

تخمین پارامترهای ژئومکانیکی با داده‌های نگار چاه و الگوریتم شبکه عصبی پرسپترون چندلایه در یکی از میادین هیدروکربنی ایران

فرهاد ملائی^۱، علی مرادزاده^{۲*}، رضا محبیان^۳

پذیرش مقاله: ۱۴۰۳/۰۸/۱۳

دریافت مقاله: ۱۴۰۳/۰۳/۰۸

چکیده

امروزه ژئومکانیک و تخمین دقیق پارامترهای ژئومکانیکی نقش بسزایی در مراحل مختلف مطالعات مهندسی نفت پیدا کرده است. در این مطالعه هدف تخمین پارامترهای ژئومکانیکی با استفاده از داده‌های نگار چاه و شبکه عصبی پرسپترون چندلایه در یکی از چاه‌های میدان هیدروکربنی در جنوب غرب ایران می‌باشد. جهت تخمین پارامترهای ژئومکانیکی یکی از پارامترهای مهم و مورد نیاز سرعت موج برشی می‌باشد که در این مقاله با استفاده از الگوریتم شبکه عصبی پرسپترون چندلایه و روابط تجربی تخمین زده شد و با توجه تخمین بهتر الگوریتم MLP در داده‌های آموزش، تست و داده کور، خروجی آن جهت تخمین مطالعات بعدی استفاده شده است. مقدار خطا (MSE) و ضریب تعیین (R^2) داده کور به ترتیب ۰/۰۰۱۳ و ۰/۸۸۷۵ به دست آمده است. سپس با استفاده از سرعت موج برشی تخمین زده شده، مدول یانگ و نسبت پواسون محاسبه و با استفاده از این دو پارامتر شاخص شکنندگی دینامیک محاسبه گردید. در ادامه مقاومت فشاری تک محوره و مقاومت کششی محاسبه گردید و شاخص شکنندگی استاتیک نیز با استفاده از مقاومت فشاری تک محوره و مقاومت کششی محاسبه و ارتباط بین شاخص شکنندگی دینامیک و شاخص شکنندگی استاتیک بررسی گردید و در خاتمه شاخص شکنندگی با استفاده از درصد حجمی کانی‌ها محاسبه و با مقادیر شاخص شکنندگی دینامیک و استاتیک مقایسه گردیده است که نتایج بیانگر ارتباط خوب شاخص شکنندگی دینامیک و استاتیک به دست آمده با استفاده از سرعت موج برشی پیش‌بینی شده از الگوریتم MLP و شاخص شکنندگی به دست آمده از درصد حجمی کانی‌ها می‌باشد.

کلید واژه‌ها: ارزیابی مدل، داده نگار چاه، سرعت موج برشی، شاخص شکنندگی، الگوریتم MLP.

۱. دانشجوی دکتری مهندسی نفت، دانشکده مهندسی معدن، دانشکدگان فنی، دانشگاه تهران، mollaeifarhad@ut.ac.ir

۲. عضو هیات علمی گروه مهندسی معدن، دانشکده مهندسی معدن، دانشکدگان فنی، دانشگاه تهران، a_moradzadeh@ut.ac.ir

۳. عضو هیات علمی گروه مهندسی معدن، دانشکده مهندسی معدن، دانشکدگان فنی، دانشگاه تهران، mohebian@ut.ac.ir

۱. مقدمه

ژئومکانیک مخازن هیدروکربنی، نقش مهمی در ارزیابی و توسعه میادین نفت و گاز ایفا می‌کند. در بسیاری از مناطق، چگونگی و محل حفاری چاه‌ها با توجه به عمق سازند مخزنی و تنش روباره، در توسعه میادین، چالشی بسیار جدی را پیش روی دست اندرکاران صنعت نفت قرار می‌دهد. مخازن در اعماق زیاد با دما و فشار بالا تا نفت‌های سنگین و نواحی کم عمق با دما و فشار پایین‌تر مشکلات و مسائل متعددی در مسیر طولانی تولید نفت از درون مخزن تا سطح زمین در جای جای دنیا وجود دارد که بخش عمده‌ای از آن‌ها ناشی از شرایط نامتعادل فیزیکی - مکانیکی سازندها است. امروزه ژئومکانیک مخازن هیدروکربنی به دانشی کلیدی برای تحلیل و غلبه کردن به این گونه مشکلات تبدیل شده است (آشتیانی عبدی، ۱۳۶۶ و ۱۳۸۹).

امروزه مطالعات متعددی در زمینه ژئومکانیک، تخمین پارامترهای ژئومکانیکی و مدلسازی‌های ژئومکانیکی صورت گرفته است. ژانگ و همکاران (Zhang et al., 2020) با یادگیری عمیق (LSTM) سرعت موج برشی را تخمین زدند. غلامی و همکاران (Gholami et al., 2020) روش‌های مختلف یادگیری ماشین (ONN, OFIS, OSVR & CM) سرعت موج برشی را پیش‌بینی کردند. قربانی و همکاران (Ghorbani et al., 2021) با یادگیری ماشین (LSSVM-GA) سرعت موج برشی را پیش‌بینی کردند. ابراهیمی و همکاران (Ebrahimi et al., 2022) با استفاده از یادگیری ماشین (الگوریتم‌های MLP-ANN، ANFIS، MGGP) و داده‌های چاه سرعت موج برشی را تخمین زدند. غلامی و همکاران (Gholami et al., 2022) با استفاده از یادگیری ماشین (الگوریتم شبکه عصبی مصنوعی، منطق فازی و نروفازی) و نگارهای پتروفیزیکی سرعت موج برشی کند و تند را پیش‌بینی کردند. نصرنیا و همکاران (Nasrnia et al., 2023) با ترکیب روش‌های هوشمند و مدل‌های فیزیکی سنگی سرعت موج برشی را پیش‌بینی کردند. احمد و همکاران (Ahmed et


al., 2021)، نسبت پواسون استاتیک را با استفاده از هوش مصنوعی (RF, FN) پیش‌بینی کردند. سیدینگ و الکاتانتی (Siddig and Elkhatny, 2021)، مشخصات مدول الاستیک استاتیک را از داده‌های حفاری با استفاده از روش‌های هوش مصنوعی (SVM, ANN) پیش‌بینی کردند. شاهانی و همکاران (Shahani et al., 2021)، مدول الاستیک سنگ‌ها را با استفاده از یادگیری ماشین (مدل‌های رگرسیون هوشمند، LightGBM)، ماشین بردار پشتیبان (SVM)، Catboost، رگرسیون درختی تقویت‌شده گرایان (GBRT)، جنگل تصادفی (RF)، و (XGBoost) پیش‌بینی کردند. جین و همکاران (Jin et al., 2022)، مقاومت فشاری و مدول الاستیک سنگ‌ها را با استفاده از یادگیری ماشین پیش‌بینی کردند. که در این مدل، یک مدل ترکیبی GWO-ELM، بر اساس یک شبکه ماشین یادگیری که توسط الگوریتم گرگ خاکستری (grey wolf) بهینه شده است، ساخته شده است. ارمقانی و همکاران (Armaghani et al., 2018) مقاومت فشاری تک محوره (UCS) سنگ را روی ۲۰ نمونه ماسه سنگ در مالزی با استفاده از الگوریتم (GEP) تخمین زد. در این تحقیق به منظور نشان دادن قابلیت الگوریتم GEP، مدل با رگرسیون خطی مقایسه شد و نتایج نشان داد که مدل GEP برای تخمین UCS دقت بیشتری دارد. ونگ و ون (Wang and Wan, 2019) UCS را با الگوریتم GEP با استفاده از مقادیر برگشتی چکش اشمیت (به عنوان پارامتر ورودی) تخمین زدند. فرج و همکاران (Faraj et al, 2022) زاویه اصطکاک داخلی را با استفاده از چگالی و نگارهای نوترون گاما و با استفاده از همبستگی Plumb تخمین زدند. شاهانی و همکاران (Shahani et al, 2022) زاویه اصطکاک داخلی و چسبندگی را با استفاده از روش یادگیری ماشین (LR)، (RR)، (DT) و (SVM) و داده‌های نگار چاه برآورد کردند. قبادی و ناصری (Ghobadi and Naseri, 2016) شاخص شکنندگی را با استفاده از شبکه عصبی مصنوعی و مدل‌های رگرسیون چندگانه پیش‌بینی کردند. کایوندا و آسیوری (Kaunda and

