

## کاربرد روش گروهی مدیریت داده‌ها (GMDH) در پیش‌بینی مقاومت فشاری تک محوره سنگ‌های آهکی

احسان مومنی<sup>۱</sup>، یاسین عبدی<sup>۲\*</sup>

پذیرش مقاله: ۱۴۰۰/۱۱/۲۹

دریافت مقاله: ۱۳۹۹/۰۶/۰۶

### چکیده

این تحقیق با هدف ارائه یک سیستم هوش مصنوعی که الگوریتم مدیریت داده‌ها به روش گروهی (GMDH) نامیده می‌شود، برای پیش‌بینی غیرمستقیم مقاومت فشاری تک محوری سنگ‌های آهکی انجام شده است. اندازه‌گیری مستقیم مقاومت فشاری تک محوری سنگ در آزمایشگاه، زمان‌بر، دشوار و پرهزینه است. در مطالعه حاضر، چندین آزمایش شاخص سنگ به‌همراه آزمایش‌های مقاومت فشاری تک محوری، بر روی نمونه‌های سنگ آهک جمع‌آوری شده انجام شده است. در این پژوهش، براساس هدف اول، چهار معادله تجربی بر مبنای پیش‌بینی کننده‌ها، شامل دانسیته خشک، سرعت سیر موج، دوام شکستگی و شاخص مقاومت بار نقطه‌ای، با هدف پیش‌بینی مقاومت فشاری تک محوری پیشنهاد شد. نتایج این تحلیل‌ها تأیید کرد که نیاز به توسعه مدل‌های چند متغیره جدید در پیش‌بینی مقاومت سنگ وجود دارد. برای این منظور مدل GMDH برای پیش‌بینی مقاومت فشاری تک محوری سنگ طراحی شده است. به منظور انجام یک مقایسه، یک مدل شبکه عصبی مصنوعی در کنار یک مدل رگرسیونی ماشین بردار پشتیبان یا SVR برای پیش‌بینی مقاومت سنگ طراحی شده است. در نهایت عملکرد مدل‌های GMDH، شبکه عصبی مصنوعی و SVR ارزیابی شده و نتایج آن‌ها با انتخاب بهترین مدل پیش‌بینی و نتایج متوسط مقایسه گردید. در نهایت، نتایج داده‌های آزمایش نشان داد که مدل GMDH با ضریب همبستگی (۰/۹۶۶) و خطای سیستمی (۰/۱۱) می‌تواند به عنوان یک روش کاربردی برای پیش‌بینی مقاومت فشاری تک محوری سنگ در نظر گرفته شود.

**کلید واژه‌ها:** مقاومت فشاری تک محوری (UCS)، مدیریت گروهی داده‌ها (GMDH)، شبکه عصبی مصنوعی (ANN)، رگرسیون ماشین بردار پشتیبان (SVR)، همدان، سنگ آهک.

۱. عضو هیات علمی گروه عمران، دانشگاه لرستان، خرم آباد

۲. عضو هیات علمی گروه زمین‌شناسی، دانشگاه لرستان، خرم آباد [abdi.ya@lu.ac.ir](mailto:abdi.ya@lu.ac.ir)

\* مسئول مکاتبات

## ۱. مقدمه

مقاومت فشاری تک محوری و مدول الاستیک سنگ‌ها، دو عامل مهم و اساسی ژئوتکنیکی برای کاربردهای مهندسی همچون طراحی سد، تونل و حفاری‌های زیرزمینی می‌باشند. روش مستقیم برای تعیین مقاومت فشاری تک محوری و مدول الاستیک در آزمایشگاه، به صورت نسبی نیازمند صرف زمان و هزینه زیادی می‌باشد. علاوه بر این، تعیین دقیق این پارامترها نیازمند تهیه نمونه‌های مغزه با کیفیت بالا می‌باشد که این امر به‌خصوص در مورد سنگ‌های ضعیف، لایه‌دار، متورق و متخلخل بسیار مشکل است. آزمایش UCS توسط روش پیشنهادی ISRM استاندارد شده است (Ulusay and Hudson, 2007). در سال‌های اخیر، مطالعات بسیاری نشان داده‌اند که UCS یا مدول الاستیسیته (E) را می‌توان به طور غیر مستقیم پیش‌بینی کرد. در حقیقت علاقه جامعه علمی بین‌المللی در بررسی روش‌هایی که می‌توانند در تخمین غیرمستقیم UCS یا E به کار گرفته شوند، ناشی از این واقعیت است که انجام آزمایش UCS، پرهزینه و زمان‌بر است؛ بنابراین در عمل، آزمون‌هایی مانند بار نقطه‌ای یا سرعت سیر موج برای تخمین UCS انجام می‌شود. چنین آزمایش‌هایی که به عنوان آزمون‌های شاخص سنگ نیز شناخته می‌شوند، نسبتاً سریع و آسان انجام می‌شوند (Zhou and Yang, 2007, Momeni et al., 2015c, Liang et al., 2016, Yang et al., 2018, Fang et al., 2019). بنابراین، تلاش‌های فراوانی برای بررسی ارتباط بین آزمایش‌های شاخص با UCS و E انجام شده است (Kahraman et al., 2005, Diamantis et al., 2009, Khandelwal and Singh, 2009, Moradian and Behnia, 2009, Yilmaz and Yuksek, 2009, Beiki et al., 2013, Khandelwal, 2013, Armaghani et al., 2016a). این مطالعات همبستگی مبتنی بر رگرسیون را پیشنهاد کردند. مومنی و همکاران (۲۰۱۵c) (Momeni et al., 2015c) مطالعه مروری نسبتاً جامعی انجام دادند. در این مطالعه، لیستی از روابط همبستگی بین آزمایش UCS و آزمون‌های شاخص سنگ ارائه شده است. همچنین، این مطالعه به معرفی تعدادی از مدل‌های مبتنی بر هوش مصنوعی، جهت تخمین مقدار UCS پرداخته

