

بررسی و مقایسه روش‌های مرسوم تخمین سرعت موج برشی از روی داده‌های چاه‌پیمایی در یکی از مخازن ماسه‌سنگی جنوب ایران

احسن لینی^۱، حسین خیرالهی^۲ و نوید شاد منامن^{۳*}

^۱ دانشجوی دکتری مهندسی اکتشاف نفت، دانشگاه صنعتی سهند، تبریز، ایران

^۲ دانشجوی کارشناسی ارشد مهندسی نفت، دانشگاه صنعتی سهند، تبریز، ایران

^۳ عضو هیات علمی دانشگاه صنعتی سهند، تبریز، ایران

(دریافت: ۱۴۰۰/۰۹/۲۶، پذیرش: ۱۴۰۱/۰۱/۲۹)

چکیده

تخمین سرعت امواج فشارشی و برشی در صنعت نفت از اهمیت بیشتری برخوردار است. برخلاف سرعت موج تراکمی، سرعت موج برشی در تمامی چاه‌های یک میدان به دلیل تحمیل هزینه‌های بیشتر اندازه‌گیری نمی‌شود. بنابراین در صنعت نفت و گاز استفاده از روشی که با هزینه کمتر و دقت بیشتر سرعت موج برشی را تخمین بزند، اجتناب‌ناپذیر است. در این مطالعه، ابتدا برای تخمین سرعت موج برشی در یک چاه، همبستگی سایر نگاره‌های موجود در آن چاه (یعنی نگاره‌های صوتی، چگالی، تخلخل نوترون، مقاومت، پرتو گاما، حجم دولومیت، حجم کوارتز و اشباع آب) با سرعت موج برشی مورد بررسی قرار گرفت و مشخص شد که نگاره‌های سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز همبستگی بیشتری با سرعت موج برشی دارند و این نگاره‌ها به‌عنوان ورودی برای تخمین سرعت موج برشی با استفاده از روش‌های مختلف انتخاب شدند. سپس از میان روش‌های مختلف، روشی که بهترین تطابق را با داده‌های واقعی موج برشی داشته باشد، به‌عنوان روش بهینه انتخاب شده و از این روش برای تخمین سرعت موج برشی در سایر چاه‌ها که فاقد نگاره موج برشی هستند استفاده می‌گردد. در این مقاله از روش رگرسیون چندگانه و الگوریتم‌های یادگیری ماشین (رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق) برای تخمین سرعت موج برشی استفاده شد. نتایج نشان می‌دهند که روش شبکه عصبی عمیق با داشتن ۹۷ درصد همبستگی بین داده‌های سرعت موج برشی واقعی و تخمینی نسبت به سایر روش‌ها جواب بهتری ارائه داده است. بنابراین برای تخمین سرعت موج برشی در سایر چاه‌ها که فاقد نگاره موج برشی هستند از روش پیشنهادشده در این مطالعه (شبکه عصبی عمیق) استفاده شد. برای صحت‌سنجی نتایج حاصل از شبکه عصبی عمیق در چاه‌های فاقد سرعت موج برشی، از مدل تجربی کاستاگنا استفاده شد که نتایج نشان‌دهنده تطابق خوبی میان این دو مدل است.

واژه‌های کلیدی: سرعت موج برشی، رگرسیون چندگانه، رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی، شبکه عصبی عمیق

۱ مقدمه

توصیف پارامترهای ژئوفیزیکی مخازن هیدروکربونی مانند سرعت موج برشی و سرعت موج تراکمی از اهمیت زیادی در صنعت نفت و گاز برخوردار است (نورافکن و کدخدایی ایلخچی، ۲۰۱۵). با استفاده از سرعت موج برشی و تراکمی می‌توان به اطلاعات مهمی از مخزن پی برد. به‌عنوان مثال، نسبت پواسون یکی از روش‌های تشخیص لیتولوژی است که به‌صورت تابعی از سرعت موج برشی و تراکمی تعریف می‌شود (آوست و همکاران، ۲۰۱۰؛ وایلی و همکاران، ۱۹۸۵). علاوه بر نسبت پواسون، سایر پارامترهای ژئوفیزیکی سازند نظیر مدول بالک، مدول برشی و مدول یانگ را می‌توان با استفاده از سرعت امواج تراکمی و برشی محاسبه کرد (اسکندری و همکاران، ۲۰۰۴). اندازه‌گیری سرعت موج برشی به‌صورت مستقیم در آزمایشگاه از روی مغزه‌های حفاری و یا از طریق اندازه‌گیری به‌کمک دستگاه (Dipole DSI Shear Sonic imager) انجام می‌شود. این دستگاه یک ابزار نسبتاً جدید برای اندازه‌گیری سرعت موج برشی است که اطلاعات آن برای تمامی چاه‌ها مخصوصاً چاه‌های قدیمی در دسترس نیست. از طرفی اندازه‌گیری سرعت موج برشی با استفاده از مغزه‌های حفاری بسیار پر هزینه و زمان‌بر است. همچنین تعمیم داده‌های حاصل از مغزه به داده‌های لاگ آسان نبوده و نیازمند بزرگ‌نمایی مقیاس داده‌های مغزه است (حسینی و همکاران، ۱۳۹۵). روش‌های مرسوم تخمین سرعت موج برشی را در حالت کلی می‌توان به سه دسته تقسیم‌بندی کرد. دسته اول روش‌های تجربی هستند که با استفاده از داده‌های آزمایشگاهی و ارتباط میان موج تراکمی و برشی در لیتولوژی‌های گوناگون ارائه شده‌اند. از جمله روابط تجربی برای تخمین سرعت موج برشی می‌توان به روابط کاستاگنا، پیکت، گرینبرگ و کاستاگنا و بروچر اشاره کرد (کاستاگنا و همکاران، ۱۹۸۵؛ پیکت، ۱۹۸۳؛ گرینبرگ و کاستاگنا، ۱۹۹۲؛ بروچر، ۲۰۰۵). دسته دوم روش‌های هوشمند و دسته سوم استفاده از مدل‌های فیزیک سنگ می‌باشد. امروزه استفاده از روش‌های هوشمند برای تخمین سرعت موج برشی در صنعت نفت

