ترکیب آنها با هم شرح داده می‌شود:

#### شبکه عصبی مصنوعی - الگوریتم پس انتشار خطا<sup>۱</sup>

شبکه‌های عصبی مصنوعی به عنوان روشی داده‌محور و بدون در نظر گرفتن فرضیات و محدودیت‌های موجود در روش‌های مدل‌گرا، چشم‌انداز نوین و قدرتمندی در جهت تقریب توابع پیچیده دارند. شبکه‌های عصبی که تا به امروز به طور گسترده در پروژه‌های مهندسی نفت مورد استفاده قرار گرفته‌اند، شبکه‌های عصبی پیش‌خور<sup>۲</sup> بیشتر به دلیل سادگی آنها بوده است.

مطالعه و ارزیابی مشخصات پتروفیزیکی و ژئومکانیکی این چاه‌ها کاربرد دارد.

### زمین‌شناسی منطقه

میدان چشمه‌خوش در منتهی الیه شمالی فروافتادگی دزفول در نزدیکی مرز جنوبی ناحیه لرستان قرار دارد (شکل ۱). فروافتادگی دزفول یکی از مناطق اصلی تولید نفت در خاورمیانه است. این فروافتادگی ساختاری در بخش مرکزی زاگرس حاوی میادین هیدروکربنی بسیاری است که میدان نفتی مورد مطالعه یکی از آنها می‌باشد. اولین چاه میدان چشمه‌خوش در سال ۱۳۴۵ حفر شد که به دلیل بروز مشکلات فنی متروکه اعلام گردید. در سال ۱۳۴۶ وجود نفت در چاه ۲ میدان و در مخزن آسماری به اثبات رسید و تاکنون ۱۵ حلقه چاه در این میدان حفاری شده که از این تعداد ۲ حلقه چاه متروکه است. در سطح زمین ساختمان میدان، یک ساختمان تک شیب می‌باشد، که به طرف شمال-شرقی شیب دارد و بخش جنوب-غربی آن توسط یک گسل تراستی محدود شده است. مخزن آسماری، با ضخامت حدود ۳۲۰ m، در این میدان به علت نفوذ بخش ماسه‌سنگی اهواز به صورت یک مخزن هیبریدی یا مخلوط کربناته-آواری می‌باشد. براساس تغییرات سنگ‌شناسی و تخلخل مفید، سنگ مخزن



شکل ۱ موقعیت میدان نفتی چشمه‌خوش در فروافتادگی دزفول [۱۳].

1. Back-Propagation Algorithm (BP)  
2. Feed-Forward

الگوریتم لونبرگ-مارکواد<sup>۱</sup> یکی از الگوریتم‌های پس انتشار خطا می‌باشد که از سرعت همگرایی بالایی بهره‌مند است. چراکه این الگوریتم نیازی به محاسبه ماتریس هشین ندارد و به وسیله ماتریس ژاکوبی مقدار خطا را تقریب می‌زند که مشتق مرتبه اول است [۱۷]. به همین دلیل در این مطالعه از تابع "trainlm" که یکی از پرکاربردترین توابع یادگیری الگوریتم پس انتشار خطا بوده به سبب کارایی و یادگیری بالای آن استفاده شده است.

#### الگوریتم کلونی مورچه برای مسائل بهینه‌سازی پیوسته- $ACO_R$

در دهه‌های اخیر، برای انطباق الگوریتم کلونی مورچه جهت بهینه‌سازی توابع پیوسته انواع گوناگونی از آن معرفی شده‌اند. یکی از کاربردی‌ترین نوع بهینه‌سازی‌های کلونی مورچه،  $ACO_R$  نام دارد که برای تطبیق آن به فضای جستجوی پیوسته بدون تغییر اساسی در ویژگی‌های اصلی الگوریتم کلونی مورچه توسط سوچا در سال ۲۰۰۴ ارائه گردید [۱۸]. تمامی انواع الگوریتم  $ACO$  بر شیوه‌ای استوار هستند که در آن مورچه‌ها براساس یک اثر شیمیایی به نام فرومون به دنبال غذا می‌گردند. میزان احتمال انتخاب مسیرهای منتهی به غذا توسط یک مورچه، طبق اندازه و کمیت فرومون آن مسیر انجام می‌شود. به گونه‌ای که یک مسیر کوتاه‌تر نیاز به زمان سفر کمتری دارد و در یک بازه زمانی، با سطح بالاتری از فرومون خاتمه یافته و به این طریق، این الگوریتم‌ها بهینه‌ترین جواب مسئله را به دست می‌دهند [۱۹]. در کار حاضر هدف از به‌کارگیری الگوریتم  $ACO_R$  پیدا کردن ضرایب اولیه ماتریس وزن و بایاس‌های مربوط به لایه‌های شبکه عصبی در مرحله آموزش می‌باشد. الگوریتم  $ACO_R$  در فضایی پیوسته، تعداد محدودی از این جواب‌های برگزیده را در ماتریسی به نام solution archive ذخیره می‌کند. اولویت در ذخیره‌سازی براساس رتبه هر کدام از راه‌حل‌ها می‌باشد.