۲. زمین‌شناسی منطقه


داده‌های موجود مربوط به یکی چاه‌های یکی از میادین هیدروکربنی در فروافتادگی دزفول می‌باشد. این میدان با روند شمال‌غربی- جنوب‌شرقی در قسمت غربی تا مرکزی و روند شمال‌شرقی جنوب‌غربی، در قسمت انتهایی شرقی، امتداد یافته‌است. تاقدیس این میدان دارای بیشینه شیب ۴۵-۶۵ درجه در یال جنوب باختری و ۲۰-۴۵ درجه در یال شمال خاوری است. رخنمون سطحی این میدان، سازند آغاچاری بوده و سازندهای آسماری و گروه‌های بنگستان و خامی، مخازن هیدروکربوری موجود در این میدان می‌باشند. سازند آسماری مهم‌ترین سنگ مخزن این میدان است، که خود به ۶ لایه مخزنی تقسیم شده‌است. لایه‌های مخزنی یک، دو، سه به‌طور عمده از کربنات‌های دولومیتی تشکیل شده‌اند، بنابراین تراکم شکستگی‌ها به ویژه در لایه یک (۹۰ درصد دولومیت) بیشتر است. در لایه‌های مخزنی چهار، پنج و شش این میدان، به دلیل افزایش لایه‌های شیلی و مارنی، همچنین کاهش شکستگی، تراکم شکستگی‌ها کمتر می‌شود (مطیعی، ۱۳۷۲). به منظور افزایش ظرفیت برداشت نفت خام از این میدان، به‌طور متوسط روزانه ۲۵ میلیون متر مکعب گاز به مخزن آسماری این میدان تزریق می‌شود. داده‌های موجود در یکی از چاه‌های این میدان جهت تخمین سرعت موج برشی شامل نگارهای گامای تصحیح شده (CGR)، چگالی (RHOB)، مقاومت ویژه (LL7)، نوترونی (NPHI)، قطرسنجی (CALIPER)، سرعت موج فشاری (Vp)، سرعت موج برشی (VS) و فوتوالکتریک (PEF) می‌باشد که در محدوده عمقی ۳۵۶۶/۷۷ تا ۳۷۸۸/۳۶ متری قرار دارند. در شکل ۱، موقعیت میدان هیدروکربنی موردنظر و میادین مجاور و در شکل ۲، نگارهای موجود در چاه موردنظر نشان داده شده است.

(Asbury, 2016) با استفاده از روش‌های غیرمخرب برای تونل زدن در سنگ‌های سخت، شکندگی سنگ را پیش‌بینی کردند. در این مقاله با استفاده از سرعت موج تراکمی و برشی و با استفاده از شبکه عصبی مصنوعی، شاخص شکندگی تخمین زده شد. لشکری پور و همکاران (Lashkaripour et al., 2018) در پژوهشی تحت عنوان بررسی ضریب شکست و همبستگی تجربی بین پارامترهای فیزیکی و مکانیکی سنگ آهک آسماری انجام دادند. در این مقاله روابط تجربی برای تخمین شاخص‌های شکندگی سنگ آهک آسماری برقرار شده است. اور و جائو (Ore and Gao, 2021) با استفاده از شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان، شاخص شکندگی را پیش‌بینی کردند.

با توجه به بررسی پژوهش‌های قبلی تعیین روشی که تخمین دقیقی از پارامترهای ژئومکانیکی انجام دهد دارای اهمیت بسیار زیادی می‌باشد. در تحقیق حاضر به بررسی و تخمین پارامترهای ژئومکانیکی شامل سرعت موج برشی، مدول یانگ، نسبت پواسون، مقاومت فشاری تک محوره و مقاومت کششی، شاخصی شکندگی دینامیک و استاتیک در محدوده یکی از چاه‌های میادین جنوب غرب ایران با استفاده از داده‌های نگار چاه، الگوریتم MLP و روابط تجربی پرداخته می‌شود. در این مقاله از تلفیق روش‌های هوشمند و روش‌های تجربی جهت تخمین پارامترهای ژئومکانیکی استفاده شده است و همچنین برای بررسی شاخص شکندگی که کمتر به آن پرداخته شده است شاخص شکندگی دینامیک و استاتیک محاسبه و با شاخص شکندگی حاصل از درصد حجمی کانی‌ها مقایسه شده است که تطابق مناسبی بین سه روش محاسبه شده به‌دست آمده است.



شکل ۱. موقعیت میدان هیدروکربنی موردنظر و میادین مجاور.



شکل ۲. نگارهای موجود در چاه. از چپ به راست: ستون ۱: Depth، ستون ۲: CALIPER، ستون ۳: CGR، ستون ۴: RHOB، ستون ۵:


NPHI، ستون ۶: LL7، ستون ۷: Vs و Vp، ستون ۸: PEF و ستون ۹: Lithology

مدل تک لایه پرسپترون یک شبکه عصبی ساده است که توسط «فرانک رزنبلات» (Frank Rosenblatt) در دهه ۱۹۵۰ ارائه شد. این مدل لایه پنهان ندارد و از آن به منظور

۳. روش تحقیق

۳-۱. شبکه عصبی پرسپترون چندلایه

بایاس هستند و هدف آموزش شبکه‌های عصبی، پیدا کردن این مقادیر است. وزن‌های شبکه، مقدار اهمیت ورودی متناظر را مشخص می‌کند. جمع مقادیر وزن‌دار ورودی (مقدار داده‌های ورودی در وزن‌های شبکه ضرب و در نهایت با مقدار بایاس با یکدیگر جمع می‌شوند تا مقدار نهایی، به تابع فعالسازی ارسال شود). تابع فعالسازی (مقدار خروجی مرحله قبل از یک تابع خطی عبور می‌دهد تا مقدار خروجی شبکه مشخص شود. این تابع خطی، تابع فعالسازی نام دارد). آموزش شبکه عصبی پرسپترون چندلایه توسط الگوریتم پس از انتشار خطا انجام می‌شود که شامل گسترش خطا از لایه خروجی به لایه‌های ورودی تکراری به منظور اصلاح مقادیر وزن است. قابلیت MLP برای یادگیری و تعمیم بستگی به معماری آن (تعداد لایه‌های پنهان و گره) و پارامترهای آموزش (نرخ یادگیری، سرعت، و تعداد تکرارها در مورد یادگیری الگوریتم پس از انتشار) دارد (Alavi et al, 2010; Ghabaei et al, 2010) شکل ۳، شماتیک شبکه MLP را نمایش می‌دهد.

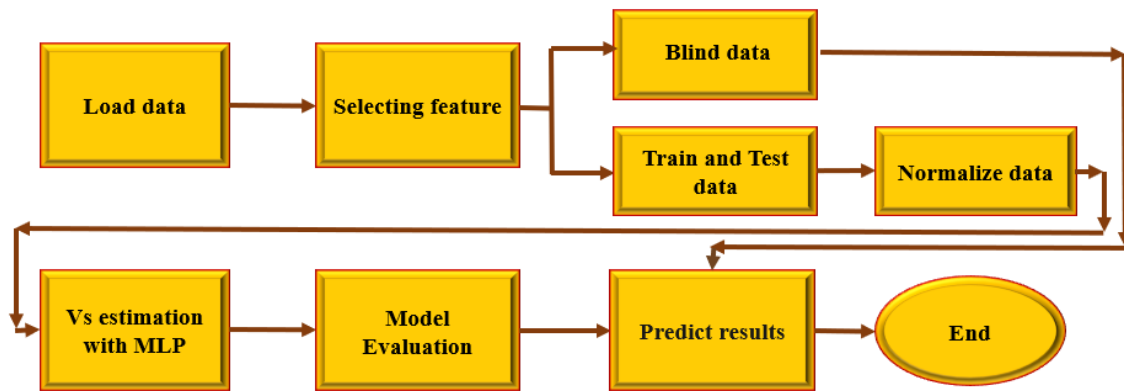


شکل ۳. شماتیک شبکه پرسپترون چند لایه (Alavi et al, 2010).

