

تخمین سرعت موج برشی به روش رگرسیون فرایند گاوسی، رگرسیون چندمتغیره و شبکه عصبی مصنوعی پرسپترون چند لایه

محسن صفاریان^۱، امین ایرجی^۲ و امیر آزادمهر^{۳*}

۱- استادیار گروه مهندسی صنایع، دانشگاه صنعتی بیرجند، بیرجند، ایران

۲- استادیار دانشکده فنی و مهندسی، دانشگاه صنعتی ارومیه، ارومیه، ایران

۳- استادیار گروه مهندسی معدن، دانشگاه صنعتی بیرجند، بیرجند، ایران

نویسنده مسئول: *a.azadmehr@birjandut.ac.ir

نوع مقاله: کاربردی

پذیرش: ۱۴۰۱/۱۰/۲۱

دریافت: ۱۴۰۱/۵/۱۴

چکیده

تخمین سرعت امواج برای طراحی سازه‌های ژئوتکنیکی و مدل‌سازی حفاری‌های عمیق اهمیت زیادی دارد. هدف از این مطالعه تخمین سرعت موج برشی به روش رگرسیون فرایند گاوسی با استفاده از تابع کرنل نمایی، شبکه عصبی مصنوعی و رگرسیون چندمتغیره می‌باشد. به منظور انجام این مطالعه، ۱۴ بلوک سنگی از شمال غرب شهر دماوند تهیه و بعد از انتقال به آزمایشگاه از آن‌ها مغزه‌گیری شد. جهت توسعه یک مدل پیش‌بینی کننده، آزمایش‌های شاخص بار نقطه‌ای، سرعت موج تراکمی، تخلخل و دانسیته بر روی ۶۱ نمونه مغزه سنگی انجام شد. شاخص بار نقطه‌ای، سرعت موج تراکمی، تخلخل و چگالی به عنوان پارامترهای ورودی مدل‌ها به منظور پیش‌بینی سرعت موج برشی استفاده شدند. نتایج مطالعات سنگ‌شناسی نشان داد که ماسه‌سنگ‌های مورد مطالعه، فلدسپاتیک لیتارنایت و لیت‌آرنایت می‌باشند. نتایج نشان داد که نسبت سرعت موج تراکمی به سرعت موج برشی بطور متوسط برابر با ۱/۷۰ می‌باشد. نتایج شبکه عصبی مصنوعی پرسپترون چند لایه نشان داد که بیش‌ترین دقت مدل‌ها با استفاده از قانون آموزش لوبنبرگ مارکوارت حاصل شده است. دقیق‌ترین مدل‌ها با استفاده از این الگوریتم برای تخمین سرعت موج برشی در نوروں شماره ۲ (نوروں بهینه) حاصل شد. روش رگرسیون فرایند گاوسی، شبکه عصبی مصنوعی و رگرسیون چندمتغیره سرعت موج برشی را به ترتیب با ضرایب همبستگی ۰/۹۷، ۰/۹۶ و ۰/۹۵ پیش‌بینی نمودند. روش رگرسیون فرایند گاوسی عملکرد بهتری در پیش‌بینی سرعت موج برشی نسبت به سایر روش‌ها نشان داد.

واژه‌های کلیدی: خصوصیات فیزیکی و مکانیکی، ماسه‌سنگ، رگرسیون فرایند گاوسی، شبکه عصبی مصنوعی پرسپترون چندلایه، رگرسیون خطی چندمتغیره

۱- پیشگفتار

متغیری برخوردار هستند (الوسای و همکاران، ۱۹۹۴؛ عبدی و همکاران ۲۰۱۸؛ هسیه و همکاران، ۲۰۰۸). میزان تخلخل، مقدار و نوع سیمان و نیز ترکیب و بافت ذرات تشکیل دهنده خصوصیات مهندسی این سنگ‌ها را تحت تاثیر قرار می‌دهند. به طوریکه ماسه‌سنگ‌های با سیمان‌شدگی بیشتر و تخلخل کمتر مقاومت بالاتری دارند (هسیه و همکاران، ۲۰۰۸). خصوصیات بافتی، پتروفیزیکی، دینامیکی و مکانیکی ماسه‌سنگ‌های کوارتزی هیمالیا مورد مطالعه قرار گرفت و با استفاده از آنالیزهای رگرسیونی ارتباط بین این ویژگی‌ها تعیین گردید (گوپتا و شارما، ۲۰۱۲). قبادی و همکاران (۱۴۰۰) خصوصیات سنگ‌شناسی، ویژگی‌های فیزیکی و مکانیکی ماسه‌سنگ‌ها بررسی کردند. نتایج مطالعه ایشان نشان داد

سرعت امواج بخصوص سرعت موج برشی از پارامترهای چون سرعت موج تراکمی، حضور سیالات منفذی، تخلخل، چگالی و مقاومت سنگ تاثیر می‌پذیرد. سرعت امواج جهت محاسبه مدول الاستیک اندازه‌گیری می‌شوند. مدول الاستیک به عنوان یکی از مهم‌ترین پارامترهای مکانیکی، بیانگر سفتی سنگ می‌باشد به طوریکه جزء اصلی‌ترین پارامترهای تحلیل و طراحی قلمداد می‌شود که تعیین آن تقریباً در تمامی پروژه‌های عمرانی و معدنی غیر قابل اجتناب است (مارتینز-مارتینز و همکاران، ۲۰۱۲؛ یاسار و همکاران، ۲۰۱۰؛ مهدی‌آبادی و خانلری، ۲۰۱۸). ماسه‌سنگ‌ها به دلیل تنوع در ترکیب سنگ‌شناسی از خصوصیات فیزیکی و مکانیکی بسیار

مرتبط کنند (ذرلو و همکاران، ۲۰۰۸؛ تاماراکار و همکاران، ۲۰۰۷). با این وجود این روابط محدود به چند شاخص برای انواع محدودی از ماسه‌سنگ‌ها می‌باشند. از اینرو، استفاده از چنین روابط تجربی به منظور پیش‌بینی خصوصیات ماسه‌سنگ‌های نقاط دیگر از دقت لازم برخوردار نخواهند بود. در چنین شرایطی تعیین روابط تجربی بین خصوصیات فیزیکی و دینامیکی ماسه‌سنگ‌های هر منطقه ضرورت دارد.

هدف اصلی این تحقیق تخمین سرعت موج برشی نمونه‌های ماسه‌سنگ با استفاده از آزمون‌های ساده و غیرمخرب سرعت موج طولی، تخلخل، شاخص بار نقطه‌ای و چگالی با استفاده از GPR رگرسیون چندمتغیره^۲ (MVLRL) و شبکه عصبی مصنوعی پرسپترون چندلایه^۳ (MLP-ANN) می‌باشد. برای انجام این کار مطالعات پتروگرافی، آزمون‌های دینامیکی، فیزیکی و شاخص بار نقطه‌ای بر روی نمونه‌های ماسه‌سنگ تهیه شده از سازند لالون در شمال غرب شهر دماوند- روستای مشا انجام شد (شکل ۱). سازند لالون از سازندهای زمین‌شناسی ایران در البرز با سن کامبرین پیشین است. ماسه‌سنگ‌های سازند لالون پی‌سنگ بسیاری از سازه‌های مهندسی شمال استان تهران را در بر می‌گیرند و از این جهت بررسی خصوصیات مهندسی آن‌ها حائز اهمیت می‌باشد.

۲- مواد و روش‌ها

۲-۱- مواد استفاده شده در تحقیق

به منظور انجام این مطالعه، ۱۴ بلوک سنگی از شمال غرب شهر دماوند تهیه شد و به آزمایشگاه منتقل و برای انجام آزمایش‌های آزمایشگاهی آماده گردیدند. برای جلوگیری از تأثیر هرگونه ناهمسانی بر روی نتایج آزمون‌ها، بلوک‌های جمع‌آوری شده باید فاقد هرگونه درزه، ترک و آثار هوازدگی باشند (لطف‌الهی و همکاران، ۲۰۱۸). نمونه‌های استوانه‌ای با استفاده از دستگاه مغزه‌گیر تهیه و برای برش و ساب دو سر نمونه‌ها از دستگاه برش اره‌ای و ماشین ساب آزمایشگاه استفاده گردید. قطر نمونه‌های استوانه‌ای تهیه شده ۵۴ میلی‌متر و نسبت طول به قطر آن‌ها حدود ۲ می‌باشد.