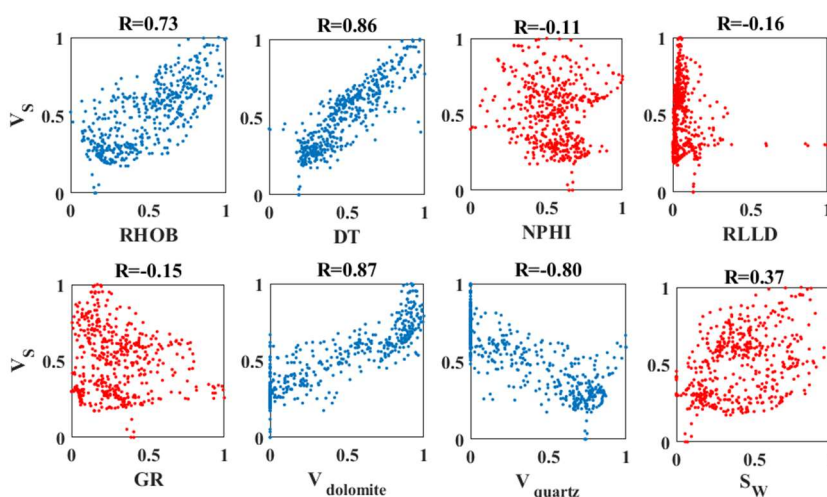
و گاز مورد توجه ویژه قرار گرفته است. در سالیان اخیر، کارهای زیادی در زمینه تخمین سرعت موج برشی با استفاده از روش‌های هوشمند انجام شده است. نورافکن و همکاران (۱۳۹۴) با استفاده از الگوریتم کلونی مورچه سرعت موج برشی را تخمین زدند. آخوندی و همکاران (۲۰۱۴) سرعت موج برشی را با استفاده از شبکه‌های عصبی مصنوعی، رگرسیون چندگانه و داده‌های پتروفیزیکی تخمین زدند. نتایج حاصل از مطالعات آن‌ها نشان می‌دهد که روش شبکه عصبی مصنوعی نسبت به روش‌های دیگر جواب بهتری ارائه داده است. معتضدیان و همکاران (۲۰۱۱) سرعت موج برشی و تراکمی را تخمین زدند و به این نتیجه رسیدند که الگوریتم ژنتیک می‌تواند به‌عنوان یک روش کارآمد، سریع و مقرون‌به‌صرفه برای پیش‌بینی داده‌های سرعت موج برشی و تراکمی از داده‌های چاه‌پیمایی در نظر گرفته شود. پرویزی و همکاران (۲۰۱۵) از روش شبکه عصبی مصنوعی برای تخمین سرعت موج برشی استفاده کردند. آنمانگلی و همکاران (۲۰۱۹) با استفاده از روش ماشین بردار پشتیبان و رگرسیون چندگانه به تخمین سرعت موج برشی پرداختند. ونگ و پنگ (۲۰۱۹) با استفاده از الگوریتم‌های یادگیری ماشین سرعت موج برشی را تخمین زدند. هدف از این مطالعه، تخمین سرعت موج برشی از روی داده‌های چاه‌پیمایی با استفاده از روش‌های مختلف است. در این مطالعه، برای تخمین سرعت موج برشی در یک چاه، همبستگی این ویژگی با سایر نگاره‌های موجود در آن چاه (یعنی نگاره‌های صوتی، چگالی، تخلخل نوترون، مقاومت، پرتو گاما، حجم دولومیت، حجم کوارتز و اشباع آب) بررسی شده و نگاره‌هایی که بیشترین همبستگی را با سرعت موج برشی داشته باشند به‌عنوان ورودی برای تخمین انتخاب می‌شوند. در مرحله بعد، سرعت موج برشی با استفاده از روش‌های رگرسیون چندگانه، رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق تخمین زده شده و دقت و صحت هر یک از این روش‌ها مورد مقایسه قرار می‌گیرد. از میان روش‌های مختلف،

موج برشی اندازه‌گیری شده است. بنابراین سرعت موج برشی در چاه شماره ۷ از روی سایر نگاره‌های مرتبط با آن توسط روش‌های مختلف تخمین زده می‌شود. روشی که بهترین نتیجه را ارائه دهد به‌عنوان روش بهینه انتخاب شده و از این روش برای تخمین سرعت موج برشی در چاه‌های دیگر که فاقد سرعت موج برشی هستند، استفاده می‌شود. مطابق با شکل ۱، همبستگی نگاره‌های مختلف با سرعت موج برشی در چاه شماره ۷ بررسی شده است. همان‌طور که در شکل ۱ مشاهده می‌شود نگاره‌های سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز بیشترین همبستگی را با سرعت موج برشی دارند. بنابراین از این نگاره‌ها به‌عنوان ورودی برای تخمین استفاده می‌شود.

روشی که بهترین تطابق را با داده‌های واقعی موج برشی داشته باشد به‌عنوان روش بهینه انتخاب شده و از این روش برای تخمین سرعت موج برشی در سایر چاه‌ها که فاقد نگاره موج برشی هستند استفاده می‌شود. برای صحت‌سنجی نتایج حاصل از روش بهینه، از مدل تجربی کاستاگنا استفاده می‌شود.

۲ معرفی داده‌ها

در این مطالعه از داده‌های چاه‌پیمایی یکی از میدانی نفتی خلیج‌فارس استفاده شده است. این میدان نفتی در شمال غربی خلیج‌فارس و در فروافتادگی دزفول قرار دارد (سلیمانی و همکاران، ۲۰۱۳). از هفت چاه موجود در این میدان، فقط در یک چاه (چاه شماره ۷) سرعت




شکل ۱. همبستگی سرعت موج برشی با نگاره‌های مختلف در چاه شماره ۷. نگاره‌هایی که همبستگی بیشتری با سرعت موج برشی دارند، با رنگ آبی نشان داده شده است.

محدودیت داده میدانی باعث شده است که داده‌های چاه شماره ۷ به داده‌های آموزشی، آزمایشی و اعتبارسنجی تقسیم‌بندی شود. به‌صورت تصادفی در همه روش‌های استفاده شده در این مطالعه، ۷۰ درصد داده‌ها برای آموزش استفاده شده است. نمونه‌های تصادفی انتخاب شده برای آموزش در همه روش‌ها یکسان است. همچنین ۳۰ درصد داده‌های باقی‌مانده برای آزمایش انتخاب شده است تا دقت و صحت تخمین افزایش یابد.

مطابق با شکل ۱، نگاره‌های سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز به‌دلیل داشتن همبستگی قوی با سرعت موج برشی در چاه شماره ۷ به‌عنوان ورودی برای تخمین انتخاب می‌شوند. سایر نگاره‌ها به‌دلیل داشتن همبستگی ضعیف به‌عنوان ورودی انتخاب نشده‌اند. با توجه به این‌که فقط در چاه شماره ۷ سرعت موج برشی اندازه‌گیری شده است و در شش چاه دیگر این ویژگی ثبت نشده است؛ لذا این

عملکرد شبکه در حین آموزش سنجیده شود تا شبکه بیش‌برازش (Over Fitting) نکند. در شکل ۲ هیستوگرام داده‌های آموزشی، آزمایشی و اعتبارسنجی مربوط به چاه شماره ۷ نشان داده شده است.