الگوریتم شبکه عصبی پرسپترون چندلایه از نرم افزار پایتون نسخه ۳،۱۱، و ترسیم نگارها از نرم‌افزار ژئولاگ و اکسل استفاده شده است. فلوچارت پیش‌بینی سرعت موج برشی در شکل ۴، نمایش داده شده است.

دسته‌بندی داده ورودی در دو کلاس استفاده می‌شود. می‌توان مدل تک لایه پرسپترون را جزء الگوریتم‌های «یادگیری نظارت شده» (Supervised Learning) تلقی کرد که آن را برای دسته‌بندی خطی داده‌ها به کار می‌برند. در بسیاری از مسائل ریاضی که بر اساس حل معادلات غیر پیچیده خطی حل می‌شود، یک شبکه پرسپترون چندلایه می‌تواند به سادگی با تعریف اوزان و توابع مناسب مورد استفاده قرار گیرد. توابع فعالیت مختلفی به فراخور تناسب روش در نرونها مورد استفاده قرار می‌گیرد. شبکه عصبی پرسپترون تک لایه محاسباتی را بر روی ورودی خود انجام می‌دهد تا داده‌ها را بر اساس شناسایی ویژگی‌هایشان، در دو کلاس جای دهد. به همین خاطر، به این مدل، دسته‌بند دودویی خطی نیز گفته می‌شود. مدل پرسپترون تک لایه از ۴ بخش تشکیل شده است: مقادیر ورودی یا لایه ورودی (لایه ورودی پرسپترون تک لایه از نرون‌هایی ساخته شده است که داده‌ها را دریافت می‌کنند و این مقادیر را برای پردازش به لایه بعد می‌فرستند). وزن‌ها و بایاس (پارامترهای شبکه عصبی، وزن‌ها و مقدار

۴. پیش‌بینی سرعت موج برشی با استفاده از الگوریتم MLP در این مقاله داده‌های نگارهای RHOB, CALIPER, NPHI, LL7, PEF, Vp, Vs, CGR برای تعیین سرعت موج برشی با استفاده از الگوریتم MLP در دسترس بودند. جهت پیاده‌سازی




شکل ۴. فلوچارت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم MLP.

دارند جهت انتخاب پارامترهای موثر ورودی جهت تخمین سرعت موج برشی مورد بررسی قرار گرفتند. شکل ۵، انتخاب ویژگی‌های موثر از طریق ماتریس همبستگی پیرسون را نشان می‌دهد. با توجه به شکل ۵، و با توجه به همبستگی پیرسون، نگارهای V_p , $RHOB$, $NPHI$, $CALIPER$ به عنوان ورودی الگوریتم‌ها انتخاب شدند چرا که اضافه کردن نگارهای دیگر باعث افزایش خطا و کاهش دقت می‌شود. همان‌گونه که در شکل ۵ نشان داده شده است همبستگی سرعت موج برشی با نگارهای قطرسنجی برابر -0.54 ، تخلخل -0.81 ، چگالی 0.73 و سرعت موج فشاری 0.98 به دست آمده است.

برای انتخاب ویژگی‌های موثر و ورودی‌های مناسب به الگوریتم باید ضریب همبستگی ویژگی‌ها را با داده سرعت موج برشی بررسی کرد. یکی از روش‌های انتخاب ویژگی محاسبه ضریب همبستگی پیرسون است. ضریب همبستگی پیرسون میزان همبستگی خطی بین دو متغیر تصادفی را می‌سنجد. مقدار این ضریب بین -1 تا 1 تغییر می‌کند که «۱» به معنای همبستگی مثبت کامل، «۰» به معنی نبود همبستگی، و « -1 » به معنی همبستگی منفی کامل است. ضریب همبستگی پیرسون بین دو متغیر تصادفی برابر با کوواریانس آنها تقسیم بر انحراف معیار آنها تعریف می‌شود. همانطوری که اشاره شد در این مطالعه نگارهای $RHOB$, $CALIPER$,

Pearson Correlation Matrix



شکل ۳. انتخاب ویژگی‌ها از طریق ماتریس همبستگی پیرسون.

تعداد لایه‌های پنهان دو لایه که در لایه اول تعداد گره‌ها ۵۰۰ و در لایه دوم تعداد گره‌ها ۱۰۰ در نظر گرفته شده است، همچنین تعداد آموزش مدل با تعداد لایه‌های پنهان بیشتر نیز بررسی گردید که نهایتاً بهبودی در نتایج حاصل نشد و همچنین با توجه به افزایش لایه‌های پنهان مدل زمان آموزش مدل نیز بسیار افزایش پیدا می‌کرد. سایر پارامترها شامل اندازه دسته: ۵۰، نرخ یادگیری: ۰،۰۰۰۱، تعداد تکرار: ۳۰۰، تابع بهینه‌ساز: Adam، و از تابع فعال‌ساز Relu استفاده شد. جهت جلوگیری از بیش‌برازش در مرحله آموزش مدل، ۱۰ درصد از داده‌های آموزش به عنوان داده‌های ارزیابی (validation split: 0.1) در نظر گرفته شده است. جهت اعتبارسنجی نتایج الگوریتم ارائه شده از داده‌های واقعی سرعت موج برشی برداشت شده از نگار DSI استفاده شد.

برای داده‌های آموزش جهت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم MLP، $MSE_{MLP} = 0.0001$ ، $RMSE_{MLP} = 0.0126$ و $R^2_{MLP} = 0.9560$ به دست آمده است. شکل ۶، خطای MSE و اعتبارسنجی (validation) را برای داده‌های آموزش با الگوریتم MLP نمایش داده است. شکل ۷، سرعت موج برشی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم MLP برای داده‌های آموزش را نشان داده است.

در ادامه از کل داده‌ها که ۱۱۶۴۰ داده بودند و از ابتدا ۱۴۳۲ داده به عنوان داده کور جهت اطمینان از نتایج الگوریتم کنار گذاشته شد و بقیه داده که به دو قسمت آموزش و تست تقسیم شدند که ۸۰٪ داده‌ها به آموزش و ۲۰٪ داده‌ها به تست اختصاص داده شدند. در مرحله بعد نرمال‌سازی داده‌ها برای دستیابی به دقت بالاتر انجام شده است. برای نرمال‌سازی از تابع Min-Max Normalization استفاده شده که داده‌های موجود بین صفر و یک تنظیم می‌گردند. در ادامه برای بهینه‌سازی از تابع بهینه‌ساز Adam استفاده شده است. برای ارزیابی مدل از میانگین مربعات خطا (MSE)، جذر میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) استفاده شده است که روابط آنها مطابق معادلات ۱، ۲، ۳ و ۴ می‌باشد.