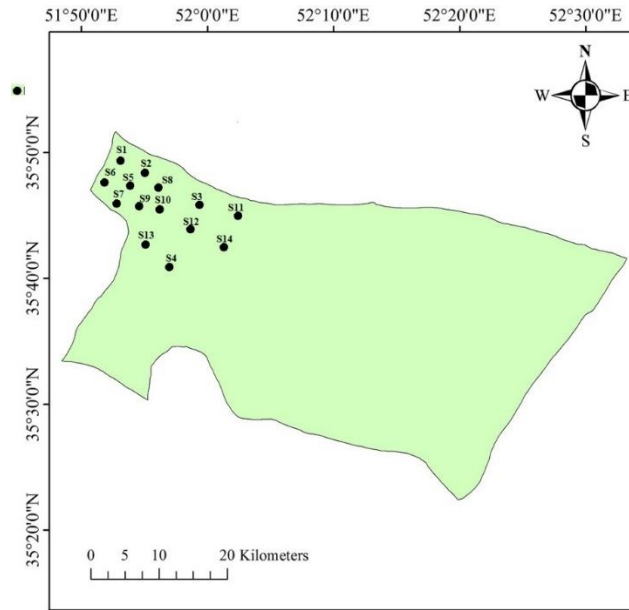
که تفاوت در خصوصیات سنگ‌شناسی و فیزیکی ماسه‌سنگ‌ها منجر به تغییر در خصوصیات مکانیکی آن‌ها شده است و انطباق مناسبی بین نتایج آزمایش مقاومتی با سرعت موج طولی در حالت خشک و اشباع وجود دارد. اجل‌لوئیان و همکاران (۲۰۲۰) تأثیر ویژگی‌های پتروگرافی بر سرعت موج برشی سنگ‌های گرانیتی را بررسی کردند. عبدی و همکاران (۱۳۹۷) خصوصیات مکانیکی ماسه‌سنگ‌های سازند قرمز بالایی با استفاده از ویژگی‌های فیزیکی در چرخه‌های مختلف آزمایش انجماد- ذوب را بررسی کردند. لاوال و همکاران (۲۰۲۲) رگرسیون فرایند گاوسی^۱ (GPR)، شبکه عصبی مصنوعی (ANN) و روش سطح پاسخ (RSM) برای پیش‌بینی خواص استاتیکی و دینامیکی سنگ از موج تراکمی و چگالی سنگ بکار بردند. نتیجه مطالعه آن‌ها نشان داد که GPR نتایج دقیق‌تری نسبت به مدل‌های ANN و RSM ارائه می‌کند. مومنی و همکاران (۲۰۲۰) از GPR برای پیش‌بینی ظرفیت باربری شمع استفاده کرد. همچنین گائو و همکاران (۲۰۱۸) تکه تکه شدن سنگ را با استفاده از روش GPR تخمین زد. دائو و همکاران (۲۰۲۰) از MFFNN و GPR برای تخمین مقاومت فشاری نمونه‌های بتنی استفاده کردند. جاهد ارمغانی و همکاران (۲۰۲۰) شکنندگی سنگ را با استفاده از SVM پیش‌بینی کرد. همچنین ویسواناتان و سامویی (۲۰۱۶) عمق سنگ کف را با استفاده از روش GPR پیش‌بینی کردند. محمودزاده و همکاران (۲۰۲۱) شاخص کیفیت سنگ (RQD) را با استفاده از چندین روش پیش‌بینی کرد و بیان کرد که روش GPR بهتر از روش‌های دیگر عمل می‌کند.

استفاده از شبکه عصبی مصنوعی در زمینه مهندسی به دلیل پویا بودن، رویکرد مناسبی برای پیش‌بینی و مدل سازی می‌باشد (شمس‌شریعتی و عامری، ۲۰۱۸). مطالعات مختلف نشان داده است که شبکه عصبی مصنوعی از دقت بالایی در پیش‌بینی ویژگی‌های دینامیکی سنگ‌ها برخوردار است (واشکیویچ و همکاران، ۲۰۱۹؛ لاوال و همکاران، ۲۰۲۲). از سوی دیگر، محققان بسیاری سعی کرده‌اند با استفاده از آنالیزهای رگرسیونی تأثیر خصوصیات پتروگرافی ماسه‌سنگ‌ها را با ویژگی‌های مهندسی آن‌ها


³ Multilayer Perceptron Artificial Neural Network (MLP-ANN)

¹ Gaussian process regression (GPR)

² Multivariate linear regression (MVLRL)



شکل ۱. مختصات جغرافیایی بلوک‌های سنگی



شکل ۲. روش تعیین شاخص بار نقطه‌ای (ASTM, 2002)

۲-۲- روش‌های استفاده شده

۲-۲-۱- آزمایش‌های مکانیک سنگ

آزمایش‌های مکانیک سنگ بر روی ۴۳ نمونه در شرایط خشک و ۱۸ نمونه در شرایط اشباع انجام شد. در مجموع آزمایش‌های فیزیکی، مکانیکی و دینامیکی بر روی ۶۱ نمونه انجام شد. آزمایشات فیزیکی مانند چگالی (ρ) و تخلخل (n) نمونه‌ها نیز براساس روش‌های پیشنهادی انجمن بین‌المللی مکانیک سنگ انجام شد (ISRM, 1981). تخلخل نمونه‌ها به روش اشباع و غوطه‌وری تعیین گردید. آزمایش‌های التراسونیک جهت اندازه‌گیری سرعت امواج تراکمی (V_p) و برشی (V_s) مطابق استاندارد ASTM D2845 انجام شد (ASTM, 1983). قبل از انجام آزمایش سر و ته نمونه‌ها با استفاده از گریس صیقلی شد. فرکانس مورد استفاده در این آزمایش‌ها 0.5 MHz می‌باشد.

آزمایش شاخص بار نقطه‌ای بر روی نمونه‌های بی‌شکل مطابق استاندارد ASTM D5731 انجام شد (ASTM, 2002). سپس با استفاده از روابط ۱ تا ۴ شاخص بار نقطه برای برای قطر ۵۰ میلی‌متر (Is50) اصلاح شد.

$$Is50 = F \left(\frac{P}{D_e^2} \right) \quad (1)$$

$$D_e^2 = \frac{4A}{\pi}, \quad A=WD \quad (2)$$

در این روابط P حداکثر بار، D_e قطر مغزه معادل برای حالت قطری و سایر حالت‌ها، W کوچک‌ترین عرض نمونه عمود بر جهت بارگذاری می‌باشد. D فاصله بین صفحات در هنگام شکست برای آزمایش بار نقطه‌ای محوری می‌باشد. F فاکتور اصلاح اندازه می‌باشد (شکل ۲) که معادل با:


$$F = \left(\frac{D_e}{50} \right)^{0.45} \quad (3)$$

۲۰۸

از نوع سیلت بوده و سیمان نمونه از جنس کلسیت و اکسید آهن است. در شکل ۳ تصاویری از مقاطع نازک نمونه شماره ۶ و نمونه شماره ۱۵ ارائه شده است. در این شکل، Q: کوارتز، Op: کانی‌های تیره، CR: خرده‌های کربناته و F: فلدسپات می‌باشند.

۳-۲- نتایج آزمایش‌های فیزیکی، مکانیکی و دینامیکی

نتایج مطالعات آزمایشگاهی بر روی ۶۱ مغزه ماسه‌سنگ (۱۸ نمونه اشباع و ۴۳ نمونه خشک) مورد مطالعه در جدول ۱ ارائه شده است. در تحقیق حاضر، به طور متوسط سرعت موج تراکمی همه ماسه‌سنگ‌های مورد مطالعه $V_p/V_s=1.70$ برابر بزرگ‌تر از سرعت موج برشی می‌باشند. متوسط تخلخل همه نمونه‌ها (خشک و اشباع) ۵/۶۷ درصد است. طبق طبقه‌بندی آنون (۱۹۷۹)، نمونه‌ها در طبقه تخلخل نسبتاً کم قرار دارند. همچنین چگالی ۲/۶۱ گرم بر سانتی‌متر مکعب است که بر اساس طبقه‌بندی آنون، ماسه‌سنگ‌ها از نظر چگالی در رده بالا قرار می‌گیرند. بر اساس طبقه‌بندی به روش براش و فرانکلین (۱۹۷۲)، میانگین شاخص بار نقطه‌ای (۲/۷۶) مگاپاسکال) همه نمونه‌ها (خشک و اشباع) در طبقه مقاومت بالا طبقه‌بندی می‌شوند. همچنین، بر اساس طبقه‌بندی آنون، همه نمونه‌ها با متوسط سرعت موج تراکمی ۴/۴۳ کیلومتر بر ثانیه در رده بالا طبقه‌بندی می‌شوند.



شکل ۳. مقطع نازک از نمونه شماره ۱۵ (سمت راست: نمونه اشباع) و نمونه شماره ۶ (سمت چپ: نمونه خشک)، (Q یا Qtz: کوارتز، Op: کانی‌های تیره، CR: خرده‌های کربناته و F: فلدسپات).

تخمین، به ترتیب از روابط ۱۴ و ۱۵ به دست می‌آیند (هی و سیو، ۲۰۱۱؛ یانگ و همکاران، ۲۰۱۸).

$$\bar{f}_{*} = K(X_{*}, X) [K(X, X) + \sigma_n^2]^{-1} y \quad (14)$$


$$\text{cov}(f_{*}) = K(X_{*}, X_{*}) - K(X_{*}, X) [K(X, X) + \sigma_n^2 I]^{-1} K(X, X_{*}) \quad (15)$$

معادله ۱۴ نشان می‌دهد که میانگین پیش‌بینی، یک ترکیبی خطی از مشاهده با خطای y است (هی و سیو، ۲۰۱۱). برای ماتریس‌های کوواریانس علامت‌های $K(X^{*}, X)$ ، $K(X, X^{*})$ ، $K(X^{*}, X^{*})$ شبیه نماد قبلی $K(X, X)$ هستند. به طور کلی کدگذاری GPR با این فرض است که احتمالاً ورودی‌های نزدیک به هم دارای خروجی‌های مشابه هستند، از این رو به نمونه‌هایی با نقطه دارای مقادیر مشابه، وزن‌های بالاتری اختصاص داده می‌شود. در این تحقیق از ۷۰ درصد داده‌ها برای آموزش و از ۳۰ باقیمانده داده‌ها به منظور آزمون مدل استفاده شد.