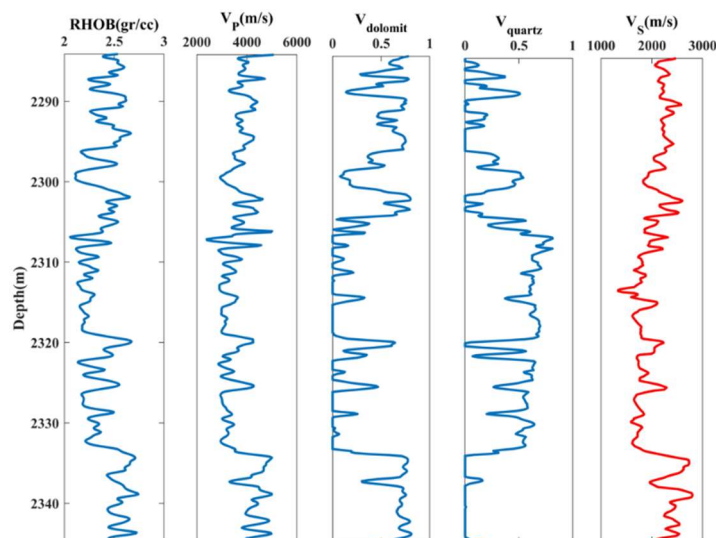
با توجه به این‌که در شبکه عصبی مصنوعی داده‌ها باید به سه دسته داده‌های آموزشی، آزمایشی و اعتبارسنجی تقسیم بشوند، بنابراین از ۳۰ درصد داده‌های آزمایشی، ۱۵ درصد به صورت تصادفی به عنوان داده‌های اعتبارسنجی انتخاب شدند. دلیل این کار این است که



شکل ۲. هیستوگرام داده‌های آموزشی، آزمایشی و اعتبارسنجی در چاه شماره ۷. محور قائم فراوانی و محور افقی سرعت موج برشی را نشان می‌دهد.

شده و برای تخمین سرعت موج برشی در چاه‌های دیگر که فاقد این ویژگی هستند، استفاده می‌شود. در شکل ۳، نگاره‌های استفاده شده به عنوان ورودی برای تخمین و همچنین پارامتر هدف (سرعت موج برشی) در چاه شماره ۷ نشان داده شده است.

پس با استفاده از نگاره‌های سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز، سرعت موج برشی توسط روش‌های مختلف در چاه شماره ۷ تخمین زده شده و با داده‌های واقعی سرعت موج برشی مقایسه می‌شود. تخمین حاصل از روشی که بهترین تطابق را با داده‌های واقعی داشته باشد، به عنوان روش بهینه انتخاب



شکل ۳. ورودی‌های استفاده شده برای تخمین سرعت موج برشی در چاه شماره ۷. ورودی‌ها از چپ به راست به ترتیب شامل چگالی، سرعت موج تراکمی، حجم دولومیت و حجم کوارتز (لاگ‌های آبی) و خروجی (هدف) سرعت موج برشی (لاگ قرمز) است.

برای تخمین سرعت موج برشی در چاه‌های دیگر که فاقد این ویژگی هستند استفاده می‌شود. در ادامه توضیح مختصری از هر روش آورده شده است.

۳-۱ رگرسیون چندگانه (Multiple Regression)

روش رگرسیون چندگانه از روش‌های متداول در تخمین سرعت موج برشی است. در روش رگرسیون چندگانه، سرعت موج برشی براساس روابطی خطی از سایر لاگ‌های مرتبط تخمین زده می‌شود. از این روش برای برازش داده‌ها به صورت تابعی خطی از ویژگی‌ها استفاده می‌شود و برای تعیین ضرایب معادله از روش گرادیان کاهشی و با حداقل کردن تابع خطا استفاده می‌شود (خوری و همکاران، ۱۹۹۷). در این مطالعه از مدل خطی و برهم‌کنش رگرسیون چندگانه استفاده شده است. مدل خطی و برهم‌کنش به ترتیب به صورت رابطه (۱) و (۲) نوشته می‌شود:

مدل خطی (Linear Model):

$$y = a_0 + \sum_{i=1}^n a_i x_i, \quad (1)$$

مدل برهم‌کنش (Interaction Model):

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n b_{ij} x_i x_j, \quad (2)$$

که در روابط (۱) و (۲)، x و y به ترتیب داده‌های ورودی و پارامتر خروجی هستند و a_i و b_{ij} ضرایب ورودی و a_0 عرض از مبدأ را نشان می‌دهد.

۳-۲ رگرسیون بردار پشتیبان SVR (Support Vector Regression)

برای ایجاد یک رابطه دقیق بین داده‌های ورودی و داده‌های خروجی می‌توان از رگرسیون بردار پشتیبان به عنوان یک الگوریتم مناسب استفاده کرد. این الگوریتم در سال ۱۹۹۲ توسط ولادیمیر واپنیک معرفی شده است. هدف اصلی این الگوریتم یافتن تابعی برای برازش داده‌ها با انحراف و خطای کمتر است (واپنیک، ۱۹۹۵).

مخزن مورد مطالعه در این مقاله، از نظر سنی معادل بخش ماسه‌سنگی اهواز است و یکی از بخش‌های مخزنی شناخته شده ناحیه خلیج فارس را تشکیل می‌دهد. این مخزن به طور عمده از ماسه‌سنگ‌های کوارتزی با سیمان دولومیتی همراه با لایه‌های نازک از دولومیت‌های ماسه‌ای تشکیل شده است. سازند مورد مطالعه از سه رخساره تخریبی شامل شیل، ماسه سست و ماسه سیمانه تشکیل شده است. در این سازند وجود لایه‌های ماسه‌ای متخلخل شرایط مناسبی برای تجمع هیدروکربن ایجاد کرده است. این سازند از نظر کیفیت مخزنی به سه زون تقسیم می‌شود. مطابق با

شکل ۳، زون ۱ از عمق ۲۲۸۵ تا ۲۳۰۶ متر، زون ۲ از عمق ۲۳۰۶ تا ۲۳۳۰ و زون ۳ از عمق ۲۳۳۰ شروع می‌شود. از بین این زون‌ها، زون ۲ از کیفیت مخزنی بهتری برخوردار است. این زون‌ها توسط واحدهای شیلی از همدیگر جدا می‌شوند. از زون ۳ به پایین بر مقدار دولومیت‌های ماسه‌ای افزوده می‌شود. همان‌طور که در شکل ۳ نشان داده شده است، از چهار ورودی (سرعت موج تراکمی، چگالی، حجم دولومیت و کوارتز) برای تخمین سرعت موج برشی استفاده شده است. علت انتخاب حجم دولومیت و کوارتز به عنوان ورودی برای تخمین سرعت موج برشی این است که مطابق با شکل ۱ این دو نگار همبستگی بیشتری با نگار هدف دارند.

۳ روش کار

برای تخمین سرعت موج برشی از روش‌های مختلفی (رگرسیون چندگانه، رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق) در این مطالعه استفاده شده است. در همه روش‌های استفاده شده در این مطالعه، سرعت موج برشی از روی نگاره‌های مرتبط با آن (چگالی، سرعت موج تراکمی، حجم کوارتز و حجم دولومیت) در چاه شماره ۷ تخمین زده می‌شود. تخمین حاصل از روشی که بهترین تطابق را با داده‌های واقعی سرعت موج برشی در چاه شماره ۷ داشته باشد، به عنوان روش بهینه انتخاب شده سپس از این روش

قابل تنظیم در لایه‌های اول و چهارم قرار دارند و پارامترهای لایه‌های دیگر ثابت هستند (جانگ، ۱۹۹۳).