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

$$RMSE = \sqrt{MSE} \quad (2)$$


$$MSE = \frac{SS_{RES}}{N} \quad (3)$$

$$R^2 = 1 - \frac{MSE \times N}{SS_{TOT}} \quad (4)$$

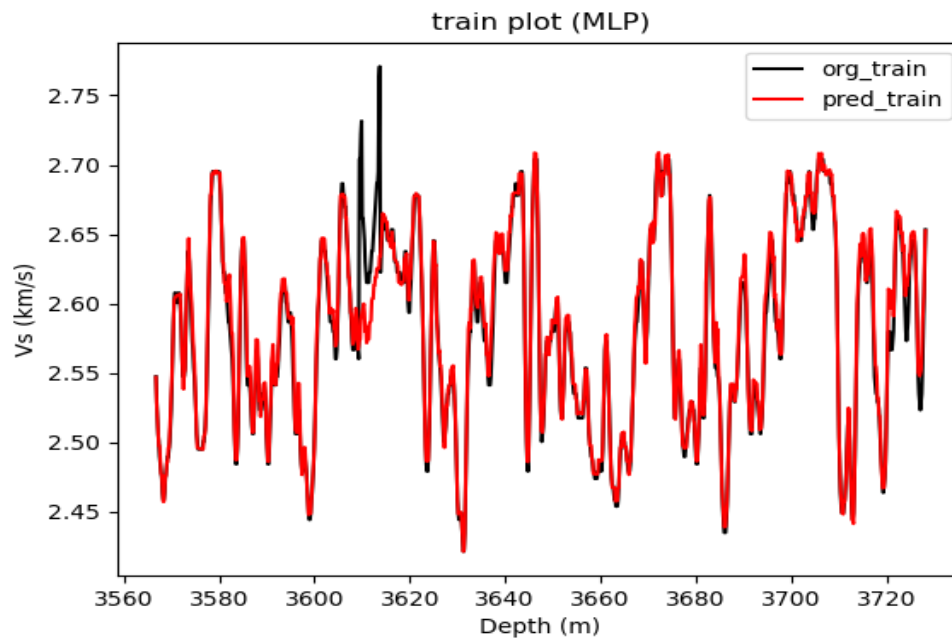
۵. نتایج

در این مطالعه نتایج الگوریتم MLP جهت پیش‌بینی سرعت موج برشی برای تخمین سایر پارامترهای ژئومکانیکی مورد بررسی قرار گرفت و مقادیر MSE, RMSE و R^2 برای داده‌های آموزش، تست و داده کور محاسبه گردید. پارامترهای مورد استفاده برای این الگوریتم به شرح زیر بوده است:

(MLP)

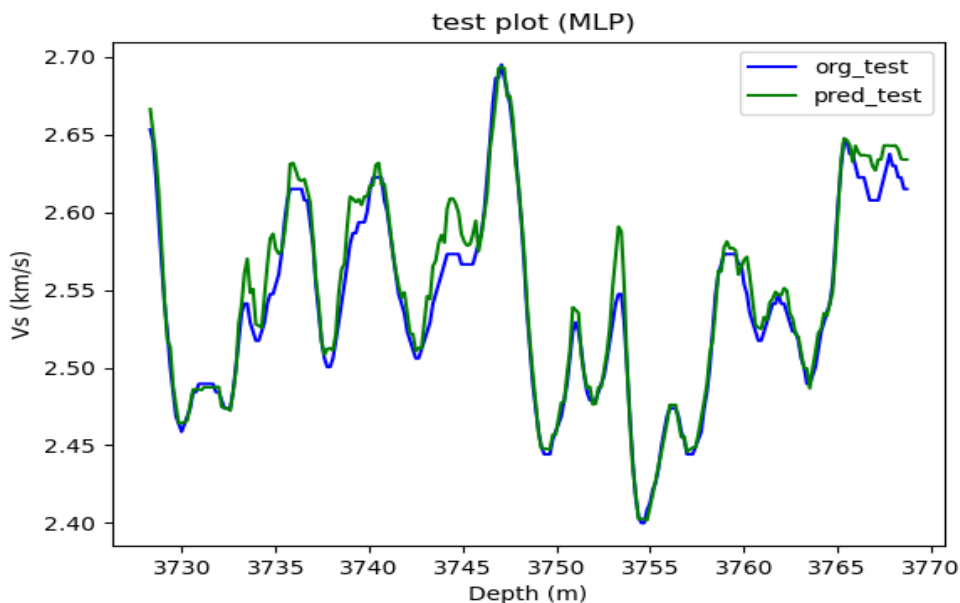


شکل ۶. نمایش خطای MSE (نمودار مشکی رنگ) و خطای اعتبارسنجی (نمودار قرمز رنگ) برای داده‌های آموزش.



شکل ۷. تخمین سرعت موج برشی با استفاده از الگوریتم MLP برای داده‌های آموزش. نمودار مشکی رنگ (سرعت موج برشی اندازه‌گیری شده داده آموزش)، نمودار قرمز رنگ (سرعت موج برشی پیش‌بینی شده داده آموزش).


شکل ۸. سرعت موج برشی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم MLP برای داده‌های تست را نشان داده است. برای داده‌های تست جهت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم MLP، $MSE_{MLP} = 0.0002$ و $RMSE_{MLP} = 0.0150$ و $R^2_{MLP} = 0.9539$ به دست آمد.



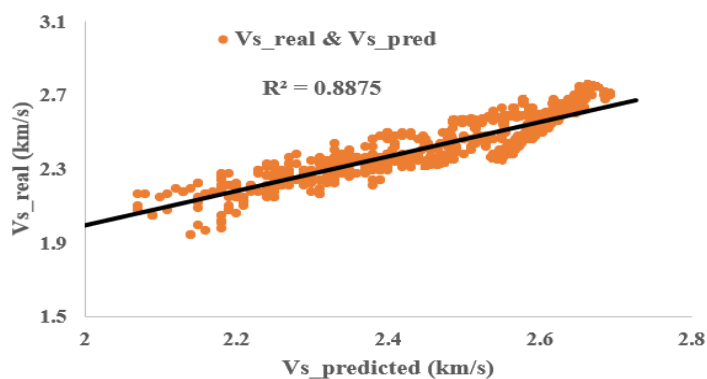
شکل ۸. تخمین سرعت موج برشی با استفاده از الگوریتم MLP برای داده‌های تست. نمودار آبی رنگ (سرعت موج برشی اندازه‌گیری شده داده تست)، نمودار سبز رنگ (سرعت موج برشی پیش‌بینی شده داده تست).

جهت اطمینان از نتایج الگوریتم بخشی از داده‌ها از ابتدا به عنوان داده کور کنار گذاشته شد که در نهایت جهت تخمین سرعت موج برشی به الگوریتم داده شود و سرعت موج برشی پیش‌بینی شده با سرعت موج برشی اندازه‌گیری شده مقایسه شود. برای داده‌های کور جهت پیش‌بینی سرعت موج برشی با استفاده از الگوریتم MLP، $MSE_{MLP} = 0.0013$.

است. شکل ۹، سرعت موج برشی اندازه‌گیری شده و تخمین زده شده با استفاده از الگوریتم MLP برای داده‌های کور را نشان داده است. شکل ۱۰، ضریب تعیین سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده داده‌های کور با استفاده از الگوریتم MLP نشان داده است.



شکل ۹. تخمین سرعت موج برشی با استفاده از الگوریتم MLP برای داده‌های کور. نمودار مشکی رنگ (سرعت موج برشی اندازه‌گیری شده داده کور)، نمودار قرمز رنگ (سرعت موج برشی پیش‌بینی شده داده کور).



شکل ۱۰. ضریب تعیین سرعت موج برشی اندازه‌گیری شده و سرعت موج برشی پیش‌بینی شده داده‌های کور با استفاده از الگوریتم MLP.

مقایسه گردیده است، می‌توان به روابط کاستاگنا و همکاران (Eskandari et al., 2004) و بروچر (Brocher, 2005) اشاره کرد. جدول ۱، روابط ارائه شده را نشان داده است.