۳- نتایج

۳-۱- نتایج مطالعات میکروسکوپی

بررسی‌های میکروسکوپی بر روی مقاطع نازک از نمونه‌ها نشان داد که بافت نمونه‌های مورد مطالعه آواری یا دانه‌ای می‌باشد و از لحاظ بلوغ بافتی ایم‌مچور^{۱۲} تا ساب‌مچور^{۱۳} می‌باشند. نام نمونه‌های ماسه‌سنگ مورد مطالعه براساس طبقه‌بندی فولک، فلدسپاتیک لیت‌آرنایت و لیت‌آرنایت می‌باشد. ترکیب کانی‌شناسی شامل چرت، آهک فسفات و خرده‌سنگ‌های ریز بلور می‌باشند. ماتریکس نمونه‌ها غالباً



¹³ sub-mature

¹² immature

جدول ۱. نتایج مطالعات آزمایشگاهی بر روی مغزه‌ها

شرایط نمونه	شماره نمونه	ρ (g/cm ³)	Vs (km/s)	Vp (km/s)	n (%)	Is50 (MPa)	شرایط نمونه	شماره نمونه	ρ (g/cm ³)	Vs (km/s)	Vp (km/s)	n (%)	Is50 (MPa)
خشک	1	2.60	2.80	4.27	1.01	3.00	اشباع	1	2.70	2.59	5.12	5.97	2.70
خشک	2	2.63	2.71	4.33	1.00	2.90	اشباع	2	2.73	2.61	5.19	5.79	2.71
خشک	3	2.70	2.80	4.29	0.70	3.00	اشباع	3	2.80	2.60	5.15	5.90	2.68
خشک	4	2.62	2.84	4.66	1.00	3.05	اشباع	4	2.72	2.68	5.60	4.84	2.77
خشک	5	2.55	2.65	4.07	2.47	2.83	اشباع	5	2.65	2.59	4.89	6.02	2.70
خشک	6	2.51	2.50	3.94	4.50	2.66	اشباع	6	2.61	2.55	4.73	6.56	2.60
خشک	7	2.66	2.68	4.71	0.80	2.87	اشباع	7	2.76	2.69	5.66	4.70	2.75
خشک	8	2.60	2.70	4.09	1.01	2.89	اشباع	8	2.70	2.56	4.91	6.47	2.80
خشک	9	2.61	2.72	4.00	2.00	2.91	اشباع	9	2.71	2.54	4.80	6.74	2.67
خشک	10	2.48	2.49	3.33	10.00	2.65	اشباع	10	2.58	2.52	3.99	6.97	2.60
خشک	11	2.50	2.40	2.90	13.00	2.54	اشباع	11	2.60	2.54	3.48	6.70	2.68
خشک	12	2.52	2.53	3.51	13.00	2.69	اشباع	12	2.62	2.56	4.22	6.43	2.68
خشک	13	2.58	2.57	3.35	12.00	2.74	اشباع	13	2.68	2.40	4.01	8.59	2.40
خشک	14	2.58	2.56	3.78	9.00	2.73	اشباع	14	2.68	2.49	4.53	7.36	2.50
خشک	15	2.47	2.45	3.67	14.00	2.60	اشباع	15	2.57	2.52	4.40	6.97	2.50
خشک	16	2.74	2.86	5.74	0.06	3.07	اشباع	16	2.84	2.91	6.80	0.08	3.00
خشک	17	2.78	2.90	5.95	0.22	3.12	اشباع	17	2.88	2.95	7.14	0.07	3.02
خشک	18	2.50	2.51	4.81	3.66	2.67	اشباع	18	2.60	2.54	5.77	6.70	2.80
خشک	19	2.68	2.77	5.19	1.34	3.00	میانگین		2.69	2.60	5.02	5.71	2.70
خشک	20	2.60	2.70	3.69	8.73	2.89							
خشک	21	2.65	2.71	4.89	3.00	2.90							
خشک	22	2.40	2.50	4.17	9.00	2.66							
خشک	23	2.78	2.88	5.83	0.16	3.09							
خشک	24	2.69	2.63	4.44	1.22	2.81							
خشک	25	2.43	2.26	3.83	9.00	2.38							
خشک	26	2.54	2.60	3.92	6.00	2.77							
خشک	27	2.35	2.35	3.69	8.28	2.49							
خشک	28	2.61	2.72	4.60	6.00	2.91							
خشک	29	2.50	2.50	4.23	8.00	2.66							
خشک	30	2.53	2.56	4.29	7.00	2.73							
خشک	31	2.41	2.60	4.17	8.00	2.77							
خشک	32	2.39	2.35	3.45	8.00	2.49							
خشک	33	2.61	2.71	4.45	7.00	2.90							
خشک	34	2.44	2.35	3.66	8.00	2.49							
خشک	35	2.35	2.40	3.60	8.39	2.54							
خشک	36	2.59	2.51	3.75	7.00	2.67							
خشک	37	2.63	2.53	3.85	6.00	2.69							
خشک	38	2.60	2.70	4.22	7.00	2.99							
خشک	39	2.65	2.74	4.35	4.03	3.03							
خشک	40	2.47	2.42	3.98	9.00	2.67							
خشک	41	2.63	2.73	3.97	7.50	2.98							
خشک	42	2.69	2.55	3.99	3.39	2.82							
خشک	43	2.74	2.57	4.06	2.36	2.84							
میانگین		2.57	2.61	4.18	5.65	2.79							

به سنگ‌های آواری محدودتر است اما سنگ‌های کربناتی خالص دارای محدوده گسترده‌ای از سرعت امواج هستند. به طور کلی سرعت امواج تراکمی در کربنات‌ها ۶۶۰۰ تا ۱۷۰۰ متر بر ثانیه، و سرعت امواج برشی در کربنات‌ها بین ۳۵۰۰ تا ۶۰۰ متر بر ثانیه است. پس می‌توان عنوان کرد که در سنگ‌های کربناتی نوع کانی‌ها نقش کم رنگی در کنترل سرعت امواج دارند. این نکته توسط وانوریو و همکاران (۲۰۰۸) به این صورت بیان شده است که تغییرات سرعت امواج صوتی در کربنات‌ها به طور عمده به وسیله نوع و میزان تخلخل کنترل می‌شود.

جدول ۲ رابطه بین نسبت سرعت موج تراکمی به برشی با نوع سنگ‌شناسی را نشان می‌دهد. همچنین محدوده سرعت موج برشی برای سنگ‌های مختلف توسط شون (۲۰۱۱) ارائه شده است. در ماسه‌سنگ‌ها کانی‌شناسی به عنوان عاملی موثر در کنترل سرعت امواج می‌باشد (ابری و همکاران، ۲۰۰۳). زیرا این دسته از سنگ‌ها، کانی‌شناسی متنوعی دارند. اما در مورد کربنات‌ها وضعیت با سنگ‌های آواری متفاوت است، با وجود این که کانی‌شناسی سنگ‌های کربناتی (کلسیت، دولومیت و آراگونیت) نسبت

جدول ۲. رابطه بین نسبت سرعت موج تراکمی به برشی با نوع سنگ‌شناسی (پیکت، ۱۹۶۳؛ کاستاگنا و همکاران، ۱۹۹۳)

نسبت سرعت موج تراکمی به برشی	نوع سنگ‌شناسی
۱-۲/۹	دولومیت
۱/۱-۹/۸	آهک
۱/۱-۸/۷	ماسه شیلی
۱/۱-۷/۶	ماسه تمیز
۲/۱-۴۲/۲۱	ماسه‌سنگ سازند لالون در تحقیق حاضر

جدول ۳. روابط چند متغیره جهت تخمین خصوصیات دینامیکی

$V_s = -0.071 + 0.33 \rho + 0.66Is_{50}$	$R^2 = 0.92, RMSE = 0.04$	۱۶
$V_s = -0.54 + 0.05Is_{50} + 0.67V_p$	$R^2 = 0.92, RMSE = 0.04$	۱۷

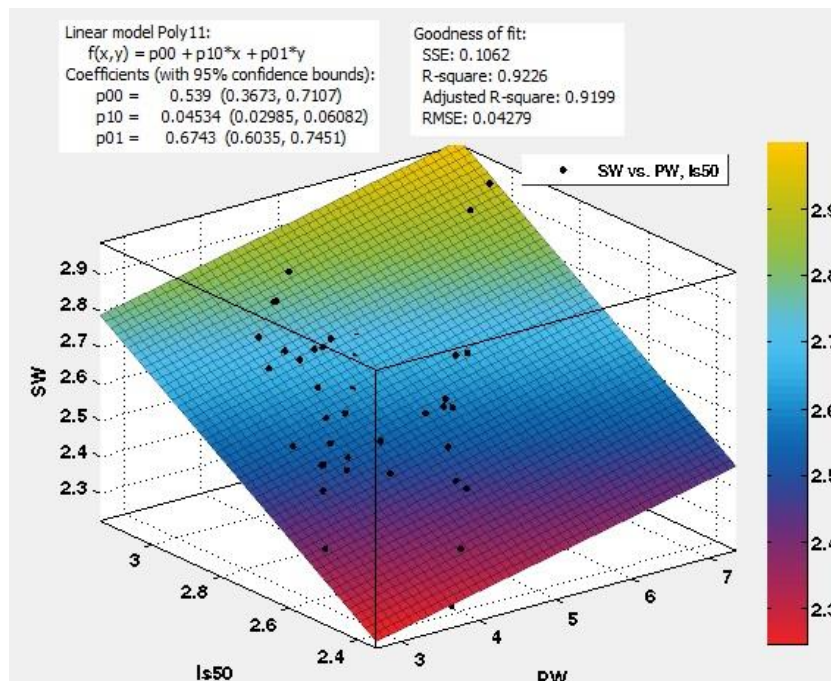

براساس معیار تیلر (۱۹۹۰) ضریب تعیین بیشتر از ۵۰ درصد، به‌عنوان همبستگی قوی در نظر گرفته می‌شود. ارتباط معکوسی بین تخلخل و سرعت امواج وجود دارد. به طور کلی، هر چقدر تخلخل افزایش یابد، در صورت ثابت بودن بقیه پارامترها، سرعت موج کاهش می‌یابد. با توجه به همبستگی بالا بین متغیرهای مستقل و سرعت موج برشی (در روابط ۱۶ و ۱۷) امکان کاربرد این متغیرها جهت مدل‌سازی با روش‌های هوشمند در تخمین متغیر وابسته وجود دارد. همچنین اندازه‌گیری متغیرهای چگالی، سرعت موج تراکمی، تخلخل و شاخص بارنقطه‌ای ارزان‌تر و راحت‌تر و به‌عنوان پارامتر شاخص مورد توجه محققین مختلف بوده است، به همین دلیل به‌عنوان متغیرهای ورودی در مدل‌سازی مدنظر قرار گرفتند. در صورتی که در مدل‌سازی پارامترهای ورودی به درستی انتخاب شوند، با در اختیار داشتن داده‌های کافی برای آموزش، مدل قادر است روابط پیچیده بین ورودی‌ها و خروجی‌ها را به خوبی فراگیرد.