شبکه‌های پیش‌خور ساختارهایی شبکه‌ای هستند که اطلاعات یا سیگنال‌ها را فقط در یک جهت منتشر می‌نمایند. در طراحی معماری این نوع شبکه‌ها، عواملی از قبیل تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، توابع تبدیل و الگوریتم آموزش باید تعیین شوند. به طور معمول شبکه‌های پیش‌خور دارای سه لایه شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی می‌باشد. امکان اینکه این شبکه‌ها بیش از یک لایه پنهان داشته باشند وجود دارد اما یک تک لایه برای تقریب هر تابع به درجه‌ای مطلوب از دقت کافی است [۱۴]. نرون، کوچک‌ترین واحد پردازشگر اطلاعات است و اساس عملکرد شبکه عصبی را تشکیل می‌دهد. برای ارتباط لایه‌ها باهم، نرون‌های هر لایه با تمام نرون‌های لایه بعدی یا قبلی ارتباط دارند اما نرون‌های یک لایه مشابه آنچه در سیستم نرونی بیولوژیکی وجود دارد با یکدیگر مرتبط نیستند، و این امر باعث عملکرد موازی نرون‌ها می‌شود. در شبکه‌های عصبی، الگوریتم‌های پس انتشار خطا محبوب‌ترین الگوریتم‌های آموزشی هستند که با توجه به موفقیت آنها از هر دو نقطه نظر سادگی و کاربرد جهت آموزش شبکه‌های پیش‌خور به طور گسترده استفاده می‌شوند [۱۵]. الگوریتم‌های متعدد پس انتشار خطا وجود دارد که انتخاب آن به فرم مسئله نیز بستگی دارد. این الگوریتم‌ها با تنظیم و محاسبه ضرایب وزنی پلی ارتباطی بین داده‌های ورودی و خروجی برقرار می‌کنند. در شبکه‌های پیش‌خور با الگوریتم پس انتشار خطا که در این مطالعه مد نظر قرار گرفته است در طول آموزش خطای خروجی به عقب منتشر می‌شود و به این طریق با بروزرسانی ماتریس ضرایب وزنی به یک خروجی مطلوب‌تر دست یافته می‌شود. این عمل تا جایی ادامه می‌یابد که خطای بین داده هدف و داده خروجی به دست آمده از ماتریس وزن اصلاح شده ناچیز شود و در نتیجه مقدار تابع هدف به حداقل ممکن برسد [۱۶].

1. Levenberg-Marquardt (LM)

می‌شود. به کمک  $\varepsilon$  حد پایینی برای مقادیر  $\sigma$  در نظر گرفته می‌شود.  $\sigma$  کوچک‌تر به معنای توزیع فرورمون باریک‌تر و بلندتر می‌باشد. در ماتریس ستونی سوم مقدار عددی برای تابع هدف محاسبه شده و در ماتریس ستونی چهارم نیز به هر یک از راه‌حل‌ها، براساس رتبه آنها، وزن داده می‌شود. بنابراین در هر مرحله، بالاترین وزن مختص راه‌حل اول می‌باشد. این وزن در این مطالعه براساس معادله ۲ محاسبه شده است:

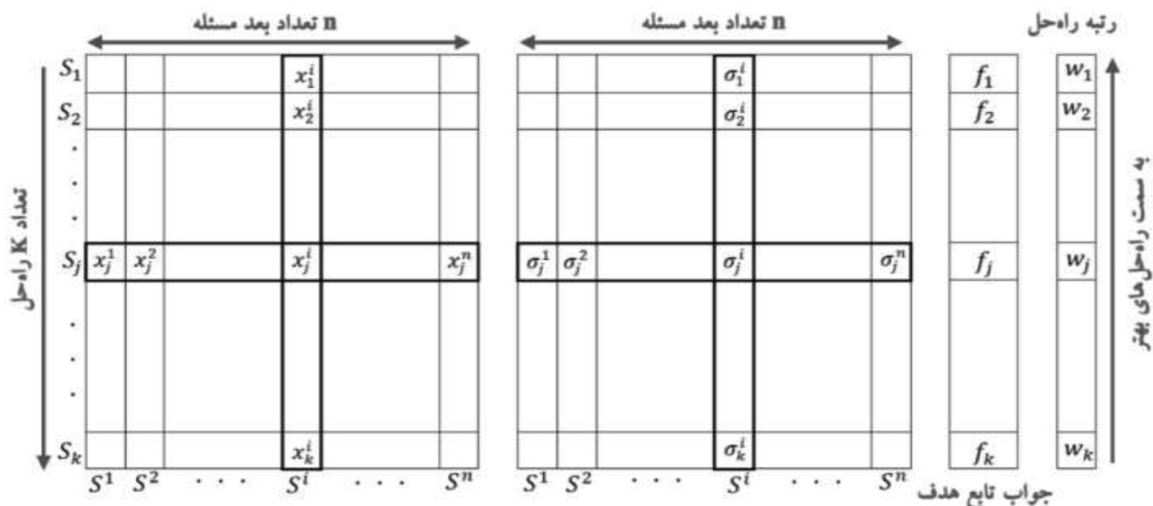
$$w_j = \frac{1}{\sqrt{2\pi}qk} e^{-\frac{(r_j - 1)^2}{q^2 k^2}} \quad (2)$$

مقدار  $(r_j=1,2,\dots,k)$ ، رتبه بهترین راه‌حل‌ها در solution archive است. بالاترین مقدار  $w_j$  به ازای بهترین راه‌حل ( $r=1$ ) حاصل می‌شود. حد پایین و بالای  $w_j$  با تغییر پارامتر  $q$  تغییر می‌کند. در واقع کاهش پارامتر  $q$  سبب می‌شود اولین راه‌حل ذخیره شده در solution archive احتمال انتخاب بیشتری داشته باشد و برعکس با افزایش این پارامتر، توزیع احتمال برای انتخاب شدن به صورت یکنواخت‌تر در می‌آید و اجازه انتخاب شدن به دیگر راه‌حل‌های موجود در solution archive داده می‌شود.  $k$  تعداد راه‌حل‌های solution archive است. مورچه‌ها براساس این اطلاعات بایگانی شده می‌توانند راه‌حل‌های احتمالی را انتخاب نمایند.

همچنین در این روش از یک تابع Gaussian Kernal PDF که مجموعه‌ای از چند تابع توزیع احتمال نرمال<sup>۱</sup> منفرد می‌باشد، استفاده می‌شود (معادله ۳). تابع توزیع احتمال نرمال به آسانی توسط روش‌های Box-Muller [۲۰] و الگوریتم Ziggurat [۲۱] توضیح داده شده است. در مرحله اولیه اجرای الگوریتم، تمام نقاط فضای جستجو احتمال انتخاب شدن یکسانی دارند. پس از آغاز جستجو و ارزیابی تابع هدف تعداد محدودی از راه‌حل‌های پیدا شده در طول هر تکرار در solution archive ذخیره می‌شود (شکل ۲). ماتریس solution archive یک ماتریس  $n \times k$  می‌باشد.  $k$  تعداد بهترین جواب‌ها تا مرحله کنونی است (این ذخیره‌سازی براساس رتبه هر کدام از جواب‌ها صورت می‌گیرد) و  $n$  بعد مسئله می‌باشد. ماتریس دوم نیز یک ماتریس  $n \times k$  است و به  $\sigma$  اختصاص یافته که شاخصی از پراکندگی نسبت به سایر راه‌حل‌های ذخیره شده در solution archive می‌باشد که به صورت زیر محاسبه می‌شود:

$$\sigma_j^i = \max \left\{ \frac{\max(x_{1..m}^i) - \min(x_{1..m}^i)}{u \cdot w_j \cdot \sqrt{t}}, \varepsilon \right\} \quad (1)$$