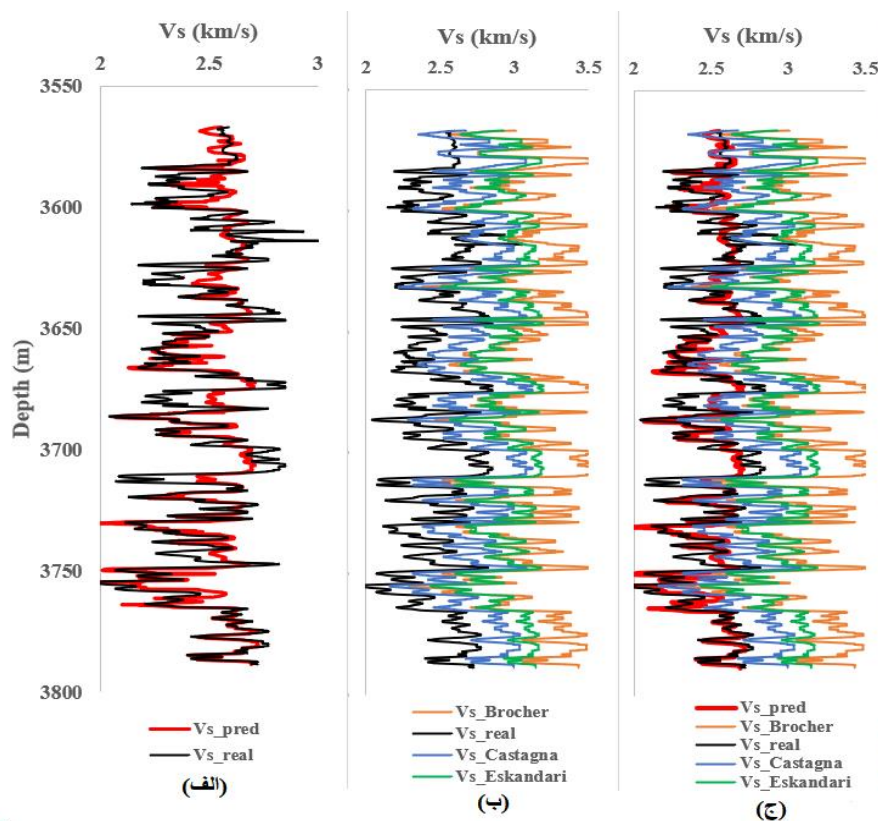
در ادامه سرعت موج برشی تخمین زده شده با استفاده از الگوریتم MLP با روابط تجربی مقایسه گردید. از روابط تجربی که در تخمین سرعت موج برشی کاربرد زیادی دارند و در این تحقیق با نتایج سرعت موج برشی پیش‌بینی شده

جدول ۱. روابط تجربی متداول جهت پیش‌بینی سرعت موج برشی.

	Empirical relation
Castagna et al, 1985	$V_s = 1.0168V_p - 0.05509V_p^2 - 1.0305$
Eskandari et al, 2004	$V_s = 1.612V_p - 0.1236V_p^2 - 2.0357$
Brocher, 2005	$V_s = 0.0064V_p^4 - 0.1238V_p^3 + 0.7949V_p^2 - 1.2344V_p + 0.7758$

الگوریتم MLP استفاده شده است. دلیل این مسئله این است که روابط تجربی برای شرایط زمین شناسی خاص و نوع سنگ خاصی ارائه شده است و همیشه میانگین داده‌ها را ارائه می‌دهد برای همین واریانس داده‌ها را نمی‌دهد. مخصوصاً در زمین شناسی که ما بدنال تفاوت‌ها هستیم.

شکل ۱۱، مقایسه بین سرعت موج برشی تخمین زده شده و روابط تجربی با داده واقعی را نشان داده است. با توجه به نتایج حاصل شده، روابط تجربی در تخمین سرعت برشی به شدت ضعیف عمل کرده و کارایی لازم را در پیش‌بینی این پارامتر برای این داده‌ها نداشتند به همین دلیل در ادامه برای تخمین سایر پارامترهای ژئومکانیکی از خروجی حاصله از



شکل ۱۱. مقایسه بین سرعت موج برشی تخمین زده شده و روابط تجربی با داده واقعی. الف) مقایسه بین سرعت موج برشی تخمین زده شده با الگوریتم MLP و داده سرعت موج برشی واقعی. ب) مقایسه بین سرعت موج برشی محاسبه شده از روابط تجربی

و داده سرعت موج برشی واقعی. ج) مقایسه بین سرعت موج برشی تخمین زده شده با الگوریتم MLP، سرعت موج برشی با استفاده از روابط تجربی و داده سرعت موج برشی واقعی.


نشان می‌دهد. با فرض یک محیط الاستیک، ضرایب تغییر شکل برشی غیرالاستیک در نظر گرفته نمی‌شوند بنابراین، نسبت پواسون پویا و استاتیک برابر هستند.

$$E_{dyn} = \rho V_s^2 \frac{3V_p^2 - 4V_s^2}{V_p^2 - V_s^2} \quad (5)$$

$$u_{dyn} = \frac{V_p^2 - 2V_s^2}{2(V_p^2 - V_s^2)} \quad (6)$$

$$E_{st} = 0.414E_{dyn} - 1.059 \quad (7)$$

در مرحله بعد با استفاده از روابط ۵ و ۶، مدول یانگ (E_{dyn}) و نسبت پواسون (u_{dyn}) دینامیک به کمک سرعت موج برشی تخمین زده شده محاسبه گردید. مدول یانگ استاتیک (E_{st}) از رابطه ۷، (Wang et al., 2000) به کمک مدول یانگ دینامیک به دست آمده است. شکل ۱۲، نمودارهای مدول یانگ دینامیک و استاتیک و نسبت پواسون به دست آمده را




شکل ۱۲. نگارهای مدول یانگ و نسبت پواسون. الف) مدول یانگ. ب) نسبت پواسون.

وابسته به مدول یانگ و نسبت پواسون دینامیک می‌باشند که این پارامترها با استفاده از سرعت موج برشی تخمین زده شده از روش یادگیری ماشین محاسبه گردیدند. شکل ۱۳، مقایسه شاخص شکنندگی دینامیک با استفاده از داده واقعی سرعت برشی و با استفاده از سرعت موج برشی تخمین زده شده را نشان می‌دهد (Valin and Antia, 2020).

$$BI_{dyn} = E_{dyn} + \frac{u_{dyn}}{2} \quad (8)$$

در مرحله بعد به بررسی شاخص شکنندگی پرداخته شده است. شاخص شکنندگی از طریق سه روش تعیین می‌شود: ۱- از طریق مدول‌های الاستیک. ۲- با استفاده از نمونه‌های آزمایشگاهی مقاومت. ۳- با استفاده از حجم کانی‌ها. جهت تعیین شاخص شکنندگی دینامیک از رابطه ۸ استفاده شده است. با توجه به این رابطه شاخص شکنندگی دینامیک



شکل ۱۳. مقایسه شاخص شکنندگی دینامیک با استفاده از داده واقعی و تخمین زده شده سرعت موج برشی. نمودار مشکی رنگ مربوط به شاخص شکنندگی دینامیک داده واقعی سرعت موج برشی و نمودار قرمز رنگ شاخص شکنندگی دینامیک مربوط به سرعت موج برشی پیش‌بینی شده.

محوره در نظر گرفته شده است. در رابطه ۱۱ از مدول یانگ استاتیک محاسبه شده در رابطه ۷ استفاده شده است.

$$UCS = 9.95V_p^{1.21} \quad (10)$$

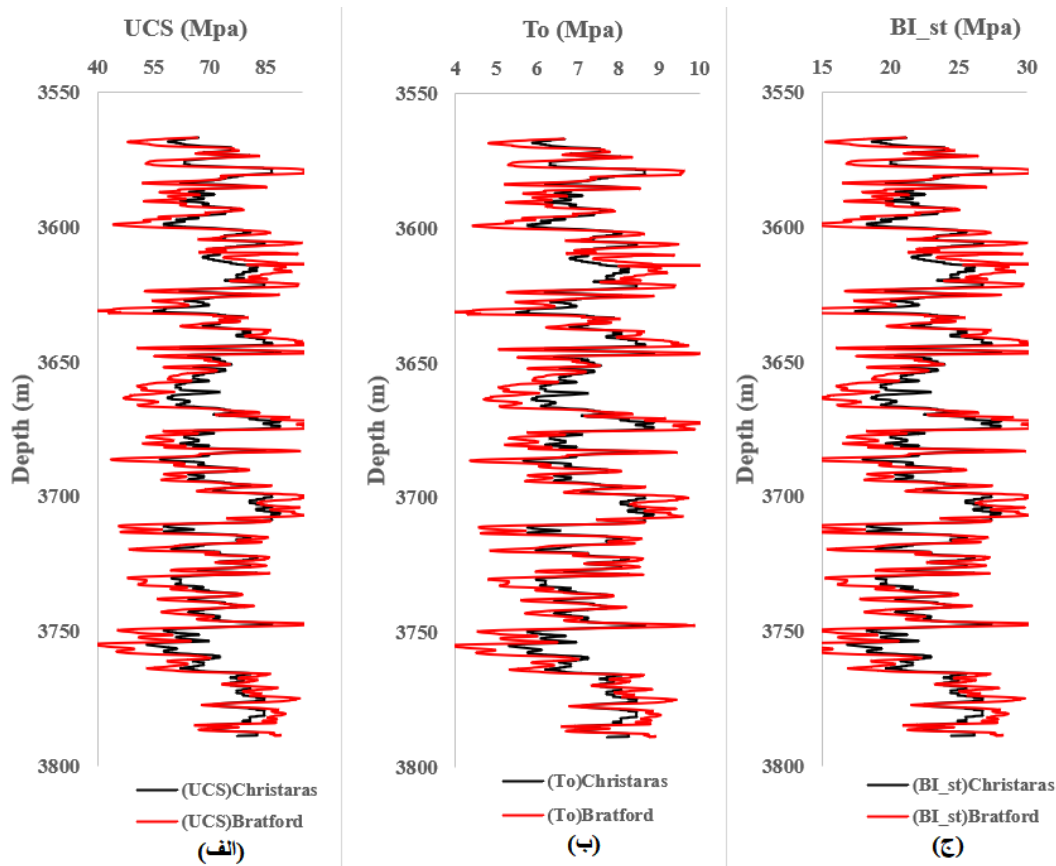
$$UCS = 2.28 + 4.1089E_{st} \quad (11)$$