۳-۴ شبکه عصبی عمیق (DANN (Deep Artificial Neural Network)

شبکه عصبی روشی مبتنی بر رفتار مغز انسان است که بر پایه اتصال به هم پیوسته چندین واحد پردازشی (نرون) ساخته می‌شود. یک شبکه عصبی مصنوعی معمولاً متشکل از لایه ورودی، لایه میانی (پنهان) و لایه خروجی است که توسط نرون‌ها مجموعه ورودی را به مجموعه خروجی ربط می‌دهند. نرون‌ها مهم‌ترین عنصر شبکه عصبی بوده و یک واحد محاسباتی هستند. در شکل ۴، شماتیک شبکه عصبی عمیق طراحی شده برای تخمین سرعت موج برشی در این مطالعه نمایش داده شده است. همان‌طور که در شکل ۴ مشاهده می‌شود، از دو لایه پنهان با ۱۵ نرون در هر لایه پنهان استفاده شده است. همچنین از تابع فعال‌سازی سیگموئیدی و از الگوریتم یادگیری لونیگ مارکوات برای آموزش شبکه عصبی استفاده شده است.

الگوریتم رگرسیون بردار پشتیبان یک روش نسبتاً جدید برای انجام تخمین در مسائل رگرسیون است. این الگوریتم به نوع تابع کرنل که توسط کاربر انتخاب می‌شود وابسته است. تابع کرنل تابعی از فضای ورودی است (نعیمی و همکاران، ۲۰۱۴). در این مقاله از روش رگرسیون بردار پشتیبان با تابع کرنل خطی برای تخمین سرعت موج برشی استفاده شده است.

۳-۳ شبکه عصبی فازی تطبیقی ANFIS (Adaptive Neuro-Fuzzy Inference System)

روش شبکه عصبی فازی در سال ۱۹۹۳ توسط جانگ پیشنهاد شده است. در این روش برای آموزش شبکه از روش‌های ترکیبی و پس‌انتشار خطا استفاده می‌شود. روش پس‌انتشار خطا یکی از رایج‌ترین روش در آموزش شبکه‌های عصبی مصنوعی است که از مقادیر خطا بین داده‌های واقعی و داده‌های پیش‌بینی‌شده در طول آموزش برای تغییر وزن‌ها به منظور تعیین مقادیر بهینه استفاده می‌کند. شبکه فازی عصبی از پنج لایه تشکیل شده است. این لایه‌ها به ترتیب شامل لایه فازی، عملگر، استلزام، جمع‌بندی و لایه خروجی است. پارامترهای



شکل ۴. شماتیک شبکه عصبی عمیق طراحی شده برای تخمین سرعت موج برشی.

استفاده شده است. در این مدل‌ها، سرعت موج برشی به صورت تابع خطی از سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز تخمین زده شد. رابطه به دست آمده برای مدل خطی و برهم‌کنش در چاه شماره ۷ به صورت روابط (۳) و (۴) می‌باشند:

مدل خطی:

$$V_S = 1135.8 - 176.95(RHOB) + 0.25(V_P) + 874.43(VOL_{Do}) + 356.79(VOL_{Qu}), \quad (3)$$

۴ بحث و نتایج

۱-۴ تخمین سرعت موج برشی با استفاده از رگرسیون چندگانه

در این مقاله، سرعت موج برشی از روی داده‌های سرعت موج تراکمی، چگالی، حجم دولومیت و حجم کوارتز با استفاده از روش‌های مختلف تخمین زده شد. اولین روش استفاده شده، روش رگرسیون چندگانه است. روش رگرسیون چندگانه مدل‌های مختلفی را شامل می‌شود که در این مطالعه از مدل خطی و مدل برهم‌کنش

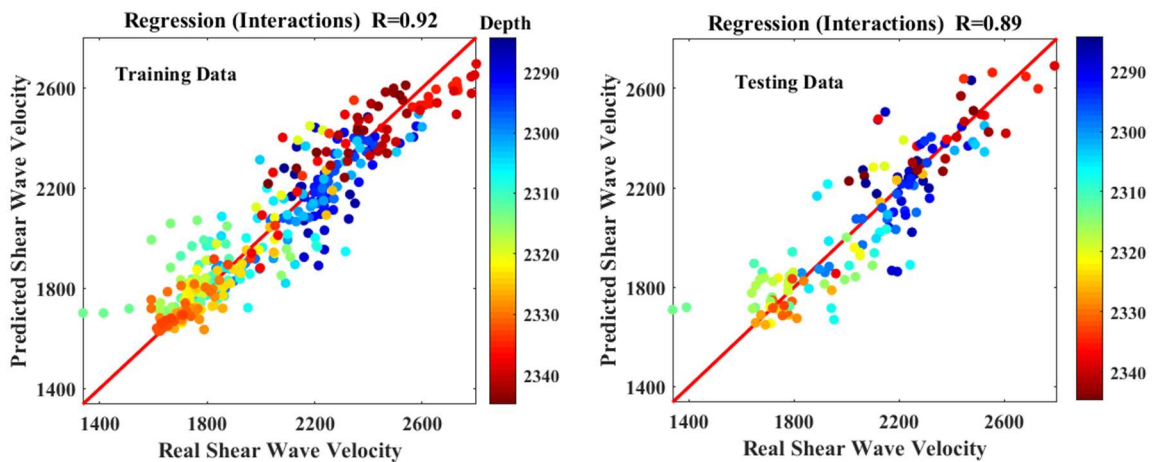
مدل برهم‌کنش:

شماره ۷ برای آموزش و ۳۰ درصد باقی‌مانده برای آزمایش مدل انتخاب شد تا دقت و صحت تخمین افزایش یابد. همبستگی بین داده‌های واقعی سرعت موج برشی و داده‌های تخمین‌زده‌شده در چاه شماره ۷ با استفاده از مدل خطی در داده‌های آموزشی و آزمایشی به ترتیب ۹۱ و ۸۸ درصد، و در مدل برهم‌کنش به ترتیب ۹۲ و ۸۹ درصد است. نتایج حاصل از مدل برهم‌کنش در شکل ۵ نشان داده شده است.

همبستگی بین داده‌های واقعی و تخمینی در مدل برهم‌کنش بیشتر از مدل خطی است. دلیل آن احتمالاً این است که در روش رگرسیون با اضافه کردن عبارت و پیچیده کردن مدل، مقدار خطای نسبی کاهش می‌یابد و باعث بهبود عملکرد مدل می‌گردد.

$$\begin{aligned}
 V_S &= 69.15 - 794.48(RHOB) \\
 &- 0.061(V_P) + 7796(VOL_{D_o}) \\
 &+ 7931.27(VOL_{Q_u}) \\
 &+ 0.44(RHOB)V_P \\
 &- 1552.4(RHOB)VOL_{D_o} \\
 &- 1627(RHOB)VOL_{Q_u} \\
 &- 0.97(V_P)VOL_{D_o} \\
 &- 1.10(V_P)VOL_{Q_u} \\
 &+ 206.28(VOL_{D_o})VOL_{Q_u}
 \end{aligned} \quad (4)$$

که در روابط (۳) و (۴)، $RHOB$ ، V_P ، VOL_{D_o} و VOL_{Q_u} به ترتیب چگالی، سرعت موج تراکمی، حجم دولومیت و حجم کوارتز را نشان می‌دهند. در مدل خطی و برهم‌کنش، به صورت تصادفی ۷۰ درصد داده‌های چاه



شکل ۵. همبستگی بین داده‌های سرعت موج برشی واقعی و تخمین‌زده‌شده با استفاده از روش رگرسیون چندگانه (مدل برهم‌کنش) در چاه شماره ۷.