$t$  شماره تکرار،  $m$  تعداد کل مورچه‌ها،  $u$  پارامتری برای تنظیم سرعت همگرایی جواب است. افزایش و کاهش پارامتر  $u$  به ترتیب سبب افزایش خاصیت اکتشافی و افزایش خاصیت استخراجی الگوریتم



شکل ۲ ماتریس Solution archive و ماتریس‌های توزیع نرمال مرتبط با آن [۲۲].

هدف برای رسیدن به دقت مورد نیاز هستند. این الگوریتم نسبت به دیگر متدهای بر پایه جمعیت نیز مثل الگوریتم ژنتیک یا تکامل تفاضلی<sup>۴</sup>، به علت داشتن حافظه و همچنین داشتن تعداد پارامترهای کمتر جهت تنظیم، نه تنها اجرای سریع‌تر بلکه کاربرد آسان‌تری دارد [۲۳].

#### الگوریتم هیبریدی ACO<sub>R</sub>-BP

ACO<sub>R</sub>-BP یک الگوریتم بهینه‌سازی ترکیبی از الگوریتم کلونی مورچه و الگوریتم پس انتشار خطا می‌باشد که عملکرد آنها به طور جداگانه شرح داده شد. ACO<sub>R</sub> نوعی از الگوریتم‌های بهینه‌سازی کلونی مورچه برای مسائل پیوسته است که توانایی بالایی در حل مسائل پیچیده دارد و قادر به فرار از مینیمم محلی برای یافتن یک راه‌حل بهینه سراسری می‌باشد. با این حال این الگوریتم یک نقطه ضعف دارد و آن جستجوی بسیار آهسته در اطراف بهینه سراسری یافت شده است. همچنین مدل‌های شبکه عصبی نیز تا حدودی از عدم قطعیت رنج می‌برند و ممکن است در بهینه محلی گیر بیافتند [۲۴]. بدین‌منظور برای پرهیز از بهینه محلی و همین‌طور تسریع در همگرایی، ترکیب الگوریتم پس انتشار خطا با ACO<sub>R</sub> صورت گرفت که هم‌زمان قابلیت جستجو در چندین ناحیه را داراست و نقاط ضعف هر یک از مدل‌های جداگانه را با نقاط قوت مدل دیگر می‌پوشاند. ترکیب این دو الگوریتم می‌تواند سبب افزایش سرعت و دقت در ارائه بهینه‌ترین جواب شود. چرا که الگوریتم ACO<sub>R</sub> با توجه به خاصیت اکتشافی‌اش برای آموزش شبکه عصبی که خود در استخراج جواب تواناست به کارگرفته می‌شود. از این رو تنظیم اولیه از ضرایب وزنی اتصال نرون‌ها که اجزای بهینه‌سازی مسئله می‌باشند بر عهده ACO<sub>R</sub> قرار می‌گیرد و بهبود نهایی به عهده خود شبکه عصبی گذاشته می‌شود (شکل ۳).

در واقع با توجه به راه‌حل‌های ثبت شده در solution archive در هر مرحله، توزیع فرامون با استفاده از تا "Gaussian kernel PDF" صورت می‌گیرد. معادله ۳ نشان‌دهنده این تابع است که به صورت مجموع وزنی از k تابع یک بعدی گوسین تعریف شده است.

$$G^i(x) = \sum_{l=1}^k w_l g_l^i(x) = \sum_{l=1}^k w_l \frac{1}{\sigma_l \sqrt{2\pi}} e^{-\frac{(x-\mu_l)^2}{2\sigma_l^2}} \quad (3)$$

در بروزرسانی مثبت، راه‌حل‌های با کیفیت بالاتر در solution archive ذخیره می‌شود. در هر تکرار، بعد از مرحله ساخت جواب‌های جدید (m راه‌حل جدید)، کارایی هر یک از این جواب‌ها به کمک تابع هدف مورد ارزیابی قرار می‌گیرد و تعداد مشخصی از این راه‌حل‌ها (nos) برگزیده می‌شود. این راه‌حل‌های برگزیده به solution archive اضافه شده و تعداد اعضای آن به k+nos می‌رسد: k+nos → k

در بروزرسانی منفی، با حذف راه‌حل‌های قدیمی و راه‌حل‌های با کارایی پایین، اندازه solution archive را ثابت نگه می‌داریم به عبارت دیگر در این بروزرسانی، تعداد nos راه‌حل از solution archive حذف می‌شود: k-nos → k

برای پیاده‌سازی بروزرسانی منفی، می‌توان روش‌های دیگری نیز به کار گرفت به‌عنوان مثال در هر تکرار با افزایش  $\sigma$  تابع توزیع فرامون عریض‌تر شده و تاثیر انتخاب جواب‌های قدیمی کاهش می‌یابد. (فرآیند تبخیر  $\sigma_i^j = \gamma \cdot \sigma_i^j$ )

تحت تاثیر تغییرات جواب‌های ذخیره شده در solution archive، در هر مرحله فرامون براساس تابع توزیع احتمال نرمال، در مسیر بهینه افزایش و برعکس در مسیرهایی که سبب بهبود تابع هدف نشده اند تبخیر شده و کاهش می‌یابد. به این طریق است که بهترین جواب برای مسئله توسط این الگوریتم پیدا می‌شود. مزیت اصلی ACO<sub>R</sub> سرعت اجرای بالاتر نسبت به دیگر الگوریتم‌های کلونی مورچه پیوسته مثل API<sup>۱</sup>، CACO<sup>۲</sup> و یا CIAC<sup>۳</sup> است که نیازمند ارزیابی زیادی از تابع

1. Asynchronous Parallel Implementation  
2. Continuous Ant Colony Optimization  
3. Continuous Interacting Ant Colony  
4. Differential Evolution



شکل ۳ نمودار گردش کار الگوریتم هیبریدی ACO<sub>R</sub>-BP [۲۵].