۳-۳- آنالیز رگرسیون چندمتغیره (MVL) با

استفاده از نرم‌افزار MATLAB

رگرسیون چندمتغیره روشی است برای تحلیل مشارکت دو یا چندمتغیر مستقل در تغییرات یک متغیر وابسته. روش رگرسیون چندمتغیره برای مواردی مفید است که روابط پیچیده‌ای وجود دارد و ترکیب بیش از یک پارامتر بر خواص سنگ تأثیر می‌گذارد، استفاده می‌شود (جمشیدی، ۱۳۹۷؛ لشکری‌پور و همکاران، ۲۰۱۸؛ مالکی و همکاران، ۲۰۲۱؛ مالکی و امامی، ۲۰۱۹). شکل ۴ رابطه سرعت موج برشی بر اساس چگالی، شاخص بار نقطه‌ای و سرعت موج تراکمی با استفاده از دستور برآزش منحنی^۱ در نرم‌افزار MATLAB را نشان می‌دهد (روابط ۱۶ و ۱۷). مشاهده می‌شود که همبستگی بالایی بین خصوصیات دینامیکی با خصوصیات فیزیکی و شاخص بار نقطه‌ای وجود دارد بطوریکه این روابط قابل کاربرد جهت تخمین سرعت امواج ماسه‌سنگ‌های مورد مطالعه می‌باشند. معیارهای مختلفی برای تفسیر ضریب تعیین وجود دارد به‌عنوان مثال

¹ Curve fitting



شکل ۴. تخمین سرعت موج برشی بر اساس الف) چگالی و شاخص بار نقطه‌ای، ب) سرعت موج تراکمی و شاخص بار نقطه‌ای

نشود. با ریزدانه شدن بافت سنگ، سرعت امواج صوتی افزایش می‌یابد (اشنویه و باقرزاده خلخالی، ۲۰۱۹). چگالی با امواج صوتی رابطه مستقیم داشته در حالی که با تخلخل رابطه غیرمستقیم دارد (ناصری و همکاران، ۲۰۱۷؛ بهنام‌نیا و براتی، ۲۰۱۹). رطوبت سنگ باعث بالا رفتن سرعت امواج فشاری می‌شود ولی از آن جا که امواج برشی از بخش جامد سنگ عبور می‌کند، میزان رطوبت تأثیر چندانی روی سرعت آن‌ها ندارند. معمولاً با افزایش درجه حرارت، سرعت امواج کاهش می‌یابد (شرف و گلدارت، ۱۹۹۵).

۳-۴- رگرسیون چندمتغیره (MVL) با استفاده از نرم‌افزار MINITAB

از عوامل مؤثر بر سرعت انتشار امواج در سنگ می‌توان به نوع سنگ، نوع مواد سیمانی سنگ و درجه سیمان‌شدگی، بافت، چگالی سنگ، ترک‌های موجود در سنگ، تخلخل، ناهمسانگردی، سطح تنش، درصد رطوبت، درجه حرارت، میزان فشار روباره و محتوی سیال منفذی اشاره کرد. سرعت امواج صوتی در سنگ متناسب با سرعت صوت در کانی‌های تشکیل دهنده آن است، البته در صورتی که تأثیر عواملی مثل اندازه یا جهت‌گیری دانه‌ها در نظر گرفته

استفاده می‌شود. مقدار این آماره به عنوان یک قانون باید بین ۱/۵ تا ۲/۵ باشد. در اینجا مقدار این آماره نشان می‌دهد که استقلال خطاها از یکدیگر وجود دارد و امکان استفاده از مدل وجود دارد (رابطه ۱۸). سطح معنی‌داری حاصل از آنالیز واریانس^۳ نیز نشان داد که مدل برازش شده مناسب می‌باشند. سطح معنی‌داری در آزمون T موجه بودن هر یک از پارامترهای برآورد شده در معادله مدل رگرسیون را نشان می‌دهد. جدول ۴ نشان می‌دهد که دقیق‌تر متغیر جهت تخمین سرعت موج برشی و تراکمی به ترتیب مربوط به شاخص بار نقطه‌ای و چگالی می‌باشد (جدول ۴). عامل تورم واریانس به عنوان معیاری جهت بررسی همبستگی متغیرهای مستقل بکار می‌رود. میزان این معیار باید کمتر از ۱۰ باشد تا مدل ارائه شده قابل استفاده باشد. بر اساس نتایج این تحقیق (عامل تورم واریانس کمتر از ۱۰)، مدل ارائه شده قابل استفاده جهت تخمین سرعت موج برشی می‌باشند.

رگرسیون چندمتغیره در این تحقیق از نوع روش همزمان^۱ با استفاده از نرم‌افزار MINITAB انجام شده است. در این روش، تمام متغیرهای مستقل با هم وارد تحلیل می‌شوند. تخمین سرعت موج تراکمی و سرعت موج برشی ماسه‌سنگ‌ها بر اساس چگالی، تخلخل، شاخص بار نقطه‌ای و سرعت موج تراکمی در منطقه مورد مطالعه و با توجه به ضرایب و آزمون T مطابق رابطه ۱۸ می‌باشد. معیارهای مختلفی جهت ارزیابی روابط ۱۸ بررسی شد. این معیارها نشانگر قابل کاربرد بودن روابط ارائه شده می‌باشند. هر چه ضریب تعیین بیشتر باشد نشان می‌دهد که متغیرهای مستقل که به مدل اضافه شده‌اند به درستی انتخاب شده‌اند. از دیگر معیارهای ارزیابی مدل‌های رگرسیونی، مستقل بودن خطاها از یکدیگر است. در صورتی که خطاها با یکدیگر همبستگی داشته باشند، امکان استفاده از رگرسیون وجود ندارد. به منظور بررسی استقلال خطاها از یکدیگر از آزمونی به نام آزمون دوربین واتسون^۲ (DW)

$$Vs = 0.27 + 0.19 \rho + 0.63 Is50 - 0.002n + 0.03Vp \quad R^2 = 0.92, DW = 1.98, VAF = 91.78\% \quad (18)$$

جدول ۴. ضرایب، آزمون تی و عامل تورم واریانس جهت ارزیابی مدل

مدل	مدل ۱۸- تخمین سرعت موج برشی				
	مقدار ثابت	ρ	Is50	n	Vp
ضرایب	0.27	0.19	0.63	-0.001	0.03
آزمون تی	1.47	2.66	14.95	-0.64	2.76
سطح معنی‌داری	0.15	0.01	0.00	0.53	0.01
عامل تورم واریانس		2.50	2.10	2.45	2.42

خوبی نمی‌دهد. ۳- بیشتر مطالعات انجام گرفته برای محاسبه و برآورد سرعت موج برشی در مورد سنگ‌های کربناتی بوده و در مورد ماسه‌سنگ‌ها مطالعات اندکی صورت گرفته است.

در این تحقیق با استفاده از روابط محققین پیشین موجود در جدول ۵ برای هر نمونه سرعت موج برشی تخمین زده شد. بدین صورت که برای ۶۱ نمونه تحقیق حاضر بر اساس هر کدام از روابط تجربی جدول ۵ سرعت موج برشی پیش‌بینی شد. سپس مقادیر حاصل از روابط مختلف برای هر نمونه تخمین زده شد و رابطه سرعت موج برشی

۳-۵- مقایسه نتایج با تحقیقات پیشین

تاکنون روابط تجربی فراوانی جهت تخمین سرعت امواج برشی و تراکمی ارائه شده است (جدول ۵). اما در بیشتر موارد، نتایج به دست آمده از این روابط در مناطق مختلف به دلایل زیر مطلوب نیست: ۱- پارامترهای متعددی بر روی سرعت امواج تأثیر می‌گذارند که تمامی این پارامترها در روابط تجربی گنجانده نمی‌شوند. ۲- روابط یادشده مربوط به یک منطقه خاص (با سنگ‌شناسی و سیال خاص) است و استفاده از این روابط در مناطق دیگر به دلیل این که ویژگی‌های سنگ و سیال تغییر می‌کند پاسخ