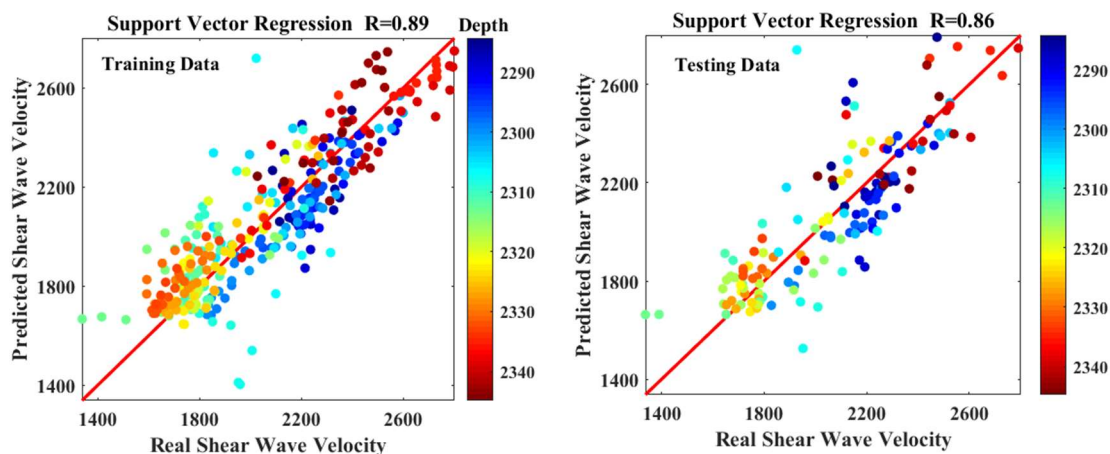
چندگانه، در این روش نیز به صورت تصادفی ۷۰ درصد داده‌های چاه شماره ۷ برای آموزش و ۳۰ درصد باقی‌مانده برای آزمایش روش انتخاب شد. نمونه‌های انتخاب شده برای آموزش و آزمایش در روش‌های رگرسیون چندگانه، رگرسیون بردار پشتیبان و شبکه فازی تطبیقی یکسان است. روش رگرسیون بردار پشتیبان با تابع کرنل خطی به ترتیب ۸۹ و ۸۶ درصد همبستگی در داده‌های آموزشی و آزمایشی در چاه شماره ۷ ارائه داده است (شکل ۶). نتایج حاصل از روش

۲-۴ تخمین سرعت موج برشی با استفاده از رگرسیون بردار پشتیبان

پس از تخمین سرعت موج برشی با استفاده از مدل‌های مختلف رگرسیون چندگانه، از الگوریتم‌های یادگیری ماشین (رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق) استفاده شد تا نتایج حاصل از الگوریتم‌های یادگیری ماشین با نتایج حاصل از روش‌های رگرسیونی مورد بررسی و مقایسه قرار گیرد و روش بهینه انتخاب شود. مشابه با روش رگرسیون

پشتیبان، از سایر الگوریتم‌های یادگیری ماشین (روش شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق) استفاده شد.

رگرسیون بردار پشتیبان به‌عنوان یک الگوریتم یادگیری ماشین نشان می‌دهد که این روش نسبت به مدل‌های رگرسیون چندگانه جواب بهتری ارائه نداده است. بنابراین در این مقاله، علاوه بر روش رگرسیون بردار

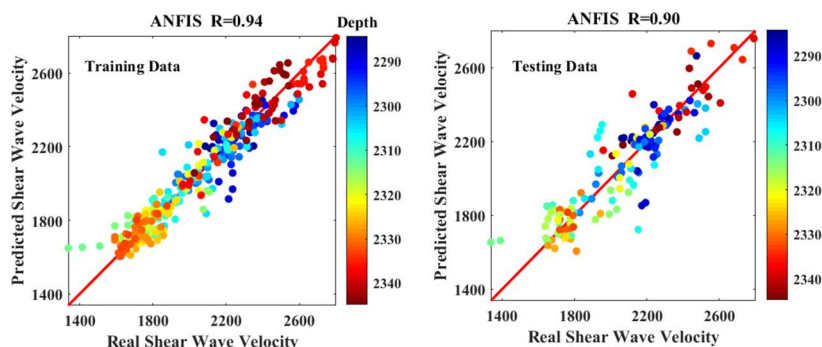


شکل ۶. همبستگی بین داده‌های سرعت موج برشی واقعی و تخمین‌زده‌شده با استفاده از روش رگرسیون بردار پشتیبان در چاه شماره ۷.

قبلی است. این روش با ارائه ۹۴ درصد همبستگی در داده‌های آموزشی و ۹۰ درصد در داده‌های آزمایشی در چاه شماره ۷ نسبت به دو روش قبلی (رگرسیون چندگانه و رگرسیون بردار پشتیبان) جواب بهتری ارائه داده است (شکل ۷).

۳-۳ تخمین سرعت موج برشی با استفاده از شبکه عصبی فازی تطبیقی

دومین الگوریتم یادگیری ماشین که در این مقاله برای تخمین سرعت موج برشی استفاده شد، روش شبکه عصبی فازی تطبیقی است. تقسیم‌بندی داده‌های آموزشی و آزمایشی در این روش دقیقاً مشابه با دو روش



شکل ۷. همبستگی بین داده‌های سرعت موج برشی واقعی و تخمین‌زده‌شده با استفاده از روش شبکه عصبی فازی تطبیقی در چاه شماره ۷.