هدف اصلی تنظیم وزن ها به حداقل رساندن تابع هدف است که در این پژوهش به صورت مجذور میانگین مربع خطا (RMSE) تعریف می شود:

$$RMSE = \sqrt{\sum_{i=1}^N \frac{1}{N} (V_{s_{real}} - V_{s_{predicted}})^2} \quad (4)$$

در این معادله RMSE مجذور میانگین مربع خطا، N تعداد نمونه ها، مقدار سرعت موج برشی پیش بینی شده و  $V_{s_{real}}$  مقدار سرعت موج برشی اندازه گیری شده توسط DSI است.

### بحث و بررسی

#### تعیین بهترین ورودی از داده های پتروفیزیکی

این گام از پژوهش، نقش مهمی را در ساخت مدل ایفا می کند. به طور کلی، ارتباط قوی بین داده های ورودی و خروجی، می تواند پیش گویی دقیق تری را نسبت به داده های با تطابق ضعیف تر ایجاد کند [۲۷]. براساس مطالعات اخیر، نگارهای تخلخل (نوترون، صوتی و چگالی) ورودی های مؤثرتری در برآورد سرعت موج برشی هستند. بنابراین پژوهش حاضر از این نگارها برای پیش بینی سرعت موج برشی استفاده نموده است. ارتباط نگارهای تخلخل با سرعت موج برشی به شرح زیر است:

**نگار صوتی:** از روی نگار صوتی (DT)، مقادیر

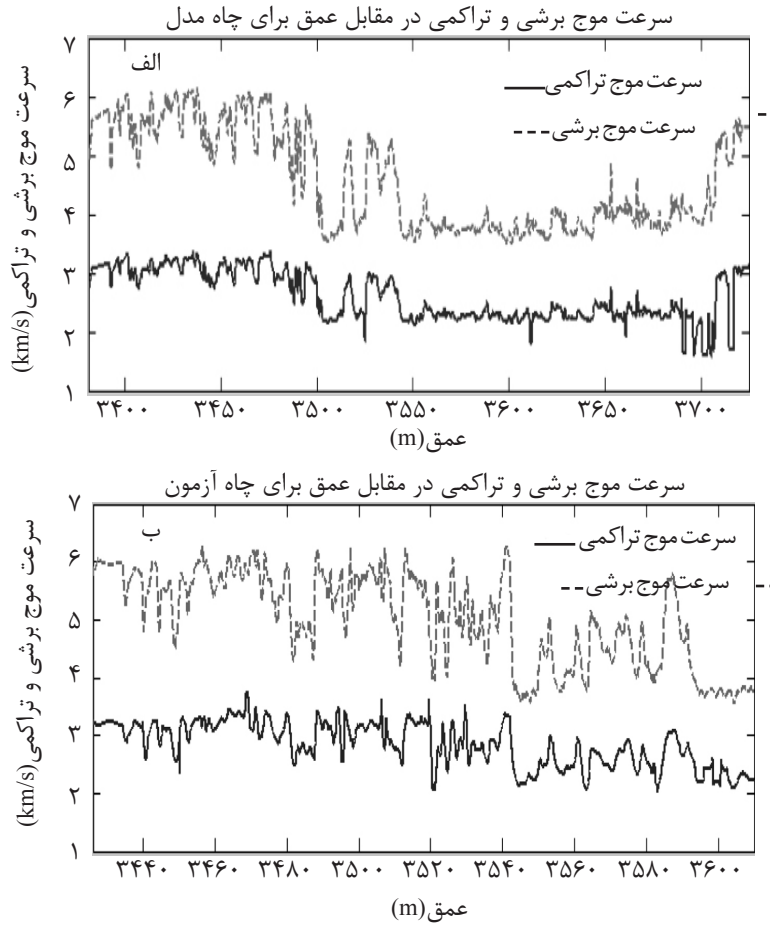
$$V_p \text{ (km/s)} = 304.8 / DT \quad (5)$$

نگار نوترون: این نگار اندازه گیری هایی از غلظت هیدروژن در خلل و فرج است. در واقع هرچه تخلخل سازند و شاخص هیدروژن سازند (HI) افزایش یابد نوترون نیز افزایش می یابد [۲۸]. با افزایش نگار نوترون (افزایش تخلخل سازند)، سرعت موج برشی و تراکمی طبق معادله ۶ کاهش می یابند [۸].

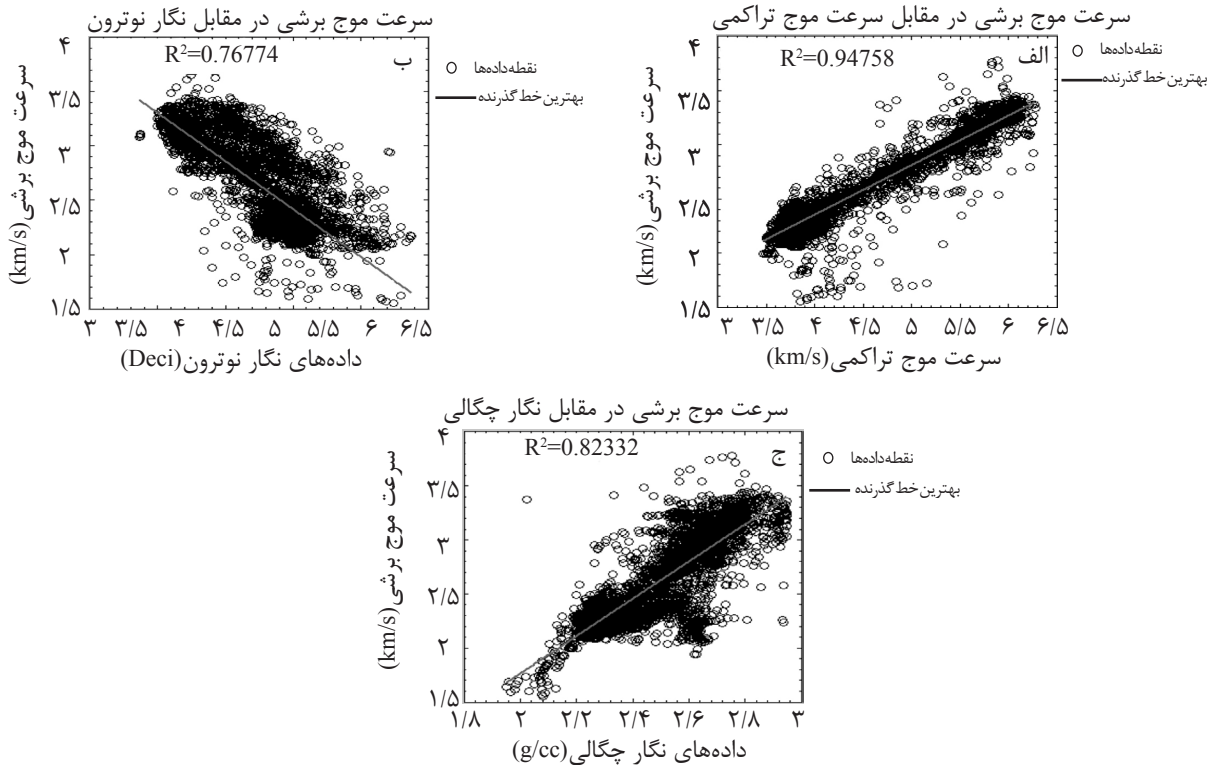
$$\frac{1}{V} = \frac{\phi}{V_f} + \frac{1-\phi}{V_m} \quad (6)$$