³ ANOVA

¹ Enter Method

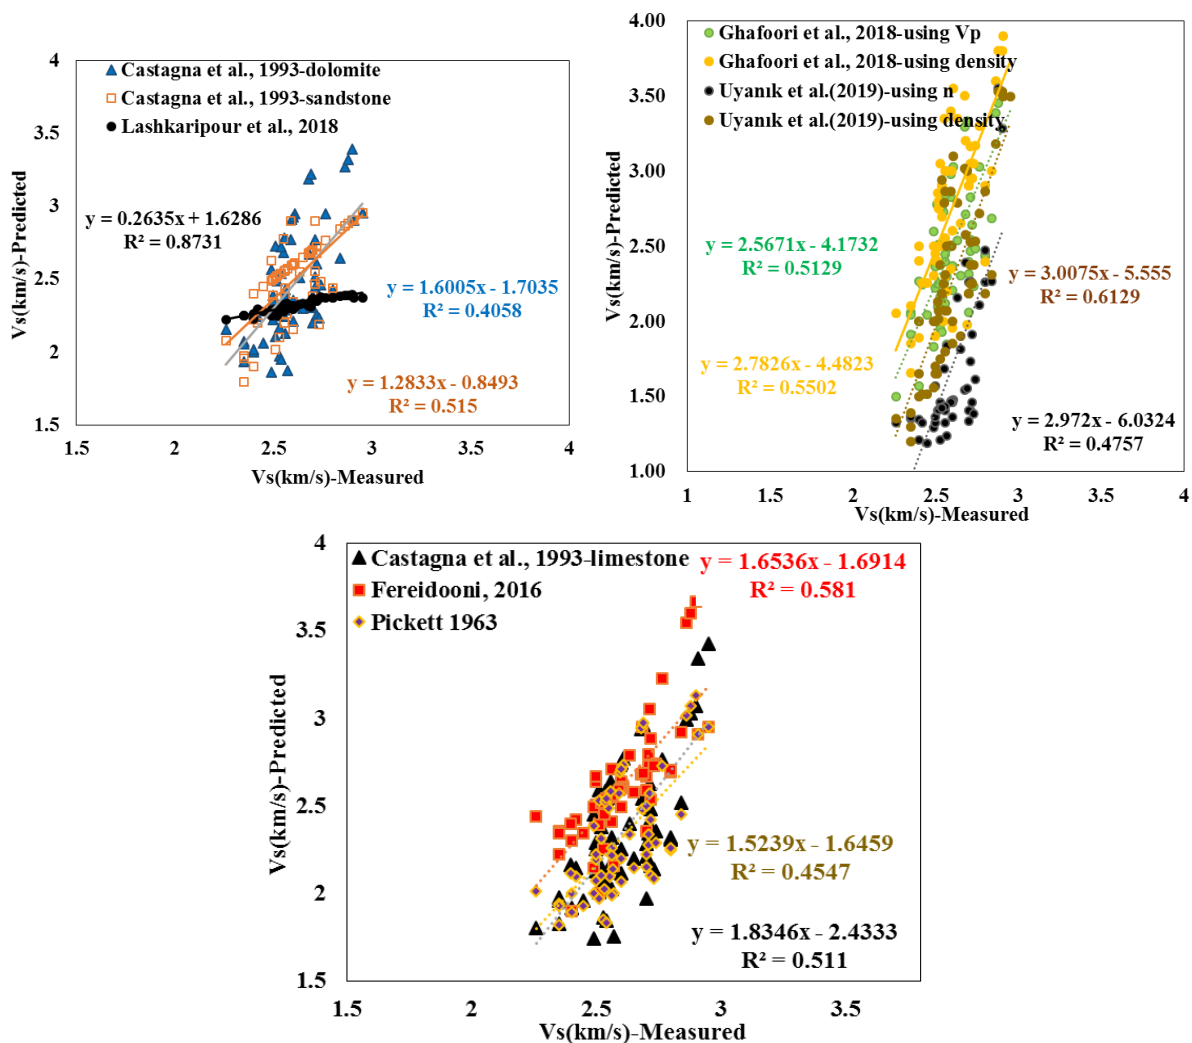
² Durbin-Watson

(۲۰۱۸) بالاترین همبستگی (ضریب تعیین بیش از ۷۰ درصد) را با نتایج تحقیق حاضر نشان می‌دهد. همچنین سازگاری قابل قبولی بین مقادیر اندازه‌گیری شده و تخمین زده شده وجود دارد (شکل ۵).

پیش‌بینی شده با مقدار اندازه‌گیری شده بررسی شد (شکل ۵). چنانچه مشاهد می‌شود دقت اکثر روابط تجربی بالا می‌باشد (ضریب همبستگی اکثر روابط پیشین بیشتر از ۰.۷۰ می‌باشد). رابطه تجربی رابطه لشکری‌پور و همکاران

جدول ۵. روابط میان خصوصیات دینامیکی و فیزیکی ارائه شده توسط محققین پیشین

شماره رابطه	مرجع	لیتولوژی	معادله
۱۹	پیکت (۱۹۶۳)	سنگ‌های کربناته	$V_s = V_p / 1.9$
۲۰	کاستاگنا و همکاران (۱۹۹۳)	آهک	$V_s = -0.055V_p^2 + 1.017V_p - 1.031$
۲۱	کاستاگنا و همکاران (۱۹۹۳)	ماسه‌سنگ	$V_s = 0.7700 V_p - 0.8674$
۲۲	کاستاگنا و همکاران (۱۹۹۳)	دولومیت	$V_s = 0.583V_p - 0.078$
۲۳	یویانک و همکاران (۲۰۱۹)	سنگ‌های رسوبی	$V_s = (28.6/n)^{(1/4.1)}$
۲۴	یویانک و همکاران (۲۰۱۹)	سنگ‌های رسوبی	$V_s = (\rho/23.3)^{(1/0.14)}$
۲۵	لشکری‌پور و همکاران (۲۰۱۸)	کربناته	$V_s = 1.742I_s 50^{0.28}$
۲۶	غفوری و همکاران (۲۰۱۸)	آهک	$V_s = 0.4741 * V_p^{1.126}$
۲۷	غفوری و همکاران (۲۰۱۸)	آهک	$V_s = 4.99 * \rho - 10.071$
۲۸	فریدونی (۲۰۱۶)	هورنفلس	$V_s = 0.58V_p + 217.44$




شکل ۵. رابطه سرعت موج برشی پیش‌بینی شده (بر اساس مقادیر حاصل از روابط پیشین) با مقادیر اندازه‌گیری شده در تحقیق حاضر

۳-۶- شبکه عصبی مصنوعی

روش شبکه عصبی مصنوعی بطور گسترده در مهندسی ژئوتکنیک مورد استفاده محققین مختلف قرار گرفته است (عبدی و قاسمی‌دهنوی، ۱۳۹۸؛ عبدی و همکاران، ۲۰۲۰). در این بخش، عملکرد آگوریتم‌های مختلف آموزشی به روش شبکه عصبی مصنوعی پرسپترون چندلایه به منظور برآورد سرعت موج برشی (V_s) نمونه‌های ماسه‌سنگ بررسی شده است. شبکه عصبی مصنوعی پرسپترون چندلایه از نوع پیشخور می‌باشند. در شبکه‌های پیشخور اطلاعات تنها از یک مسیر حرکت می‌کند که جهت آن رو به جلو می‌باشد. در واقع اطلاعات با شروع از گره (نورون‌های) ورودی و گذر از لایه‌های پنهان به سمت گره‌های خروجی می‌روند. در این شبکه حلقه یا دوری وجود ندارد. بدین منظور الگوریتم‌های مختلف آموزش شبکه عصبی از قبیل الگوریتم شیب توام مقیاس شده^۱ (SCG)، الگوریتم لونبرگ مارکورات^۲ (LM) و

الگوریتم منظم‌سازی بی‌زین^۳ (BR) در تخمین سرعت موج برشی مقایسه شدند. در آموزش شبکه‌های عصبی علاوه بر روش آموزش، روند آموزش نیز در سرعت یادگیری و دقت شبکه عصبی مؤثر می‌باشد. معمولاً یکی از دو روند آموزش الگو به الگو^۴ (آنچه که در تحقیق حاضر استفاده شده است) و آموزش گروهی^۵ در تدوین مدل‌های شبکه عصبی به کار می‌رود (انصاری و هاشمی، ۲۰۱۷). در این تحقیق یک تا پانزده نورون در یک لایه پنهان به روش سعی و خطا بررسی شدند و برای ساختن مدل پس انتشار برای تخمین سرعت موج برشی بررسی شدند (شکل ۶). شبکه در نظر گرفته شده شامل یک لایه پنهان با ۴ ورودی (ورودی‌ها جهت تخمین سرعت موج برشی شامل سرعت موج تراکمی، تخلخل، چگالی و شاخص بار نقطه‌ای) و یک خروجی (شامل V_s) می‌باشد. به منظور مقایسه، ترکیب ورودی‌ها و خروجی‌ها در هر سه روش شبکه عصبی مصنوعی و فرایند رگرسیون گاوسی و رگرسیون چندمتغیره یکسان انتخاب شد.



شکل ۶. نمونه ای از ساختار شبکه عصبی (قسمت بالا) و مدل بهینه با دو نورون (قسمت پایین) استفاده شده جهت تخمین سرعت موج برشی

ادامه بیان شده است. از مجموعه آموزشی برای آموزش الگوریتم و بدست آوردن مقادیر دقیق وزن‌ها برای نتایج مطلوب استفاده می‌شود. از مجموعه اعتبارسنجی برای اطمینان از عدم وابستگی زیاد شبکه به مجموعه داده‌های آموزش استفاده می‌شود. مجموعه آزمایش در طول آموزش

کل داده‌ها به عنوان ورودی به شبکه به سه مجموعه شامل داده‌های آموزش، آزمایش و صحت‌سنجی تقسیم می‌شوند. از ۷۰ درصد داده‌ها برای آموزش مدل استفاده شد. تعداد داده‌های آموزش، آزمایش و صحت‌سنجی در تحقیق حاضر به ترتیب ۴۳، ۹ و ۹ داده انتخاب شدند که دلایل آن در

^۴ Epochs

^۵ Batch

^۱ Scaled Conjugate Gradient (SCG)

^۲ Levenberg Marquardt (LM)

^۳ Bayesian regularization (BR)

بررسی معیارهایی مختلف ارزیابی شد. مشاهده می‌شود که میزان خطا و ضریب همبستگی این روش به ترتیب کمتر و بیشتر از روش شبکه عصبی می‌باشد (شکل ۸). چنان که در شکل ۸ مشاهده می‌شود مقادیر پیش‌بینی شده با رگرسیون فرایند گوسی در هر دو فاز آموزش و آزمایش بسیار به مقادیر واقعی سرعت موج برشی نزدیک هستند. نزدیکی یا همپوشانی این خطوط نشان می‌دهد که پیش‌بینی‌های رگرسیون فرایند گوسی نسبت به مقادیر واقعی سازش خوبی دارند. البته تعدادی نقاط دیده می‌شوند که خطای ناچیزی دارند. همچنین نزدیکی نتایج در هر دو فاز آموزش و آزمایش نشان‌دهنده مناسب بودن میزان آموزش مدل است. زیرا فاز آموزش قابلیت تعمیم آن را ثابت می‌کند.