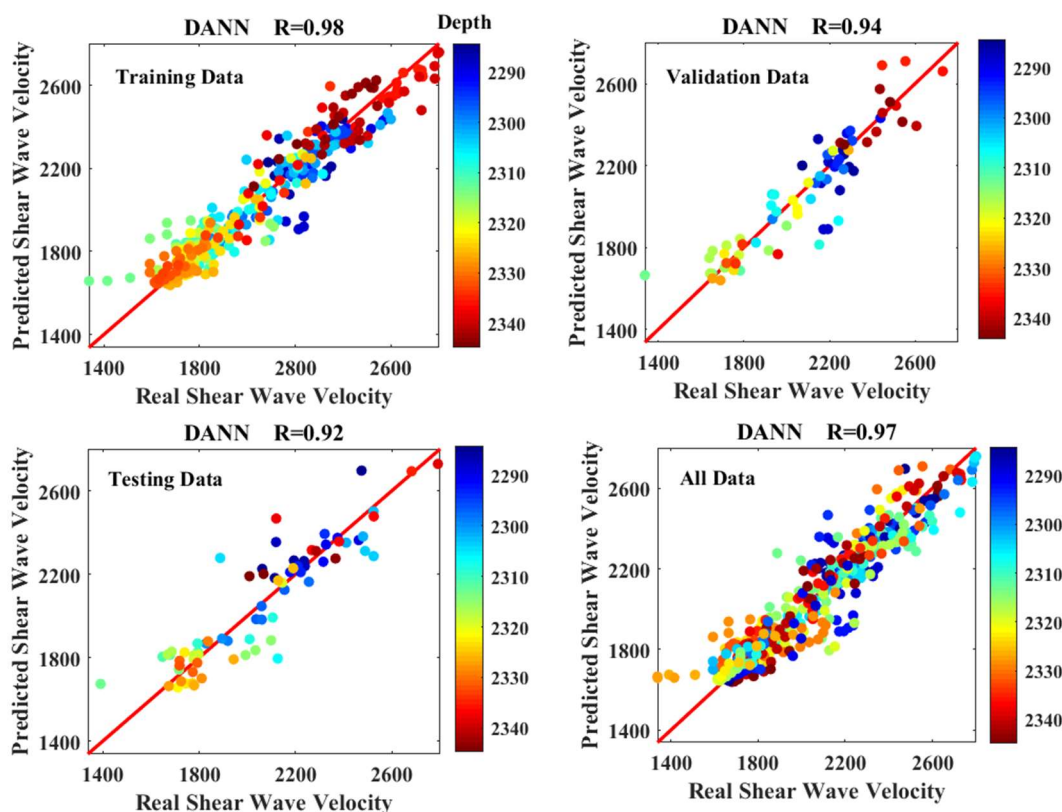
بشوند، مانند روش‌های قبلی ۷۰ درصد داده‌های چاه شماره ۷ به‌صورت تصادفی برای آموزش و از باقی‌مانده داده‌ها ۱۵ درصد برای آزمایش و ۱۵ درصد دیگر برای اعتبارسنجی انتخاب شدند. دلیل اختصاص داده برای

۳-۴ تخمین سرعت موج برشی با استفاده از شبکه عصبی عمیق

با توجه به این‌که در شبکه عصبی داده‌ها باید به سه دسته داده‌های آموزشی، آزمایشی و اعتبارسنجی تقسیم

داده‌های آموزشی، ۹۴ درصد در داده‌های اعتبارسنجی و ۹۲ درصد در داده‌های آزمایشی است. این روش نسبت به همه روش‌های استفاده شده در این مطالعه جواب بهتری ارائه داده است (شکل ۸ و شکل ۹).

اعتبارسنجی در شبکه عصبی این است که عملکرد شبکه در حین آموزش سنجیده شود تا شبکه بیش‌برازش (Over Fitting) نکند. همبستگی بین سرعت موج برشی واقعی و تخمین‌زده‌شده با استفاده از روش شبکه عصبی عمیق در چاه شماره ۷، ۹۸٫۷ درصد در



شکل ۸. همبستگی بین داده‌های سرعت موج برشی واقعی و تخمین‌زده‌شده با استفاده از شبکه عصبی عمیق در چاه شماره ۷.

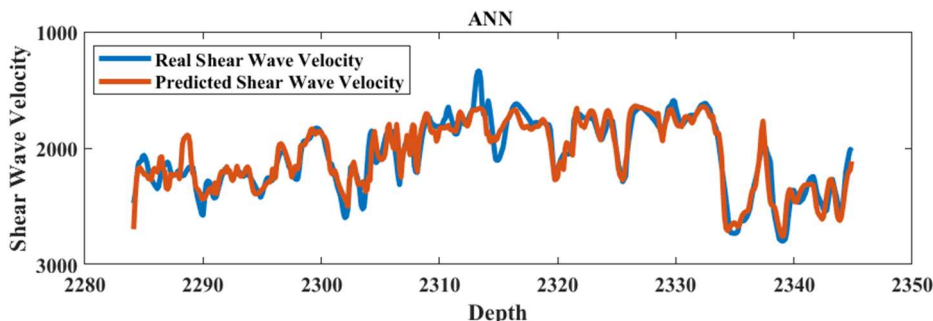
موج برشی و تراکمی رابطه تجربی کاستاگنا محاسبه شد. رابطه کاستاگنا در چاه شماره ۷ در شکل ۱۰ آورده شده است که سرعت موج برشی به صورت تابعی از سرعت موج تراکمی محاسبه شده است. مطابق با شکل ۱۰ مدل تجربی کاستاگنا ۸۶ درصد همبستگی بین سرعت موج برشی واقعی و تخمینی در چاه شماره ۷ ارائه داده است.

در شکل ۱۱ نتایج تخمین سرعت موج برشی آورده شده است. در چاه ۷ لاگ آبی سرعت موج برشی واقعی، لاگ قرمز سرعت موج برشی تخمین‌زده‌شده با استفاده از شبکه عصبی عمیق و لاگ سیاه سرعت موج برشی

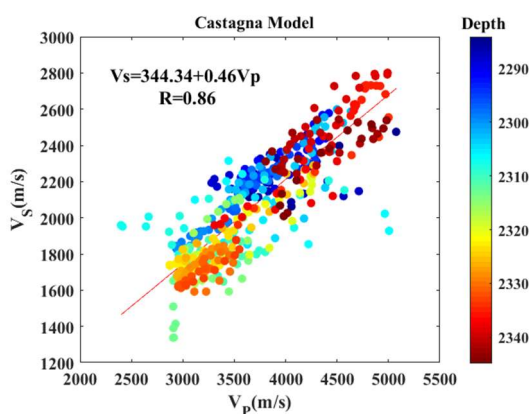
در این مقاله سرعت موج برشی با استفاده از روش‌های مختلف (رگرسیون چندگانه، رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی عمیق) در چاه شماره ۷ تخمین زده شد. روش شبکه عصبی عمیق نسبت به سایر روش‌ها جواب بهتری ارائه داده است. بنابراین برای تخمین سرعت موج برشی در سایر چاه‌ها که فاقد این ویژگی هستند از روش شبکه عصبی عمیق استفاده شد. برای صحت‌سنجی نتایج حاصل از شبکه عصبی عمیق در چاه‌های فاقد سرعت موج برشی، از مدل تجربی کاستاگنا استفاده شده است. برای این منظور در چاه شماره ۷ با استفاده از داده‌های سرعت

شده و با مدل کاستاگنا در همان چاه‌ها مقایسه شده است. نتایج نشان می‌دهند که این دو روش در چاه‌های فاقد سرعت موج برشی انطباق بهتری با یکدیگر دارند.