در این معادله،  $\phi$  تخلخل سازند می باشد، که توسط تخلخل نوترون تعیین شده است.  $V_f$  سرعت سیال و  $V_m$  سرعت در خمیره سنگ است. شکل (۵-ب) تأییدکننده ارتباط عکس بین سرعت موج برشی و نگار نوترون می باشد.

**نگار چگالی:** بر طبق معادله ۶ و ۷، با افزایش چگالی سازند، سرعت موج برشی و تراکمی افزایش می یابد [۲۹].



شکل ۴ نمایش تطابق گرافیکی از روند داده‌های سرعت موج برشی ( $V_s$ ) و سرعت موج تراکمی ( $V_p$ ). الف- چاه مدل و ب- چاه آزمون



شکل ۵ الف- ارتباط بین سرعت موج برشی ( $V_s$ ) و سرعت موج تراکمی ( $V_p$ ), ب- ارتباط بین سرعت موج برشی ( $V_s$ ) و سرعت موج برشی ( $V_s$ ), ج- ارتباط بین سرعت موج برشی ( $V_s$ ) و نگار نوترون (NPHI).



حدود مقادیر داده‌های ورودی برای ساخت مدل هیبریدی ACO<sub>R</sub>-BP، همراه با عمق مربوطه در شکل ۶ نشان داده شده است.

همان‌طور که قبلاً ذکر شد، سرعت موج برشی به تراکم سنگ رسوبی بستگی دارد. از آنجایی که قسمت زیرین سازند آسماری در میدان مورد مطالعه ماسه سنگ‌های پر تخلخل و سست می‌باشد سرعت موج برشی اندازه‌گیری شده مطابق با روند سرعت موج تراکمی به شدت کاهش می‌یابد. همچنین ماسه سنگ‌های این بخش سازند به‌ندرت سیمانی شده‌اند. از طرفی بخش بالایی سازند به دلیل کربناته بودن و اثر دیاژنز، مقادیر سرعت موج برشی و تراکمی بیشتری خواهد داشت. زیرا سنگ‌های کربناته تخلخل کمتری دارند و همین‌طور مستعد دیاژنز هستند. فرآیندهای دیاژنزی مانند سیمانی شدن، فشردگی و دولومیتی شدن موجب افزایش سرعت موج برشی در سنگ می‌شود. مدل هوشمند طراحی شده باید قادر به تشخیص تغییرات رسوب‌شناسی سازند آسماری از روی داده‌های ورودی باشد، تا بتواند عملکرد خوبی را ارائه دهد. جدول ۱ نمایانگر شاخص‌های اصلی کد نوشته شده برای مدل هیبریدی ACO<sub>R</sub>-BP می‌باشد. در به‌کارگیری این مدل، مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R2)، به‌عنوان معیاری از کارایی مدل تعیین گردید. برای محاسبه مقادیر خطای واقعی در هر دسته داده، پس از اجرای الگوریتم تمامی داده‌ها از حالت نرمال‌سازی، دی‌نرمال شده‌اند. الگوریتم ACO<sub>R</sub>-BP با ضریب همبستگی برابر با ۰/۹۸۹ و مجذور میانگین مربعات خطای برابر با ۰/۰۳۲ آموزش دید. در نتیجه این آموزش موفق، مدل هیبریدی توانست با مقادیر خطای بسیار کم و ضریب همبستگی بالا، سرعت موج برشی را شبیه‌سازی نماید (شکل ۷). تطابق بین سرعت موج برشی اندازه‌گیری شده و سرعت موج برشی پیش‌بینی شده در داده‌های تست و داده‌های صحت‌سنجی از این مدل به‌همراه مقادیر خطا، در شکل (۸ و ۹) نشان داده شده است.

شکل (۵-ج) ارتباط مستقیم بین نگار چگالی و سرعت موج برشی را نشان می‌دهد.

$$\phi = \frac{\rho_{ma} - \rho_b}{\rho_{ma} - \rho_f} \quad (7)$$

$\rho_b$  چگالی سازند (چگالی کل)،  $\rho_{ma}$  چگالی خمیره و  $\rho_f$  چگالی سیال است.