است. نظیر و همکاران (۲۰۱۳) (Nazir et al., 2013) با انجام یک مطالعه آزمایشگاهی، به معرفی یک رابطه بین UCS و شاخص بار نقطه‌ای پرداختند. با وجود این، با ظهور تکنیک‌های هوش مصنوعی، بسیاری از مطالعات توانایی این روش‌ها را در حل مشکلات مختلف در زمینه‌های گوناگون مهندسی عمران نشان دادند (Momeni et al., 2015b, Zhou et al., 2016, Armaghani et al., 2018, Momeni et al., 2018, Armaghani et al., 2019, Hajihassani et al., 2019, Xu et al., 2019, et al., Zhou et al., 2019b, Marto et al., 2014, Rezaei, 2016, Khandelwal et al., 2017, Bunawan et al., 2018, اجل لوئیان و همکاران، ۱۳۹۱). بررسی مطالعات انجام شده در زمینه مقاومت و تغییر شکل سنگ، نشان می‌دهد که تکنیک‌های مبتنی بر هوش مصنوعی، بر روش‌های رایج رگرسیونی برتری دارد. نگارا و همکاران (۲۰۱۷) (Negara et al., 2017) نشان دادند که می‌توان از رگرسیون ماشین بردار پشتیبان (SVR) برای تخمین UCS استفاده کرد. مومنی و همکاران (۲۰۱۵a) (Momeni et al., 2015a) با استفاده از ترکیب شبکه‌های عصبی مصنوعی و الگوریتم ازدحام ذرات، به پیش‌بینی مقاومت فشاری نامحسور سنگ‌ها پرداختند. آن‌ها در این مطالعه برای ساخت مدل هوشمند خود، داده‌های بار نقطه‌ای، سرعت سیر موج، دانسیته و عدد بازجهش چکش اشمیت را به عنوان ورودی در نظر گرفتند. ضریب تعیین یا  $R^2$  مساوی ۰/۹۷ برای داده‌های آزمایش، بیانگر عملکرد مطلوب مدل پیشنهادی آنها در تخمین مقاومت فشاری سنگ‌ها است. بر اساس مطالعه آنها، هنگامی که رابطه بین پارامترهای ورودی و خروجی پیچیده باشد، روش مبتنی بر محاسبات نرم، بر تکنیک‌های رگرسیونی برتری دارند. از سال ۲۰۱۰ مطالعات متعددی، تکنیک‌های هوش مصنوعی را برای پیش‌بینی غیرمستقیم UCS و E به کار گرفتند (Tiryaki, 2008, Majdi and Beiki, 2010, Yesiloglu-Gultekin et al., 2013, Mohamad et al., 2014 and 2018, Bejarbaneh et al., 2018). لازم به ذکر است که مدل‌های پیش‌بینی کننده پیشنهاد شده در صورتی که با استفاده از داده‌های زیاد و با کیفیت بالا آموزش داده شوند، مطمئن و قابل اعتماد می‌باشند. ارمغانی و همکاران (۲۰۱۶b) (Armaghani et al., 2016b) نشان دادند که مقاومت فشاری گرانیته‌ها را می‌توان با استفاده از شبکه‌های عصبی مصنوعی ارتقاء یافته، به صورت غیرمستقیم تخمین زد.