۳-۸- مقایسه روش‌های مورد استفاده

شکل ۹ دقت روش‌های مورد استفاده برای پیش‌بینی سرعت موج برشی را نشان می‌دهد. با توجه به معیارهای آماری (یعنی R^2 ، MAPE، و RMSE)، روش GPR از دقت بالاتری نسبت به سایر روش‌ها برخوردار است. بر اساس ضریب همبستگی، همه روش‌ها ($R > 70\%$) دقت خوبی برای تخمین سرعت موج برشی دارند. مقادیر اندازه‌گیری شده سرعت موج برشی و مقادیر پیش‌بینی شده با استفاده از روش‌های مورد استفاده نیز مقایسه شد (شکل ۹). مشاهده می‌شود که روش فرایند گاوسی مقادیری برابر با مقدار اندازه‌گیری شده ارائه می‌کند. نتایج مطالعات نشان داد که روش GPR با تابع کرنل نمایی می‌تواند خردایش سنگ^۴ را بهتر از سایر روش‌های هوشمند پیش‌بینی کند (گو و همکاران، ۲۰۱۸). همچنین مقایسه روش‌های مختلف توسط لاوال (۲۰۲۱) نشان داد که خروجی مدل GPR در مقایسه با مدل ANN و سایر مدل‌های استفاده شده در تخمین لرزش زمین ناشی از انفجار^۵ دقیق‌تر عمل می‌کند. تعداد متغیرهای ورودی و تعداد نمونه‌ها نوع تابع مورد استفاده در دقت روش‌های هوشمند موثر می‌باشد (تانگ و همکاران، ۲۰۱۷؛ مقدم و همکاران، ۲۰۲۰). میانگین سرعت موج برشی پیش‌بینی شده از هر ۳ روش ۲/۶۳ کیلومتر بر ثانیه می‌باشد (شکل ۱۰). میانگین درصد تغییرات سرعت موج برشی پیش‌بینی شده به‌دست‌آمده از

شبکه استفاده نشده و برای آزمایش شبکه در پیش‌بینی داده‌های جدید محفوظ می‌ماند. عملکرد مدل آموزش دیده باید با استفاده از یک گروه مستقل از داده‌های آزمایش (داده‌های آزمون) تأیید می‌شود (ساقی و همکاران، ۲۰۱۹). دقت متغیرهای تخمین زده شده با استفاده از شبکه عصبی مصنوعی بهینه با محاسبه شاخص‌هایی مانند R^2 و MSE ارزیابی شد. عملکرد الگوریتم‌های آموزشی مختلف در تخمین متغیرهای وابسته بر اساس متغیرهای مستقل با استفاده از نرم‌افزار متلب برای یک لایه پنهان با ۱ تا ۱۵ نورون بررسی شد. تابع انتقال نورن‌ها در هر سه الگوریتم آموزشی ثابت و برای لایه میانی سگموئید^۱ و لایه خروجی پورلین^۲ انتخاب شدند. نتایج نشان داد که بیشترین دقت مدل‌ها با استفاده از قانون آموزش LM حاصل می‌شود. دقیق‌ترین مدل‌ها با استفاده از این الگوریتم برای تخمین سرعت موج برشی در نورون شماره ۲ (نورون بهینه) حاصل شد. در شکل ۶ روند تغییرات خطای مجذور میانگین^۳ (MSE) با استفاده از الگوریتم آموزشی LM (دقیق‌ترین الگوریتم آموزشی) در مدل بهینه جهت تخمین Vs ارائه شده است. کمترین مقدار MSE در دوره دوم برای سرعت موج برشی با استفاده از الگوریتم آموزشی LM به دست آمد (شکل ۷). همچنین ضریب همبستگی بین متغیرهای وابسته و متغیرهای ورودی برای موارد آموزش، آزمایش و کل داده‌های مدل MLP-ANN بهینه با استفاده از قوانین آموزش LM در شکل ۷ نشان داده شده است. نتایج نشان می‌دهد که شبکه عصبی برای برآورد این متغیرها دقت بالاتری نسبت به رگرسیون ساده نشان می‌دهد.

۳-۷- نتایج رگرسیون فرآیند گاوسی

در این بخش به بررسی توانایی مدل رگرسیون فرایند گوسی با استفاده از تابع کرنل نمایی برای پیش‌بینی سرعت موج برشی نیز پرداخته شده است (نتایج در شکل ۸). سرعت موج تراکمی، تخلخل، چگالی و شاخص بار نقطه‌ای به عنوان ورودی این مدل رگرسیونی و سرعت موج برشی به عنوان خروجی مدل در نظر گرفته شدند. همانطور که پیش از این نیز گفته شد به منظور آموزش این مدل رگرسیونی از ۷۰ درصد داده‌ها و برای آزمون از ۳۰ درصد آن‌ها استفاده گردید. در نهایت توانایی عملکرد مدل با

^۴ Rock fragmentation

^۵ Blast-induced ground vibration

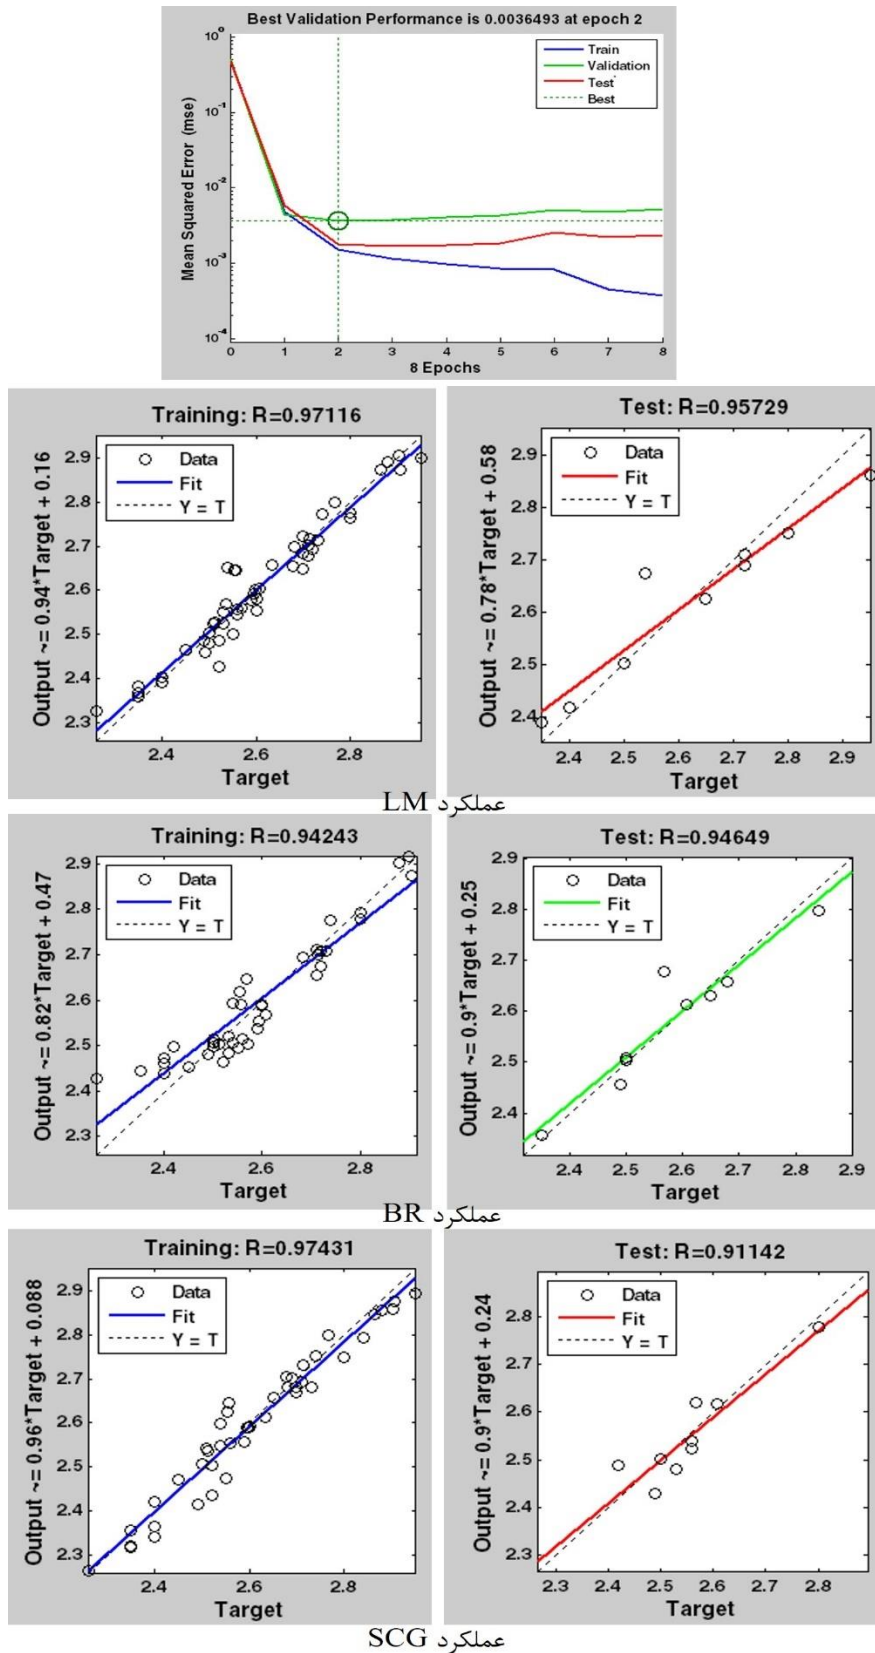
^۱ Sigmoid

^۲ Purelin


^۳ Mean square error (MSE)

روش‌های ارائه شده می‌توانند سرعت موج برشی را با دقت بسیار بالایی پیش‌بینی کنند.