### تعمیم و اجرای الگوریتم


در این پژوهش از مدل هیبریدی ACO<sub>R</sub>-BP جهت تخمین سرعت موج برشی از نگارهای تخلخل استفاده شده است. کد الگوریتم هیبریدی ACO<sub>R</sub>-BP به‌صورت یک مدل ریاضی در محیط نرم‌افزار MATLAB طراحی گردید. برای این منظور از نرم‌افزار MATLAB با نسخه 7.12 استفاده شد. مجموعه داده‌ها از دوچاه در میدان نفتی چشمه‌خوش بوده که توسط شرکت نفت مرکزی ایران تهیه شده است. موقعیت مکانی از چاه‌های مطالعاتی فاصله کافی را برای ارزیابی مدل داشته است. کاتالوگ داده‌ای تهیه شده شامل ۲۰۹۰ داده آموزشی از چاه مدل و ۱۱۰۰ داده از چاه آزمون می‌باشد. داده‌های چاه آزمون خود به دو دسته داده، شامل داده‌ای تست (تعداد ۶۰۰ داده) و داده‌های صحت‌سنجی (تعداد ۵۰۰ داده) تقسیم شده‌اند. تمام کاتالوگ داده‌ای برای ارزیابی و مقایسه بهتر، به روشی که لاروس مطرح نموده است [۲۶]، مطابق معادله‌های ۸ الی ۱۰ در بازه [L, H] که در این پژوهش معادل [۰, ۱] انتخاب گردید، نرمال‌سازی شدند. بازه انتخاب شده برای نرمال‌سازی داده‌ها مرسوم‌تر است.

$$X^* = mX_i - b \quad (8)$$

$$m = \frac{H-L}{\text{Max}(X) - \text{Min}(X)} \quad (9)$$

$$b = \frac{\text{Max}(X)L + \text{Min}(X)H}{\text{Max}(X) - \text{Min}(X)} \quad (10)$$

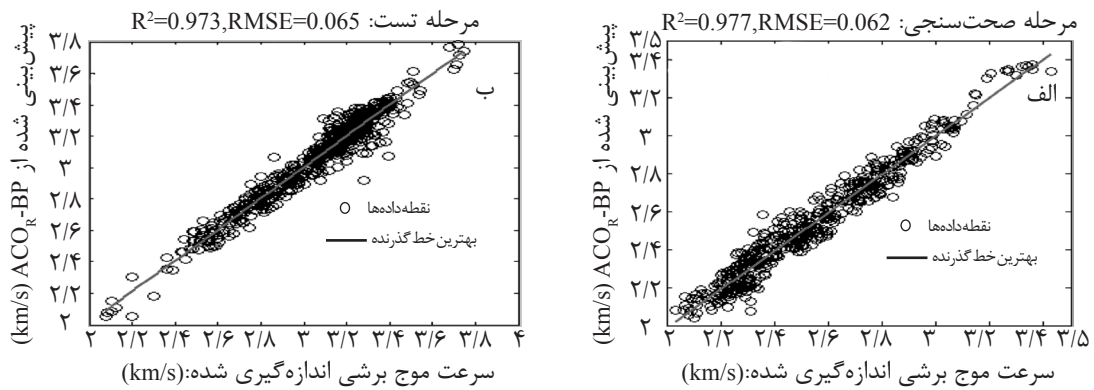
در این رابطه  $X^*$  متغیر نرمال‌سازی شده و  $X_i$  متغیر اصلی است. جهت اجرای مدل سه ورودی سرعت موج تراکمی، نگار نوترون و نگار چگالی در قالب ماتریس‌های ورودی و سرعت موج برشی حاصل از ابزار DSI به‌عنوان ماتریس خروجی مطلوب شبکه تعیین و برای انجام شبیه‌سازی اعمال می‌شوند.



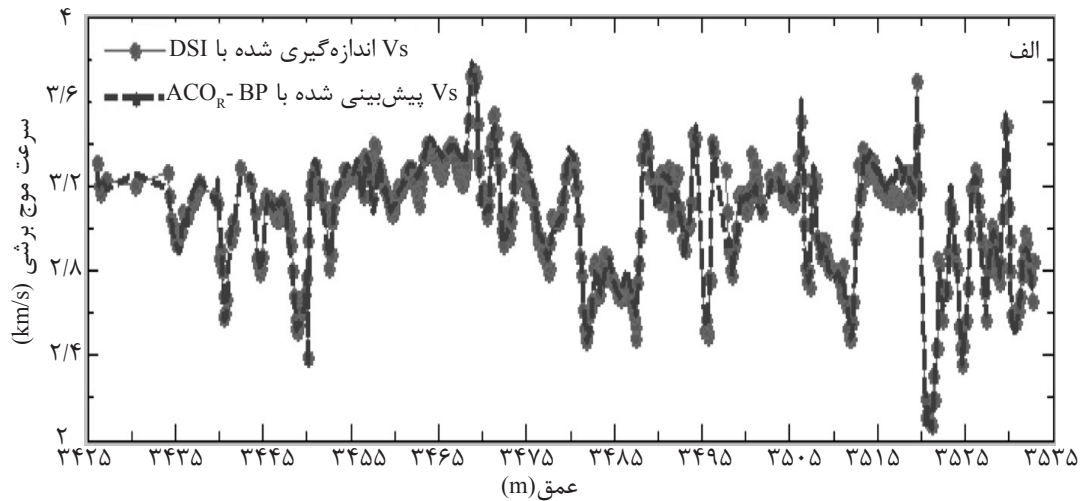
شکل ۶ نمایش گرافیکی نگارهای پتروفیزیکی مورد استفاده در این پژوهش.

جدول ۱ تنظیم شاخص‌های اصلی الگوریتم هیبریدی  $ACO_R$ -BP.


شاخص‌ها	تنظیمات
تابع توزیع احتمال نرمال	Gaussian Kernel PDF
(m): تعداد کل مورچه‌ها	۲۰۰
(k): تعداد بهترین جواب‌ها در solution archive	۱۰
(u): پارامتر تنظیم سرعت همگرایی جواب	۱۰
(q): پارامتر توزیع احتمال	۰/۵
(ε): حد پایینی از شاخص پراکندگی	۰/۰۰۰۵
ماکزیمم تکرار الگوریتم $ACO_R$	۵۰
نوع شبکه عصبی مصنوعی	BP-FF
الگوریتم آموزشی شبکه عصبی	LM
تعداد نرون در لایه پنهان	۸
تابع انتقال از لایه ۱ به ۲	TANSIG
تابع انتقال از لایه ۲ به ۳	PURELIN
ماکزیمم تکرار شبکه عصبی مصنوعی	۱۰۰




شکل ۷ مقادیر ضریب همبستگی بین  $V_s$  حاصل از  $ACO_R$ -BP و  $V_s$  اندازه‌گیری شده از DSI. الف) در مقابل داده‌های صحت‌سنجی و ب) در مقابل داده‌های تست.