شکل (۱۴-الف) مقاومت فشاری تک‌محوره، شکل (۱۴-ب) مقاومت کششی و شکل (۱۴-ج) شاخص شکنندگی استاتیک را نشان می‌دهد. رنگ مشکی مربوط به پارامترهای محاسبه شده از رابطه ۱۰ و رنگ قرمز مربوط به پارامترهای محاسبه شده از رابطه ۱۱ می‌باشد.

برای محاسبه شاخص شکنندگی استاتیک (BI_{st}) می‌توان از رابطه بین این پارامتر با مقاومت فشاری تک محوره (σ_c) و مقاومت کششی (σ_t) استفاده کرد. رابطه ۹، یکی از روابطی است که جهت تعیین شاخص شکنندگی استاتیک مطرح شده است (Altindag, 2010):

$$BI_{st} = \sqrt{\frac{\sigma_c \times \sigma_t}{2}} \quad (9)$$

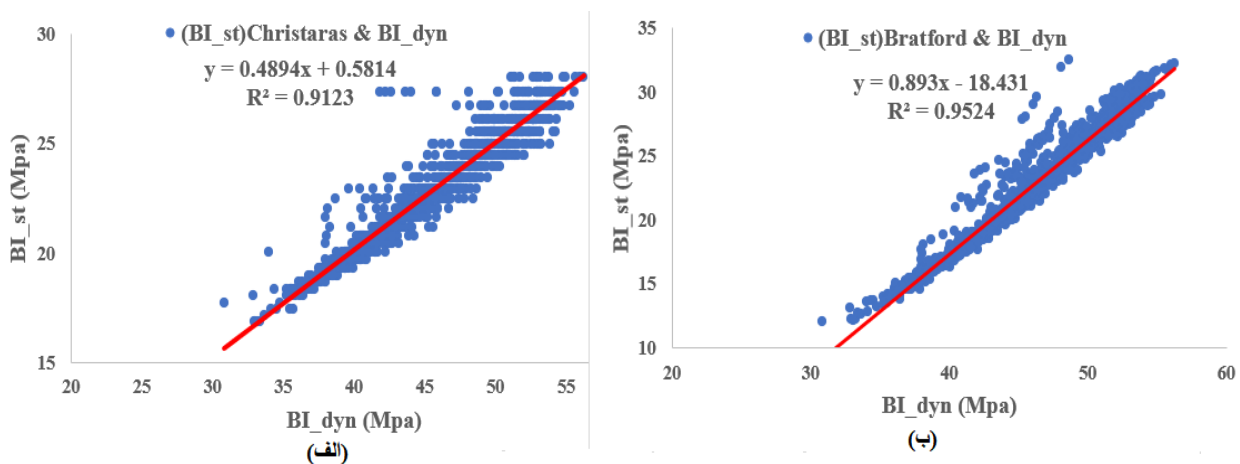
برای محاسبه مقاومت فشاری تک محوره از رابطه ۱۰ (Christaras, 1997) و رابطه ۱۱، (Bradford, 1998) استفاده شده و مقاومت کششی ۰٫۱ مقاومت فشاری تک



شکل ۱۴. نمایش الف) نمودار مقاومت فشاری تک‌محوره. ب) مقاومت کششی. ج) شاخص شکنندگی استاتیک. رنگ مشکی پارامترهای محاسبه شده از رابطه (۱۰) و رنگ قرمز (پارامترهای محاسبه شده از رابطه (۱۱)).

شکل (۱۵-ب) همبستگی بین شاخص شکنندگی به دست آمده از رابطه ۱۱ و شاخص شکنندگی دینامیک را با ضریب $R^2=0.9524$ نشان می‌دهد.

شکل ۱۵، همبستگی بین شاخص شکنندگی دینامیک و استاتیک و رابطه بین آن‌ها را نمایش داده است. شکل (۱۵-الف) همبستگی بین شاخص شکنندگی به دست آمده از رابطه ۱۰ و شاخص شکنندگی دینامیک را با ضریب $R^2=0.9123$ و



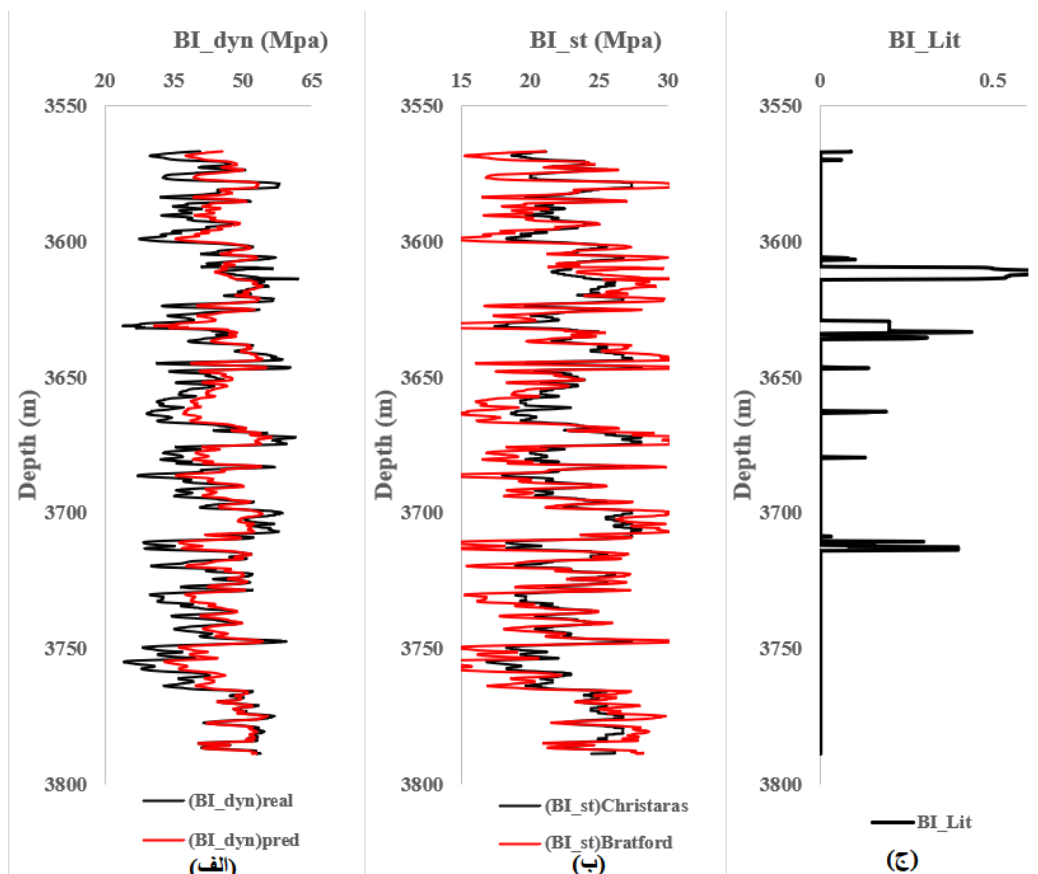
شکل ۱۵. همبستگی بین شاخص شکنندگی دینامیک و استاتیک. الف) از رابطه چریستارس. ب) از رابطه براتفورد.