هر ۳ روش نسبت به مقدار اندازه‌گیری شده ۰/۹۴ درصد است که خطای کمتر از ۵ درصد را نشان می‌دهند و



شکل ۷. عملکرد الگوریتم آموزشی مختلف در مدل پهنه



شکل ۸. نتایج روش فرایند رگرسیون گاوسی در تخمین سرعت موج برشی

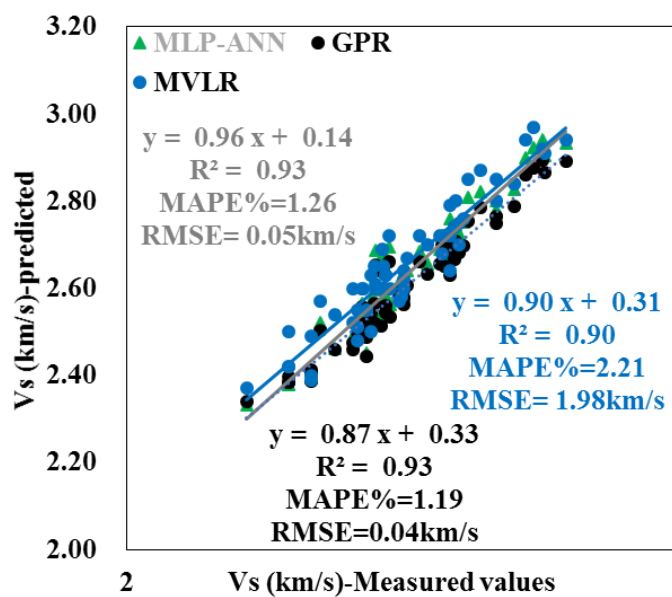
۴- نتیجه‌گیری

در این تحقیق سرعت موج برشی و سرعت موج تراکمی بر اساس خصوصیات شاخص حاصل از نتایج آزمایشگاهی بر روی ماسه‌سنگ‌های سازند لالون به روش شبکه عصبی و رگرسیون چندمتغیره تخمین زده شد. روابط و مدل‌های ارائه شده با استفاده از معیارهای R^2 , RMSE, VAF و DW ارزیابی شدند. بدین منظور ابتدا آزمایشات پتروگرافی،

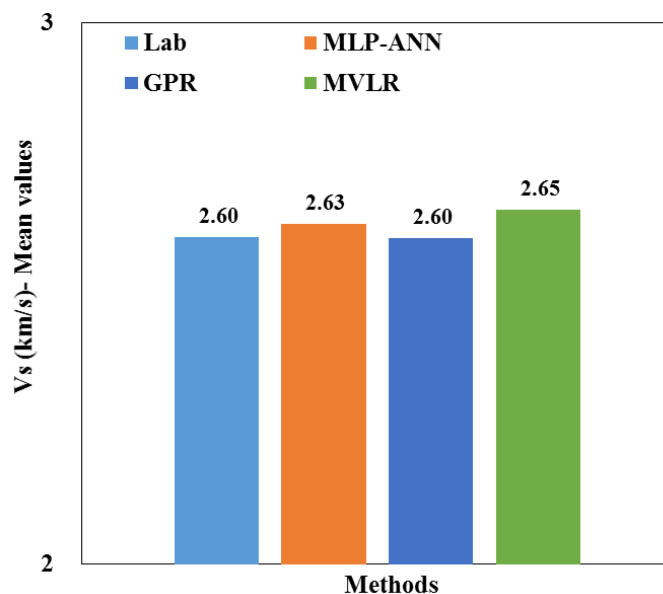
فیزیکی، مکانیکی و دینامیکی بر روی ۶۱ مغزه (۱۸ مغزه در شرایط اشباع و ۴۳ مغزه در شرایط خشک) انجام شد. نتایج مقاطع نازک نشان داد که کانی‌های غالب ماسه‌سنگ‌های مورد مطالعه شامل کوارتز، فلدسپار، دولومیت و کلسیت می‌باشند. ماسه‌سنگ‌های مورد مطالعه از نوع فلدسپاتیک لیت‌آرنایت و لیت‌آرنایت می‌باشد. نتایج نشان داد که نسبت سرعت موج تراکمی به سرعت موج

خواص دینامیک بیشتر از رگرسیون چندمتغیره می‌باشد و در مجموع، روش رگرسیون فرایند گاوسی نسبت به سایر روش‌ها دقت بیشتری در تخمین سرعت موج برشی نشان داد. تجزیه و تحلیل تمام فرضیه‌های مدل با استفاده از روش‌های رگرسیون خطی چندمتغیره (مانند معیارهای ارزیابی مدل‌ها، وضعیت همخطی متغیرهای مستقل، استقلال خطاها و تجزیه و تحلیل واریانس) نشان داد که امکان استفاده از مدل‌ها وجود دارد. روش‌های ارائه شده با خطای کمتر از ۵ درصد می‌توانند سرعت موج برشی را با دقت بالایی پیش‌بینی کنند.

برشی دارای دامنه‌ای از ۱/۲۱ تا ۲/۴۲ با متوسط ۱/۷۰ می‌باشد. نتایج تحقیق حاضر با نتایج تحقیقات پیشین مقایسه شد. با استفاده از رگرسیون فرایند گاوسی با استفاده از تابع کرنل نمایی، رگرسیون چندمتغیره خطی و شبکه عصبی مصنوعی دقت تخمین سرعت موج برشی (Vs) بر اساس متغیرهای سرعت موج تراکمی، تخلخل، چگالی و شاخص بار نقطه‌ای بررسی شد. شاخص بار نقطه‌ای بیشترین تاثیر را بر خصوصیات دینامیکی نشان داد. بر اساس معیارهای ضریب تعیین و خطا، دقت شبکه عصبی با استفاده از قوانین آموزش مختلف جهت تخمین



شکل ۹. دقت روش‌های مورد استفاده برای پیش‌بینی سرعت موج برشی



شکل ۱۰. میانگین سرعت موج برشی پیش‌بینی شده

- Ansari, Y., Hashemi, A (2017) Neural Network Approach in Assessment of Fiber Concrete Impact strength, *Journal of civil Engineering and Materials Application*, 1(3): 88-97.
- ASTM (2002) Standard test method for determination of the point load strength index of rock. ASTM D5731 International, West Conshohocken.
- ASTM. (1983) Test methods for ultra violet velocities determination. Designation D2845.
- Behnamnia, A., Barati, M (2019) Seismic Behavior of Steel-Concrete Composite Columns Under Cyclic Lateral Loading. *Journal of civil Engineering and Materials Application*, 3(4): 183-192.
- Broch, E., Franklin, J (1972) The point-load strength test", *International Journal of Rock Mechanics and Mining Sciences*, 9(6): 669-97.
- Castagna, J. P., Batzle, M. L., and Kan, T. K. (1993) Rock physics- the link between rock properties and AVO response in Castagna, J. P., and Backus, M. M., Eds., *Offset-dependent reflectivity-Theory and practice of AVO analysis*", *Society of Exploration Geophysicists*, 135-171.
- Dao, D. V., Adeli, H., Ly, H. B., Le, L. M., Le, V. M., Le, T. T. and Pham, B. T (2020) A sensitivity and robustness analysis of GPR and ANN for high-performance concrete compressive strength prediction using a Monte Carlo simulation. *Sustainability*, 12(3): 830.
- Eberli, G. P., Anselmetti, F. S. & Incze, M. L (2003) Factors controlling elastic properties in carbonate sediments and rocks, *The Leading Edge*: 654-660.
- Fereidooni, D (2016) Determination of the geotechnical characteristics of hornfelsic rocks with a particular emphasis on the correlation between physical and mechanical properties. *Rock Mechanics and Rock Engineering*, 49(7): 2595-2608.
- Folk, R. L (1974) *Petrology of Sedimentary Rocks*. Hemphill, Austin, 600p
- Gao, W., Karbasi, M., Hasanipanah, M., Zhang, X. and Guo, J (2018) Developing GPR model for forecasting the rock fragmentation in surface mines. *Engineering with Computers*, 34(2): 339-345.
- Ghafoori, M., Rastegarnia, A. Lashkaripour, G. R (2018) Estimation of static parameters based on dynamical and physical properties in limestone rocks. *Journal of African Earth Sciences*, 137: 22-31.
- Gupta, V., Sharma, R (2012) Relationship between textural, petrophysical and mechanical properties of quartzites: A case study from northwestern Himalaya, *Engineering Geology*, 1(9): 135-136.
- Hassanzadeh, R. Beiranvand, B. Komasi, M. Hassanzadeh, A (2021) Investigation of data
- منابع
- قبادی، م. ح.، امیری، م.، رسولی‌فرح، م. ر (۱۴۰۰) مطالعه خصوصیات ژئوتکنیکی ماسه‌سنگ‌های سازند قم و استفاده از آن‌ها به عنوان منابع قرضه (مطالعه موردی: روستای لتگاه، شمال همدان). نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۱۵، شماره ۲۹، ص ۵۵-۷۰.
- عبدی، ی.، قاسمی‌دهنوی، آ (۱۳۹۸) پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیسیته ماسه‌سنگ‌ها با استفاده از شبکه عصبی مصنوعی و آنالیز رگرسیون چندمتغیره، نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۱۳، شماره ۲۶، ص ۴۵ - ۵۴.
- عبدی، ی.، خانلری، غ (۱۳۹۷) بررسی تاثیر انجماد- ذوب بر ویژگی‌های مکانیکی ماسه‌سنگ‌های سازند قرمز بالایی بر اساس اندازه‌گیری سرعت سیر موج و تخلخل، نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۱۲، شماره ۲۳، ص ۷۵-۹۱.
- جمشیدی، ا (۱۳۹۷) تأثیر چگالی و تخلخل بر میزان دقت روابط تخمین مقاومت فشاری تک‌محوری و مدول الاستیسیته سنگ‌آهک از سختی و اجتهشی اشمیت. نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۱۲، شماره ۲۴، ص ۶۵-۷۶.
- نصیری، ش.، آبدانان م. ز.، سامان، ن. ز (۱۳۹۹) پیش‌بینی پذیرش کلی میوه موز با استفاده از پردازش تصاویر دیجیتال و مدل رگرسیون فرآیند گاوسی در خلال انبارمانی، نشریه پژوهش‌های علوم و صنایع غذایی ایران، دوره ۱۶، شماره ۲، ص ۱۷۱-۱۹۱.
- Abdi, Y., Momeni, E., Rashidi Khabir, R (2020) A Reliable PSO-based ANN Approach for Predicting Unconfined Compressive Strength of Sandstones. *The Open Construction & Building Technology Journal*, 14(1): 237-249
- Abdi, Y., Taheri-Garavand, A., Zarei-Sahamieh, R (2018) Prediction of strength parameters of sedimentary rocks using artificial neural networks and regression analysis. *Arabian Journal of Geosciences*, 11 (19): 1-11.
- Ajalloeian, R., Jamshidi, A. and Khorasani, R (2020) Assessments of ultrasonic pulse velocity and dynamic elastic constants of granitic rocks using petrographic characteristics. *Geotechnical and Geological Engineering*, 38(3): 2835-2844.
- Anon, OH (1979) Classification of rocks and soils for engineering geological mapping, Part 1: Rock and soil materials, *Bulletin of Engineering Geology and the Environment*, 19 (1): 364-37.