مقایسه بین سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های تست



شکل ۸ الف) مقایسه نموداری بین  $V_s$  اندازه‌گیری شده توسط DSI و  $V_s$  برآورد شده توسط  $ACO_R$ -BP در داده‌های تست و ب) مقادیر خطای برآورد شده در تخمین دسته داده‌های تست.



شکل ۹ الف) مقایسه نموداری بین Vs اندازه‌گیری شده توسط DSI و Vs برآورد شده توسط ACO<sub>R</sub>-BP در داده‌های صحت‌سنجی و ب) مقادیر خطای برآورد شده در تخمین دسته داده‌های صحت‌سنجی.

### نتیجه‌گیری

کلونی مورچه و شبکه عصبی بهره می‌گیرد. روش هیبریدی ACO<sub>R</sub>-BP با فرار از مینیمم محلی و تسریع در همگرایی جواب در مینیمم مطلق، از هر یک از الگوریتم‌های جداگانه کلونی مورچه و شبکه عصبی مصنوعی، دقت پیش‌بینی بهتری دارد و قابلیت اطمینان بیشتری از شبیه‌سازی سرعت موج برشی ایجاد می‌نماید. با توجه به اینکه سازند آسماری در میدان مورد مطالعه، دارای سنگ‌شناسی غیریکنواخت بوده و شامل ۶ زون با سنگ‌های کربناته، ماسه‌سنگی و شیلی می‌باشد، عملکرد مدل بسیار موفق بوده است. این موضوع تأیید کننده این است که روش هیبریدی ACO<sub>R</sub>-BP قدرت تعمیم‌پذیری بالایی از لیتولوژی‌های مختلف دارد و بنابراین برای مخازن ناهمگن به خوبی پاسخگو خواهد بود. مقایسه نتایج حاصل از این پژوهش با یکی از اخیرترین الگوریتم‌های پیشنهاد شده که کاربرد آن در میدان چشمه‌خوش مورد بررسی قرار گرفته، نشان می‌دهد که روش هیبریدی ACO<sub>R</sub>-BP نسبت به الگوریتم هیبرید کلونی مورچه-منطق فازی (ACOFIS) که توسط نورافکن و کدخدائی

در این مطالعه با استفاده از روش هیبریدی ACO<sub>R</sub>-BP، سرعت موج برشی از مخزن آسماری در میدان چشمه‌خوش برآورد شد. داده‌های پتروفیزیکی (مقادیر سرعت موج تراکمی، نوترون و همچنین چگالی) به عنوان ورودی شبکه تعیین شدند. نتایج شبیه‌سازی از سرعت موج برشی توسط مدل ACO<sub>R</sub>-BP، مقادیر RMSE و R<sup>2</sup> را برای داده‌های تست به ترتیب ۰/۰۶۵ و ۰/۹۷۳ محاسبه نمود. این مقادیر برای داده‌های صحت‌سنجی نیز به ترتیب ۰/۰۶۲ و ۰/۹۷۷ محاسبه شده است. با مقایسه نتایج به دست آمده از بخش آزمون با داده‌های واقعی سرعت موج برشی که در شکل‌های ۸ و ۹ نشان داده شد، می‌توان به قطعیت داده‌های تخمین زده شده پی برد. این خود نشانگر اهمیت مدل‌سازی با استفاده از سیستم‌های هوشمند می‌باشد که جهت پی بردن به تغییرپذیری ویژگی‌های مخزنی، در بازه‌های طولانی بدون صرف هزینه و زمان زیاد، کاربرد دارد. روش به کار گرفته از نقاط قوت دو الگوریتم

این نگار پیشنهاد می‌دهد. لازم به ذکر است که اعتبار نتایج حاصل از روش‌های هوشمند منوط به اعتبار داده‌های ورودی و تجربه کاربر است و مقایسه باید براساس دسته داده‌های مشابه و تنظیمات تقریباً یکسان در الگوریتم‌ها صورت گیرد.

### تشکر و قدردانی

نویسندگان مقاله از مدیریت شرکت نفت مناطق مرکزی ایران به جهت تهیه داده‌های این پژوهش کمال سپاس‌گزاری و تشکر را دارند.

در سال ۲۰۱۵ ارائه شده [۱۱]، عملکرد بهتری در مرحله آموزش داشته و به واسطه آن نتایج شبیه‌سازی دقیق‌تری را نشان می‌دهد. همچنین هر دو الگوریتم هیبریدی در مقایسه با شبکه عصبی - فازی و سایر سیستم‌های هوشمند منفرد (شبکه عصبی، الگوریتم ژنتیک و الگوریتم کلونی مورچه) که نتایج آن‌ها در مرجع [۱۱] آورده شده، عملکرد موفق‌تری داشته‌اند. از این‌رو پژوهش حاضر روش هیبریدی  $ACO_R$ -BP را به‌عنوان یکی از بهینه‌ترین مدل‌های اخیر معرفی نموده و به‌کارگیری آن را برای برآورد سرعت موج برشی در چاه‌های فاقد

### منابع

- [1]. Moatazedian I., Rahimpour Bonab H., Kadkhodaie-Ilkhchi A., and Rajoli M. R., "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," J. Geopersia, Vol. 1, No. 1, pp. 1- 17, 2011.
- [2]. Lim, J. S., "Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea," J. Petrol. Sci. Eng., Vol. 49, pp. 182-192, 2005.
- [3]. Eskandari H., Rezaee M., Javaherian M., and Mohammadnia M., "Shear wave velocity estimation utilizing wireline logs for a carbonate reservoir, South-West Iran," Iranian Int. J. Sci., Vol. 4, pp. 451-464, 2003.
- [4]. Eskandari H., Rezaee M. R. and Mohammadnia M., "Application of multiple regression and artificial neural networks techniques to predict shear wave velocity from well log data for a carbonate reservoir, South-West Iran," Cseg Recorder, Vol. 29, pp. 42-48, 2004.
- [5]. Rezaee R., Kadkhodaie Ilkhchi A., and Barabadi A., "Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia," J. Petrol. Sci. Eng., Vol. 55, pp. 201-212, 2007.
- [6]. Rajabi M., Bohloli B., and Gholampour Ahangar E., "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)," Comput. Geosci., Vol. 36, No. 5, pp. 647-664, 2010.
- [7]. Asoodeh M., and Bagheripour P., "Neuro-fuzzy reaping of shear wave velocity correlations derived by hybrid genetic algorithm-pattern search technique," Cent. Eur. J. Geosci., Vol. 5, No. 2, pp. 272-284, 2013.
- [8]. Akhundi H., Ghafoori M., and Lashkaripour G. R., "Prediction of shear wave velocity using artificial neural network technique, multiple regression and petrophysical data: a case study in Asmari reservoir (SW Iran)," Open J. Geology, Vol. 4, pp. 303-313, 2014.