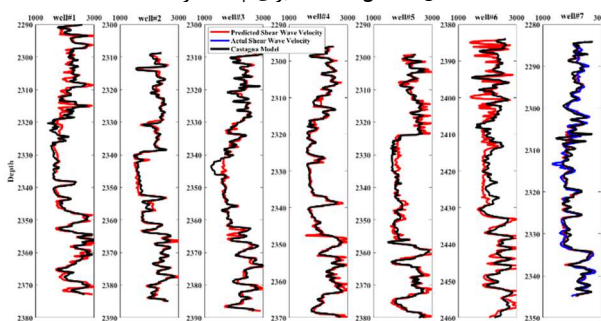
حاصل از مدل کاستاگنا را نشان می‌دهد. در شش چاه دیگر که فاقد نگاره سرعت موج برشی هستند، این ویژگی با استفاده از شبکه عصبی عمیق تخمین زده



شکل ۹. تطابق لاگ سرعت موج برشی واقعی (لاگ آبی) با لاگ سرعت موج برشی تخمین‌زده‌شده با استفاده از شبکه عصبی عمیق (لاگ قرمز) در چاه شماره ۷.



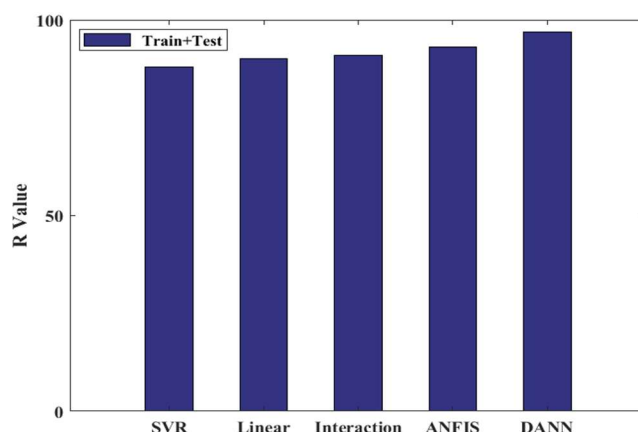
شکل ۱۰. مدل کاستاگنا برای چاه شماره ۷.



شکل ۱۱. تخمین سرعت موج برشی در سایر چاه‌ها با استفاده از روش شبکه عصبی عمیق و مقایسه آن با مدل تجربی کاستاگنا.

جدول ۱. جذر میانگین مربعات خطا برای هر یک از روش‌های استفاده شده در این مقاله در چاه شماره ۷.

خطای داده‌های آموزشی	خطای داده‌های آزمایشی	روش
۱۲۵/۵۹	۱۳۹/۷۷	مدل خطی
۱۱۵/۸۶	۱۳۳/۴۴	مدل برهم‌کنش
۱۴۸/۲۳	۱۶۶/۰۳	رگرسیون بردار پشتیبان
۸۴/۳۶	۱۲۶/۱۵	شبکه فازی عصبی تطبیقی
۸۰/۴۹	۹۸/۰۴	شبکه عصبی عمیق



شکل ۱۲. همبستگی کلی (آموزش+آزمایش) هر یک از روش‌های استفاده شده در چاه شماره ۷.

رگرسیون چندگانه در تخمین سرعت موج برشی است. جهت دستیابی به این هدف، در این مطالعه با استفاده از روش‌های مختلف، سرعت موج برشی از روی داده‌های پتروفیزیکی (سرعت موج تراکمی، چگالی، حجم کوارتز و حجم دولومیت) به‌عنوان ورودی تخمین زده شد. ابتدا سرعت موج برشی توسط مدل‌های رگرسیون چندگانه (خطی و برهم‌کنش) تخمین زده شد و نتیجه گرفتیم که مدل برهم‌کنش نسبت به مدل خطی تطابق بیشتری بین داده‌های سرعت موج برشی واقعی و تخمینی هم در داده‌های آموزشی و هم در داده‌های آزمایشی دارد. دلیل آن احتمالاً این است که در روش رگرسیون با اضافه کردن عبارت و پیچیده کردن مدل، مقدار خطای نسبی کاهش می‌یابد و باعث بهبود عملکرد مدل می‌گردد. در مرحله بعد، از الگوریتم‌های یادگیری ماشین (رگرسیون بردار پشتیبان، شبکه عصبی فازی تطبیقی و شبکه عصبی مصنوعی) استفاده شد تا نتایج حاصل از الگوریتم‌های یادگیری ماشین با نتایج حاصل از رگرسیون چندگانه مقایسه شود. نتایج ما نشان می‌دهند که روش شبکه عصبی عمیق نسبت به سایر روش‌ها نتیجه بهتری ارائه داده است. روش شبکه عصبی عمیق در حالت کلی ۹۷ درصد همبستگی بین سرعت موج برشی واقعی و تخمینی ارائه داده است. بنابراین از این روش برای تخمین سرعت موج برشی در چاه‌های فاقد این ویژگی استفاده شد. برای صحت‌سنجی نتایج حاصل از شبکه عصبی عمیق در چاه‌های فاقد سرعت موج

در شکل ۱۲، همبستگی کلی (آموزش+آزمایش) هر روش نمایش داده شده است. مطابق با این شکل، روش شبکه عصبی عمیق و رگرسیون بردار پشتیبان به ترتیب بیشترین و کمترین همبستگی بین سرعت موج برشی واقعی و تخمینی در چاه شماره ۷ را دارند.

پس از تخمین سرعت موج برشی با استفاده از روش‌های مختلف در چاه شماره ۷، جذر میانگین مربعات خطا برای هر روش محاسبه شد. جذر میانگین مربعات خطا (Root Mean Square Error) به‌صورت رابطه (۵) تعریف می‌شود:

$$RMSE = \left[\frac{\sum_{i=1}^N (V_i - \hat{V}_i)^2}{N} \right]^{0.5}, \quad (5)$$

که V_i مقدار واقعی پارامتر مدنظر (سرعت موج برشی بر حسب متر بر ثانیه)، \hat{V}_i مقدار تخمین‌زده‌شده و N تعداد نمونه را نشان می‌دهد. در جدول ۱ جذر میانگین مربعات خطا برای روش‌های استفاده شده در این مقاله آورده شده است.

همان‌طور که در

جدول ۱ دیده می‌شود، خطای روش شبکه عصبی عمیق هم در داده‌های آموزشی و هم در داده‌های آزمایشی از سایر روش‌ها کمتر است.

۵ نتیجه‌گیری

هدف از این مقاله، بررسی کارایی و توانمندی الگوریتم‌های یادگیری ماشین نسبت به روش‌های