- Engineering and Materials Application, 3(2): 101-107.
- Martinez-Martinez, J., Benavente, D., Garcí'a-del-Cura, M. A (2012) Comparison of the static and dynamic elastic modulus in carbonate rocks, *Bulletin of Engineering Geology and the Environment*, 71: 263-268.
- Mikaeil, R., Esmaeilzade, A., Shaffiee Haghshenas, S (2021) Investigation of the Relationship Between Schimazek's F-Abrasiveness Factor and Current Consumption in Rock Cutting Process. *Journal of civil Engineering and Materials Application*, 5(2): 47-55.
- Moghaddam, D. D., Rahmati, O., Panahi, M., Tiefenbacher, J., Darabi, H., Haghizadeh, A., Haghghi, A. T., Nalivan, O. A. and Bui, D. T. (2020) The effect of sample size on different machine learning models for groundwater potential mapping in mountain bedrock aquifers. *Catena*, 187: 104421.
- Momeni, E., Dowlatshahi, M. B., Omidinasab, F., Maizir, H., Armaghani, D. J (2020) Gaussian process regression technique to estimate the pile bearing capacity. *Arabian Journal for Science and Engineering*, 45(10): 8255-8267.
- Naseri, F., Lotfollahi, S., Bagherzadeh Khalkhali, A (2017) Dynamic Mechanical Behavior of Rock Materials. *Journal of Civil Engineering and Materials Application*, 1(2): 39-44.
- Nazmi, A., Paydar, A., Firoozian, S (2021) Studying the Role of Traffic Flow Control Methods in Freeways and its Effect on Drivers Behavior, *Journal of Civil Engineering and Materials Application*, 5(1): 17-24.
- Oshnavieh, D. and Bagherzadeh Khalkhali, A (2019) Use of shear wave velocity in evaluation of soil layer's condition after liquefaction. *Journal of civil Engineering and Materials Application*, 3(3): 119-135.
- Pickett, G. R (1963) Acoustic character logs and their applications in formation evaluation. *Journal of Petroleum Technology*, 15: 650-667.
- Saghi, H., Behdani, M., Saghi, R., Ghaffari, A. R., Hirdaris, S (2019) Application of Gene Expression Programming Model to Present a New Model for Bond Strength of Fiber Reinforced Polymer and Concrete, *Journal of civil Engineering and Materials Application*, 3(1): 15-29.
- Schon, J. H (2011) Physical Properties of Rocks_A workbook (Handbook of Petroleum Exploration and Production, 8, ELSEVIER.
- Shamsashtiany, R., Ameri, M (2018) Road Accidents Prediction with Multilayer Perceptron MLP modelling Case Study: Roads of Qazvin, Zanjan and Hamadan", *Journal of civil Engineering and Materials Application*, 2(4): 181-192.
- mining method in optimal operation of Eyvashan earth dam reservoir based on PSO algorithm., *Journal of civil Engineering and Materials Application*, 5(3): 125-137.
- He, H., Siu, W. C (2011) Single image super-resolution using Gaussian process regression. In *CVPR 2011* (pp. 449-456). IEEE.
- Hsieh, Y. M., Li, H. H., Huang, T. H., Jeng, F. S (2008) Interpretations on how the macroscopic mechanical behavior of sandstone affected by microscopic properties-revealed by bonded-particle model, *Engineering Geology*, 99: 1-10.
- ISRM (1981) Rock characterization testing and monitoring. In: Brown, E.T. (Ed.), *ISRM Suggested Methods*. Pergamon Press, Oxford.
- Jahed Armaghani, D., Asteris, P. G., Askarian, B., Hasanipanah, M., Tarinejad, R. and Huynh, V. V (2020) Examining hybrid and single SVM models with different kernels to predict rock brittleness. *Sustainability*, 12(6): 2229.
- Kookalani, S., Cheng, B (2021) Structural analysis of GFRP elastic gridshell structures by particle swarm optimization and least square support vector machine algorithms, *Journal of civil Engineering and Materials Application*, 5(3): 139-150.
- 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.
- Lawal, A. I., Kwon, S., Aladejare, A. E., Oniyide, G. O. (2022) Prediction of the static and dynamic mechanical properties of sedimentary rock using soft computing methods. *Geomechanics and Engineering*, 28(3): 313-324.
- Lawal, A. I., Olajuyi, S. I., Kwon, S., Aladejare, A. E. and Edo, T. M (2021) Prediction of blast-induced ground vibration using GPR and blast-design parameters optimization based on novel grey-wolf optimization algorithm. *Acta Geophysica*, 69(4): 1313-1324.
- Lotfollahi, S., Ghorji, M., Hoseini Toodashki, V (2018) An Investigation into the Effect of Foliation Orientation on Displacement of Tunnels Excavated in Metamorphic Rocks. *Journal of civil Engineering and Materials Application*, 2(3): 138-145.
- Mahmoodzadeh, A., Mohammadi, M., Ali, H. F. H., Abdulhamid, S. N., Ibrahim, H. H., Noori, K. M. G (2021) Dynamic prediction models of rock quality designation in tunneling projects. *Transportation geotechnics*, 27: 100497.
- Maleki, M. A., Emami, M (2019) Application of SVM for investigation of factors affecting compressive strength and consistency of geopolymer concretes. *Journal of civil*

- Zorlu, K., Gokceoglu, C., Ocakoglu, F., Nefeslioglu, H.A., Acikalin, S (2008) Prediction of uniaxial compressive strength of sandstones using petrography-based models, *Engineering Geology*, 96(1): 141-158.
- Sheriff, R. E., Geldart, L. P (1995) *Exploration Seismology*, 2nd ed. Cambridge University press
- Tamrakar, N. K., Yokota, S. and Shrestha, S. D. (2007) Relationships among mechanical, physical and petrographic properties of Siwalik sandstones, Central Nepal Sub-Himalayas, *Engineering Geology*, 90(4): 105-123.
- Tange, R. I., Rasmussen, M. A., Taira, E. and Bro, R (2017) Benchmarking support vector regression against partial least squares regression and artificial neural network: Effect of sample size on model performance. *Journal of Near Infrared Spectroscopy*, 25(6): 381-390.
- Taylor, R (1990) Interpretation of the correlation coefficient: a basic review. *Journal of diagnostic medical sonography*, 6(1): 35-39.
- Ulusay, R., Tureli, K., Ider, M. H (1994) Prediction of engineering properties of a selected litharenite sandstone from its petrographic characteristics using correlation and multivariate statistical techniques. *Engineering Geology*, 37: 135-157.
- Uyanik, O., Sabbağ, N., Uyanik, N. A., Öncü, Z (2019) Prediction of mechanical and physical properties of some sedimentary rocks from ultrasonic velocities. *Bulletin of Engineering Geology and the Environment*, 78(8): 6003-6016.
- Vanorio, T., Scotellaro, C., Mavko, G (2008) The effect of chemical and physical processes on the acoustic properties of carbonate rocks, *The Leading Edge*: 1040-1048.
- Viswanathan, R. and Samui, P (2016) Determination of rock depth using artificial intelligence techniques. *Geoscience Frontiers*, 7(1): 61-66.
- Wani, U., Hamid, I., Wani, S. G., Farooq, S (2022) Statistical Analysis of b-value Parameter under Unconfined Uni-axial Compression Testing, *Journal of Civil Engineering and Materials Application*, 6(3): 1-29.
- Waszkiewicz, S., Krakowska-Madejska, P., Puskarczyk, E (2019) Estimation of absolute permeability using artificial neural networks (multilayer perceptrons) based on well logs and laboratory data from Silurian and Ordovician deposits in SE Poland". *Acta Geophysica*, 67(6): 1885-1894.
- Yang, D., Zhang, X., Pan, R., Wang, Y. and Chen, Z (2018) A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *Journal of Power Sources*, 384: 387-395.
- Yasar, E., Ranjith, P. G., Perera, M. S. A (2010) Physico-mechanical behaviour of southeastern Melbourne sedimentary rocks, *International Journal of Rock Mechanics and Mining Science*, 47: 481-487.

Estimation of shear wave velocity using Gaussian process regression, multivariate regression and multilayer perceptron artificial neural network

M. Saffarian¹, A. Iraj², A. Azadmehr^{*3}

1- Assist. Prof., Dept., of Industrial Engineering, Birjand University of Technology, Birjand, Iran

2- Assist. Prof., Dept., of Civil Engineering, Urmia University of Technology, Urmia, Iran

3- Assist. Prof., Dept., of Mining Engineering, Birjand University of Technology, Birjand, Iran

* a.azadmehr@birjandut.ac.ir

Received: 2022.8.5 Accepted: 2023.1.11

Abstract

Estimation of wave velocities is very important for designing geotechnical structures and modeling deep drillings. The purpose of this study is to estimate shear wave velocity (V_s) using Gaussian process regression (GPR), multilayer perceptron artificial neural network (MLP-ANN) and multivariate linear regression (MVLN) methods. In order to carry out this study, 14 rock blocks were prepared from the northwest of Damavand city and after being transferred to the laboratory, cores were extracted from them. In order to develop a predictive model, point load index, compressional wave velocity (V_p), porosity and density tests were performed on 61 rock core samples. Point load index, V_p , porosity and density were used as input parameters of models to predict V_s . The results of lithological studies showed that the studied sandstones are feldspathic litharenite and litharenite. The results showed that the ratio of V_p to V_s is equal to 1.70 on average. The results of the MLP-ANN showed that the highest accuracy of the models was obtained by using the Levenberg-Marquardt training algorithm. The most accurate models were obtained using this algorithm to estimate the V_s in neuron number 2 (optimal neuron). The GPR, MLP-ANN and MVLN predicted V_s with correlation coefficients of 0.97, 0.96 and 0.95, respectively. GPR method showed better performance in predicting V_s than other methods.

Keywords: Physical and mechanical properties, Sandstone rocks, Gaussian process regression (GPR), Multilayer perceptron artificial neural network (MLP-ANN), Multivariate linear regression (MVLN).