شکنندگی حاصل از درصد حجمی کانی‌ها را مشاهده کرد. در محدوده‌های ۳۶۰۰ تا ۳۶۳۰ متری، ۳۶۴۰ تا ۳۶۴۵ متری و ۳۷۰۰ تا ۳۷۱۰ متری که شاخص شکنندگی دینامیک و استاتیک افزایش قابل ملاحظه‌ای داشته است عمدتاً شامل درصد بالایی از کوارتز بوده است که بررسی نگار شاخص شکنندگی به دست آمده از درصد حجمی کانی‌ها مبین درصد حجمی بالای کوارتز در این محدوده‌ها می‌باشد. در محدوده ۳۶۰۰ تا ۳۶۱۰ متری بیش از ۵۰ درصد حجمی، در محدوده ۳۶۴۰ تا ۳۶۴۵ متری بیش از ۴۰ درصد حجمی و در محدوده ۳۷۰۰ تا ۳۷۱۰ متری بیش از ۴۰ درصد حجمی کوارتز را شامل می‌شود که تایید کننده نتایج فوق می‌باشد.

جهت تعیین شاخص شکنندگی با استفاده از حجم کانی‌ها از رابطه جارویه و همکاران (Jarvie et al., 2007) (رابطه ۱۲)، استفاده شده است در این رابطه شاخص شکنندگی تابعی از حجم کوارتز، کربناته و رس می‌باشد. این رابطه، شاخص شکنندگی بر حسب کانی (BI_{lit}) را بر حسب حجم کوارتز (V_z)، حجم رس (V_{cl}) و حجم کربناته (V_{ca}) بیان کرده است.

$$BI_{lit} = \frac{V_z}{V_z + V_{cl} + V_{ca}} \quad (12)$$

شکل ۱۶، نمودار حاصل از درصد حجمی کانی‌ها با استفاده از رابطه جارویه و مقایسه آن با شاخص شکنندگی دینامیک و استاتیک را نشان می‌دهد. با بررسی این نمودارها می‌توان تطابق مناسبی بین شاخص شکنندگی دینامیک، استاتیک و شاخص



شکل ۱۶. نمودارهای شاخص شکنندگی. الف) شاخص شکنندگی دینامیک (شاخص شکنندگی داده واقعی رنگ مشکی و شاخص شکنندگی پیش‌بینی شده رنگ قرمز). ب) شاخص شکنندگی استاتیک (با استفاده از رابطه چریستارس رنگ مشکی و با استفاده از رابطه برتفورد رنگ قرمز). ج) شاخص شکنندگی با استفاده از درصد حجمی کانی‌ها.

CALIPER دارای بیشترین همبستگی بودند و به‌عنوان ورودی الگوریتم انتخاب شدند. در ادامه الگوریتم MLP بر روی داده‌های آموزش، تست و داده‌های کور اعمال شد که برای آموزش مدل از دو لایه که لایه اول شامل ۵۰۰ و لایه دوم ۱۰۰ لایه و پارامترهای نرخ یادگیری، تعداد تکرار و اندازه دسته به ترتیب ۰/۰۰۰۱، ۳۰۰ و ۵۰ انتخاب گردید و جهت ارزیابی نتایج مدل‌ها RMSE, MSE و R^2 محاسبه گردید که ضریب تعیین (R^2) داده کور ۰/۸۸۷۵ به دست آمده است. نتایج به‌دست آمده با روابط گاستاگنا، اسکندری و بروچر مقایسه گردید و نشان داده شد که نتایج روش MLP نسبت به روابط تجربی دارای دقت بالاتری می‌باشد. به همین دلیل از خروجی این الگوریتم برای تخمین سرعت موج برشی و سایر پارامترهای ژئومکانیکی استفاده شده است. در مرحله بعد نسبت پواسون و مدول یانگ دینامیک و استاتیک جهت تخمین مقاومت فشاری تک محوره و شاخص شکنندگی محاسبه شد. در ادامه مقاومت فشاری تک محوره، مقاومت کششی، شاخص شکنندگی دینامیک و استاتیک و شاخص شکنندگی با استفاده از حجم کانی‌ها محاسبه و نتایج حاصل از این سه شاخص شکنندگی با هم مقایسه گردید که نتایج بیانگر این است که در محدوده‌هایی که درصد حجمی کوارتز افزایش پیدا می‌کند شاخص شکنندگی دینامیک و استاتیک نیز افزایش پیدا کرده است. با توجه به نتایج حاصل شده می‌توان بیان کرد که با تلفیق روش‌های یادگیری ماشین، روابط تجربی و به کمک داده‌های نگارهای متداول می‌توان پارامترهای ژئومکانیکی را با دقت مناسب تخمین زد.

در این مقاله پارامترهای ژئومکانیکی با استفاده از داده‌های نگارچاه و الگوریتم MLP تخمین زده شد. ابتدا سرعت موج برشی با استفاده از شبکه عصبی پرسپترون چندلایه تخمین زده شد و در ادامه نسبت پواسون و مدول یانگ دینامیک و استاتیک جهت محاسبه مقاومت فشاری تک محوره، مقاومت کششی و شاخص شکنندگی به دست آمد. در مرحله بعد شاخص شکنندگی دینامیک، استاتیک و شاخص شکنندگی با استفاده از لیتولوژی محاسبه و نتایج شاخص شکنندگی دینامیک و استاتیک با شاخص شکنندگی حاصل از لیتولوژی مقایسه گردید که تطابق خوبی بین شاخص شکنندگی حاصل از سه روش حاصل شد. نتایج بیانگر کارایی تلفیق روش‌های یادگیری ماشین و روابط تجربی با استفاده از داده‌های نگارچاه جهت تخمین پارامترهای ژئومکانیکی می‌باشد.

۶. نتیجه‌گیری

با توجه به جایگاه ویژه‌ای که امروزه ژئومکانیک در مطالعات نفتی پیدا کرده است در این مطالعه تلاش شده است با استفاده از یکی از روش‌های یادگیری ماشین، روابط تجربی و داده‌های نگارهای متداول چاه پارامترهای ژئومکانیکی تخمین زده شود. در این مطالعه از الگوریتم MLP برای تخمین سرعت موج برشی در یکی از چاه‌های موجود در یکی از میادین جنوب غرب ایران استفاده شده است. جهت اعمال الگوریتم روی داده‌ها ابتدا ویژگی‌های مناسب جهت ورودی‌های این الگوریتم‌ها با استفاده از ضریب همبستگی پیرسون تعیین شد و از بین داده نگارهای موجود، نگارهای V_p , $RHOB$, $NPHI$

منابع

- آشتیانی عبدی، ه.، ۱۳۸۸. دانش نوپای ژئومکانیک مخازن هیدروکربوری. مجله اکتشاف و تولید. شماره ۳۳.
- آشتیانی عبدی، ه.، ۱۳۸۹. دانش نوپای ژئومکانیک مخازن هیدروکربوری (جمع‌آوری داده‌ها و تشکیل مدل ژئومکانیکی). مجله اکتشاف و تولید، شماره ۳۹.
- مطیعی، ه.، ۱۳۷۲، زمین‌شناسی ایران، چینه‌شناسی زاگرس. سازمان زمین‌شناسی کشور، ۵۳۶ صفحه.
- Ahmed, A., Elkhatny, S. Alsaihati, A., 2021. Applications of artificial intelligence for static Poisson's ratio prediction while drilling, *Computational Intelligence and Neuroscience*, 2021(1), p.9956128.
- Alavi, A. H., Gandomi, A. H., Mollahasani, A., Heshmati, A. A. R., Rashed, A., 2010. Modeling of maximum dry density and optimum moisture content of stabilized soil using artificial neural networks, *Journal of Plant Nutrition and Soil Science*, 173(3), 368-379.