- [9]. Maleki, S., Moradzadeh, A., Ghavami Riabi, R., Gholami, R., and Sadeghzadeh, F., "Prediction of shear wave velocity using empirical correlations and artificial intelligence methods," NRIAG J. Astron. & Geophysics, Vol. 3, No.1, pp. 70-81, 2014.
- [10]. Bagheripour, P., Gholami, A., Asoodeh, M., and Vaezzadeh-Asadi, M., "Support vector regression based determination of shear wave velocity," J. Petrol. Sci. Eng., Vol. 125, pp. 95-99, 2015.
- [11]. Nourafkan, A., and Kadkhodaie-Ilkhchi, A., "Shear wave velocity estimation from conventional well log data using a hybrid ant colony-fuzzy inference system: A case study from Cheshmeh-Khosh oilfield," J. Petrol. Sci. Eng., Vol. 127, pp. 459-468, 2015.
- [۱۲]. هنرمند، ج.، "بررسی عوامل رسوب شناسی و دیاژنزی کنترل‌کننده خواص مخزنی در سازند آسماری میدان چشمه خوش،" رساله دکتری، دانشگاه تهران، ایران، ۱۳۹۱.
- [13]. Rastegarnia, M., and Kadkhodaie-Ilkhchi, A., "Permeability estimation from the joint use of stoneley wave velocity and support vector machine neural networks: a case study of the Cheshmeh Khush Field, South Iran," J. Geopersia, Vol. 3, No. 2, pp. 87-97, 2013.
- [14]. Hornik, K., Stinchcombe, M., and White, H., "Multilayer feedforward networks are universal approximators," Neural Networks, Vol. 2, pp. 359-366, 1989.
- [15]. Kulluk S., "A novel hybrid algorithm combining hunting search with harmony search algorithm for training neural networks," J. Oper. Res. Soc. Vol. 64, No. 5, pp. 748-761, 2013.
- [16]. Hosseini, Z., and Nakhaei, M., "Estimation of groundwater level using a hybrid genetic algorithm-neural network," Pollution, Vol. 1, No. 1, pp. 9-21, 2015.
- [17]. Hagan, M., and Menhaj, M., "Training Feedforward Networks with the Marquardt Algorithm," IEEE T. Neural Networ., Vol. 5, No. 6, pp. 989-993, 1994.
- [18]. Socha, K., "ACO for continuous and mixed-variable optimization," in M. Dorigo, M., Birattari, C., Blum, L.M., Gambardella, F., Mondada and T., Stutzle (eds), Ant Colony Optimization and Swarm Intelligence, 4<sup>th</sup> International Workshop, ANTS 2004. 3172 of LNCS: 25-36, 2004.
- [19]. Dorigo, M., Birattari, M., and Stutzle, T., "Ant Colony Optimization: Artificial Ants as a Computational Intelligence Technique," [www.cimat.mx/~jortega/MaterialDidactico/modestol10/.../ACO1.pdf](http://www.cimat.mx/~jortega/MaterialDidactico/modestol10/.../ACO1.pdf) , 2006.
- [20]. Box, G.E.P., and Muller, M.A., "A note on the generation of random normal deviates. Annals," Math. Stat., Vol. 29, pp. 610-611, 1958.
- [21]. Marsaglia, G., and Tsang, W.W., "The ziggurat method for generating random variables," J. Stat. Softw., Vol. 5, No. 8, pp. 1-7, 2000.
- [22]. Socha, K., and Blum, C., "Hybrid ant algorithms applied to feed-forward neural network training: An application to medical pattern classification," NCA. Vol. 16, No. 3, pp. 235-248, 2007.
- [23]. Socha, K., and Dorigo, M., "Ant colony optimization for continuous domains," EJOR. Vol. 185, No. 3, pp. 1155-1173, 2008.
- [24]. Ashena, R., and Moghadasi, J., "Bottom hole pressure estimation using evolved neural networks by real coded ant colony optimization and genetic algorithm," J. Petrol. Sci. Eng., Vol. 77, pp. 375-385, 2011.

- [25]. Tabatabaei S. M. E., Kadkhodaie-Ilkhchi A., Hosseini Z., and Asghari Moghaddam A., "A hybrid stochastic-gradient optimization to estimating total organic carbon from petrophysical data: A case study from the Ahwaz oilfield, SW Iran," J. Petrol. Sci. Eng., Vol. 127, pp. 35-43, 2015.
- [26]. Larose D. T., "Discovering knowledge in data: an introduction to data mining," 2<sup>nd</sup> edition, Jhon Wiley & Sons Inc, 240 p., 2014.
- [۲۷]. عبدی‌زاده، ه.، کدخدائی، ع.، شایسته، م.، "ساخت نگار کل کربن آلی (TOC) از داده‌های چاه‌پیمایی به کمک تکنیک الگوریتم ژنتیک در میدان نفتی اهواز،" پژوهش‌های چینه‌نگاری و رسوب‌شناسی، جلد ۲۸، شماره ۴، صفحات ۹۵-۱۱۰، ۱۳۹۳.
- [28]. Kamali M. R., and Mirshady A. A., "Total organic carbon content determined from well logs using  $\Delta \log R$  and neuro fuzzy techniques," J. Petrol. Sci. Eng., Vol. 45, pp. 141-148, 2004.
- [29]. Schlumberger "Log interpretation: principles/applications," Schlumberger Wireline and Testing. 225 Schlumberger Drive, Sugar Land, Texas No. 77478, 1989.