- Castagna, J. P., batzle, M. L. eastwood, R. L., 1985, Relationships between compressional-wave and shear-wave velocities in elastic silicate rocks: *Geophysics*, 50(4), 571-581.
- Eskandari, H. Rezaee, M. R., 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*, 42, P. 480.
- Greenberg M. L., Castagna J. P., 1992, Shear wave velocity estimation in porous rocks: theoretical formulation, preliminary verification and applications: *Geophysical Prospecting*, 40, 195-209.
- Jang, J. R., 1993, ANFIS: Adaptive-Network-Based Fuzzy inference system: *IEEE*, 23(3).
- Khuri, A., Mathew, T., Sinha, B., 1997, *Statistical Tests for Mixed Linear Models: Wiley series in probability and statistics*.
- Moatazadian I., Rahimpour-Bonab H., Kadkhodaie-Ilkhchi A., Rajoli M. R., 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: *JGeope*, 1(1), 1-17.
- Na'imi, S. R., Shadizadeh, S. R., Riahi, M. A., Mirzakhani, M., 2014, Estimation of Reservoir Porosity and Water Saturation Based on Seismic Attributes Using Support Vector Regression Approach: *Journal of Applied Geophysics*, 107, 93-101.
- Nourafkan, A., Kadkhodaie-Ilkhchi, A., 2015, Shear wave velocity estimation from conventional well log data by using a Hybrid ant colony-fuzzy inference system, a case study from Cheshmeh-Khosh oilfield: *Journal of Petroleum Science and Engineering*, 127, 459-468.
- Parvizi, S., Kharrat, R., Asef, M. R., Jahangiry, B., Hashemi, A., 2015, Prediction of the Shear Wave Velocity from Compressional Wave Velocity for Gachsaran Formation: *Acta Geophysica*, 65(5), 1231-1243.
- Pickett, G. R., 1963, acoustic character logs and their applications in formation evaluation: *journal of petroleum technology*, 15(6), 659-667 .
- Soleimani, B., Bahadori, A., Meng, F., 2013, Microbiostratigraphy, microfacies and sequence stratigraphy of upper cretaceous and paleogene sediments, Hendijan oilfield, Northwest of Persian Gulf, Iran: *Natural Science*, 5(11): 1165.1180.
- برشی، از مدل تجربی کاستاگنا استفاده شد که نتایج نشان‌دهنده تطابق خوبی میان این دو مدل است. نتایج حاصل از این پژوهش، روش شبکه عصبی عمیق را به‌عنوان یکی از بهینه‌ترین روش‌های هوشمند برای تخمین سرعت موج برشی در چاه‌هایی که فاقد سرعت موج برشی هستند، پیشنهاد می‌کند. روش پیشنهاد شده در این مطالعه (شبکه عصبی عمیق) می‌تواند به‌عنوان یک روش کاربردی برای تخمین سرعت موج برشی بدون صرف هزینه‌های زیاد و زمان بیشتر مورد استفاده قرار بگیرد.
- ### منابع
- حسینی، ز.، قره چلو، س.، کدخدایی، ع.، ۱۳۹۵، استفاده از مدل هیبریدی ACO_R-BP جهت تخمین سرعت موج برشی از نگارهای تخلخل: پژوهش نفت، ۲۶(۶-۹۵)، ۱۲۱-۱۳۵.
- نورافکن، ا.، سلیمانی، ب.، کدخدایی، ع.، ۱۳۹۴، ساخت نمودار سرعت موج برشی با بهره‌گیری از الگوریتم کلونی مورچه و استفاده از داده‌های چاه‌پیمایی در میدان نفتی چشمه خوش: پژوهش نفت، ۲۵(۱-۸۵)، ۱۹۳-۲۰۳.
- Akhundi, H. Ghafoori, M. Lashkaripour, G. R., 2014, Prediction of shear wave velocity using artificial neural network technique, multiple regression and petrophysical data: a case study in Asmari reservoir (SW Iran): *Open Journal of Geology*, 4, 303-313.
- Anemangely, M. Ramezanzadeh, A. Amiri, H. Hoseinpour, S. A., 2019, Machine learning technique for the prediction of shear wave velocity using Petrophysical logs: *Journal of Petroleum Science and Engineering*, 174, 306-327.
- Avseth, P. Mukerji, T. Mavko, G., 2010, Quantitative seismic interpretation: Applying rock physics tools to reduce interpretation risk: Cambridge university press.
- Brocher, T. M., 2005, Empirical Relations between Elastic Wave speeds and Density in the Earth's Crust: *Bulletin of the Seismological Society of America*, 95(6), 2081-2092.

- Science and Engineering, 180, 105–123.
- Wyllie, M., Gregory, A., Gardner, G., 1958, an experimental investigation of factors affecting elastic wave velocity in porous media: *Geophysics*, 23(3), 459-493.
- Vapnik, V. N., 1995, *The Nature of statistical learning theory*: Springer New York.
- Wang, P., Peng, S., 2019, on a new method of estimating shear wave velocity from conventional well logs: *Journal of Petroleum*

Investigation and comparison of conventional methods for estimating shear wave velocity from well logging data in one of the sandstone reservoirs in southern Iran

Ahsan Leisi ¹, Hossein Kheirollahi ² and Navid Shad Manaman ^{3*}

¹ Ph.D. Student, Sahand University of technology, Tabriz, Iran

² Master Student, Sahand University of technology, Tabriz, Iran

³ Associate Professor, Faculty Member of Sahand University of technology, Tabriz, Iran

(Received: 17 December 2021, Accepted: 18 April 2022)

Summary

Estimation of compressional and shear wave velocities is very important in the oil and gas industry. Unlike compressional wave velocity, shear wave velocity is not measured in all wells of a field due to its higher costs. Therefore, using an alternative method that estimates the shear wave velocity at a lower cost and with acceptable accuracy is inevitable. In this study, to estimate the response variable in a well, the correlation of several logs in that well (i.e., acoustic logs, density, neutron porosity, resistivity, gamma ray, dolomite volume, quartz volume, and water saturation) with target log investigated. It was found that the compressional wave velocity, density, dolomite volume, and quartz volume logs are more correlated with shear wave velocity. Therefore, these logs were selected as input features for estimating shear wave velocity using different approaches. In the next step, among the various methods, The estimated values obtained from a method that has the best match with the actual shear wave velocity is introduced as the optimal model. Afterward, it is performed to estimate the shear wave velocity in other wells that do not have a shear wave velocity log. In this paper, multiple regression methods and machine learning algorithms (support vector regression, adaptive Neuro-fuzzy inference system, and deep artificial neural network) were applied to predict the shear wave velocity. In this study, data from seven wells were used. Due to the fact that only in well #7 shear wave velocity has been measured, and in six other wells this feature has not been recorded, this field data limitation has caused the data of well #7 to be divided into training, testing, and validation data. In multiple regression methods (linear and interaction models), support vector regression, and adaptive Neuro-fuzzy inference system, Randomly, 70% of the data has been used for training and 30% for testing, but in the artificial neural network method, Randomly, 70% of the data has been used for training, 15% for validation and 15% for network testing. For all methods, the root means square error and correlation between actual and estimated data are calculated. Linear model, interaction model, support vector regression, adaptive Neuro-fuzzy inference system, and deep artificial neural network have provided 91, 92, 89, 94, and 98% correlation in training data, and 88, 89, 86, 90 and 92% in testing data, respectively. Also, the RMSE for each of the mentioned methods is 125.59, 115.86, 148.23, 84.36, and 80.49 (m/s) in the training data and 139.77, 133.44, 166.03, 126.15, and 98.04 (m/s) in the testing data, respectively. Our results show that deep artificial neural network has provided a better solution than other methods. Hence, in this study deep artificial neural network has been proposed to estimate the shear wave velocity in other blind wells. Moreover, the Castagna empirical model was used to validate the obtained results from the deep artificial neural network in these wells, which show a good fit between the two models.

Keywords: Shear wave velocity, multiple regression, Support vector regression, Adaptive Neuro-fuzzy inference system, deep artificial neural network