- Altindag, R., 2010. Assessment of some brittleness indexes in rock-drilling efficiency, *Rock mechanics and rock engineering*, 43(3), 361-370.
- Armaghani, D. J., Safari, V., Fahimifar, A., Mohd Amin, M.F., Monjezi, M. Mohammadi, M.A., 2018. Uniaxial Compressive Strength Prediction through a New Technique Based on Gene Expression Programming, *Neural Computing and Applications*, 30, 3523-3532.
- Bradford, I.D.R., Fuller, J., Thompson, P.J., Walsgrove, T.R., 1998. Benefits of assessing the solids production risk in a North Sea reservoir using elastoplastic modelling, In *SPE/ISRM rock mechanics in petroleum engineering* (pp. SPE-47360). SPE.
- 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):2081-92.
- Castagna, J. P., Batzle, M. L., Eastwood, R. L., 1985. Relationships between compressional wave and shear-wave velocities in clastic silicate rocks. *Geophysics* 50 (4), 571-581.
- Christaras, B., 1997. Landslides in iliolitic and marly formations; examples from north-western Greece, *Engineering Geology*, 47(1-2), 57-69.
- Ebrahimi, A., Izadpanahi, A., Ebrahimi, P., Ranjbar, A., 2022. Estimation of shear wave velocity in an Iranian oil reservoir using machine learning methods, *Journal of Petroleum Science and Engineering*, 209, p.109841.
- 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*, 29, 42-48.
- Faraj, A., Abdul Hussein, H., Al-Hasnawi, A. N., 2022. Estimation of Internal Friction Angle for The Third Section in Zubair Oil Field: A Comparison Study, *Iraqi Journal of Oil and Gas Research (IJOGR)*, 2(2), 102-111.
- Ghabaei sough, M., Assadi, A., Hesam, M., Khazjerribi, A., 2010. Evaluation of the Effect of Preprocessing of Artificial Neural Network input parameters (ANNs) using stepwise and gamma regression methods to estimate faster evapotranspiration of water and soil (science And Agricultural Industries): August and September 2010, 24 (3), 610-624 (In Persian).
- Ghobadi, M. H., Naseri, F., 2016. Rock Brittleness Prediction Using Geomechanical Properties of Hamekasi Limestone: Regression and Artificial Neural Networks Analysis. *Journal of Geopersia*, 6 (1), 19-33.
- Gholami, A., Seyedali, S. M., Ansari, H. R. 2020. Estimation of shear wave velocity from post-stack seismic data through committee machine with cuckoo search optimized intelligence models, *Journal of Petroleum Science and Engineering*, 189, p.106939.
- Gholami Vijouyeh, A., Kadkhodaie, A., Hassanpour Sedghi, M., 2022. A committee machine with intelligent experts (CMIE) for estimation of fast and slow shear wave velocities utilizing petrophysical logs, *Computers & Geosciences*, 165, p.105149.
- Ghorbani, H., Davoodi, S., Davarpanah, A., 2021. Accurate determination of shear wave velocity using LSSVM-GA algorithm based on petrophysical log. In *Third EAGE Eastern Mediterranean Workshop (2021(1), 1-3)*. European Association of Geoscientists & Engineers.
- Jarvie, D.M., Hill, R.J., Ruble, T.E., Pollastro, R.M., 2007. Unconventional shale-gas systems: The Mississippian Barnett Shale of north-central Texas as one model for thermogenic shale-gas assessment. *AAPG bulletin*, 91(4), 475-499.
- Jin, X., Zhao, R., Ma, Y., 2022. Application of a Hybrid Machine Learning Model for the Prediction of Compressive Strength and Elastic Modulus of Rocks, *Minerals*, 12(12), p.1506.
- Kaunda, R. B., and Asbury, B., 2016. Prediction of rock brittleness using nondestructive methods for hard rock tunneling, *Journal of Rock Mechanics and Geotechnical Engineering*, 8(4), 533-540.
- Lashkaripour, G. R., Rastegarnia, A., Ghafoori, M., 2018. Assessment of brittleness and empirical correlations between physical and mechanical parameters of the Asmari limestone in Khersan 2 dam site, in southwest of Iran, *Journal of African Earth Sciences*, 138: 124-132.
- Nasrnia, B., Falahat, R., Kadkhodaie, A., Gholami Vijouyeh, A., 2023. A committee machine-based estimation of shear velocity log by combining intelligent systems and rock-physics model using metaheuristic algorithms, *Engineering Applications of Artificial Intelligence*, 126, p.106821.

- Ore, T., and Gao, D., 2021. Supervised machine learning to predict brittleness using well logs and seismic signal attributes: Methods and application in an unconventional reservoir, In SEG International Exposition and Annual Meeting (p. D011S064R005). SEG.
- Plumb, R.A., 1994. Influence of composition and texture on the failure properties of clastic rocks, In SPE/ISRM Rock Mechanics in Petroleum Engineering (pp. SPE-28022). SPE.
- Shahani, N.M., Zheng, X., Liu, C., Hassan, F. U., Li, P., 2021. Developing an XGBoost Regression Model for Predicting Young's Modulus of Intact Sedimentary Rocks for the Stability of Surface and Subsurface Structures, *Frontiers in Earth Science*, 9, p.761990.
- Shahani, N.M., Ullah, B., Shah, K. S., Fawad, U. I., Hassan, F. U., Rashid Ali, R., Elkotb, M. A., Ghoneim, M., Tag-Eldin, E., 2022. Predicting Angle of Internal Friction and Cohesion of Rocks Based on Machine Learning Algorithms, *Mathematics*, 10(20), p.3875.
- Siddig, O., and Elkatatny, S., 2021. Workflow to build a continuous static elastic moduli profile from the drilling data using artificial intelligence techniques, *Journal of Petroleum Exploration and Production Technology*, 11(10), 3713-3722.
- Valim. S.M., and Antia. L.S., 2021. The Use of Well-Log Data in the Geomechanical Characterization of Middle Cambrian Tight Sandstone Formation: A Case Study from Eastern Pomerania, Poland, *Energies*, 14(19), p.6022.
- Wang, M., and Wan, W., 2019. A New Empirical Formula for Evaluating Uniaxial Compressive Strength Using the Schmidt Hammer Test, *International Journal of Rock Mechanics and Mining Sciences*, 123, p.104094.
- Wang, Z., Wang, Z., Nur, A., 2000. Dynamic vs. static properties of reservoir rocks. Seismic and acoustic velocities in reservoir rocks, 3, recent developments. SEG, Tulsa.
- Zhang, Y., Zhong, H. R., Wu, Z., Zhou, H., Ma, Q., 2020. Improvement of petrophysical workflow for shear wave velocity prediction based on machine learning methods for complex carbonate reservoirs, *Journal of Petroleum Science and Engineering*, 192, p.107234.

علائم اختصاری

AI	Artificial intelligence
ANN	Artificial neural network
BI	Brittleness index
BPANN	Backpropagation artificial neural
network	
CALI	Caliper log
CNL	Compensate neutron log
CNN	Convolutional neural network
DL	Deep learning
DNN	Deep neural network
DT	Time Transit (Sonic Log)
ELM	Extreme learning machine
ENN	Elman neural network
FFANN	Feedforward artificial neural
network	
FL	Fuzzy logic
GA	Genetic algorithm
GR	Gamma ray log
LSTM	Long short-term memory networks
LL7	Latero Log 7
ML	Machine learning technique
MLL	Micro Latero Log
MLEM	Multi extreme learning machine
MLP	Multi-layer perceptron
MSE	Mean square error

NEUT	Neutron porosity
PEF	Photoelectric Log
R2	Coefficient of determination
RHOB	Density log
RMSE	Root mean square error
RNN	Recurrent neural network
RT	Formation true resistivity
SVM	Support vector machine
SVR	Support vector regression
Vs	Shear wave velocity
Vp	Compressional wave velocity