آنها از نتایج آزمایش‌های چکش اشمیت، سرعت موج، تخلخل و بار نقطه‌ای برای پیش‌بینی غیرمستقیم UCS استفاده کردند. در حقیقت، در روش‌های مبتنی بر محاسبات نرم، یک مدل پیش‌بینی کننده با استفاده از داده‌های موجود آموزش داده می‌شود و بعد از آموزش، مدل پیش‌بینی کننده را می‌توان برای تخمین پارامترهای مورد نظر به کار گرفت. بیکی و همکاران (Beiki et al., 2013) (۲۰۱۳) یک مدل پیش‌بینی کننده UCS را با استفاده از الگوریتم ژنتیک توسعه دادند. پارامترهای ورودی استفاده شده در این مدل، دانسیته، تخلخل و همچنین سرعت موج بودند. ضریب تعیین یا  $R^2$  گزارش شده در مطالعه آنها معادل ۰/۶۷ است. تونیزام محمد و همکاران (Tonnizam Mohamad et al., 2014) (۲۰۱۴) مدل هوشمندی را مبتنی بر ترکیب شبکه عصبی و الگوریتم ازدحام ذرات، جهت پیش‌بینی مقاومت سنگ‌ها معرفی کردند. آن‌ها ۱۶۰ آزمایش UCS، بار نقطه‌ای، آزمایش کشش غیرمستقیم برزیلی، و سرعت موج را روی ۴۰ نمونه سنگ (عمدتاً شیل) انجام دادند و با توجه به مقدار بالای ضریب همبستگی به دست آمده برای داده‌های آزمایش، نتیجه گرفتند که مدل توسعه داده شده، قابلیت به‌کارگیری جهت تخمین UCS را دارد. در مطالعه‌ای دیگر، عبدی و همکاران (Abdi et al., 2018) (۲۰۱۸) پارامترهای مقاومتی (E - UCS) سنگ‌های رسوبی را با استفاده از شبکه عصبی و آنالیز رگرسیون چند متغیره (MLR) تخمین زده‌اند. آن‌ها ۱۹۶ نوع مختلف نمونه‌های سنگ، از جمله سنگ آهک، کنگلومرا، ماسه‌سنگ، و مارن را مورد استفاده قرار داده‌اند. ورودی‌های مدل پیشنهادی آن‌ها دانسیته خشک، سرعت موج، تخلخل، و جذب آب بودند. براساس نتیجه‌گیری آن‌ها، ANN در مقایسه با MLR بهتر عمل می‌کند. عبدی و قاسمی (۱۳۹۸) در مطالعه‌ای دیگر، به پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته ماسه‌سنگ‌ها با استفاده از شبکه عصبی مصنوعی و آنالیز رگرسیون چند متغیره پرداختند. مطالعه آنها نشان داد که عملکرد شبکه عصبی مصنوعی پیشنهاد شده در پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیک به‌مراتب بهتر از آنالیز رگرسیون می‌باشد. سینگ و همکاران

(Singh et al., 2012) (۲۰۱۲) برای پیش‌بینی مدول الاستیسیته سنگ‌ها از ANFIS استفاده کردند. براساس مطالعه آن‌ها، جذب آب، دانسیته و شاخص بار نقطه‌ای به عنوان ورودی مدل در نظر گرفته شده‌اند. با این حال، ضریب تعیین یا  $R^2$  برابر با ۰/۶۶ نشان می‌دهد که مدل ANFIS پیشنهاد شده توسط آنها خیلی قابل اعتماد نیست. ایلماز و یوکسک (Yilmaz and Yuksek, 2008) (۲۰۰۸) به منظور پیش‌بینی مدول الاستیسیته، یک مدل شبکه عصبی مصنوعی را با  $R^2$  برابر ۰/۹۱ معرفی کردند. ورودی‌های این مدل شامل شاخص دوام شکستگی، شاخص بار نقطه‌ای، تخلخل مؤثر و عدد بازجهش چکش اشمیت می‌باشند. ایلماز و یوکسک (Yilmaz and Yuksek, 2009) (۲۰۰۹) در مطالعه‌ای دیگر با کمک ANFIS به تخمین مدول الاستیسیته پرداخته‌اند. در این مطالعه، آنها از شاخص بار نقطه‌ای، سرعت سیر موج و عدد بازجهش چکش اشمیت به عنوان ورودی‌های مدل استفاده کرده‌اند و مدول الاستیسیته به عنوان خروجی مدل در نظر گرفته شده است. مقدار  $R^2$  معادل ۰/۹۵ نشان‌دهنده سطح اطمینان بالای مدل پیشنهادی آنها می‌باشد. براین اساس، می‌توان ملاحظه کرد که هیچ معیار خاصی برای انتخاب پارامترهای ورودی مدل‌های پیش‌بینی کننده مبتنی بر هوش به منظور تخمین پارامترهای مقاومتی سنگ از قبیل UCS یا E وجود ندارد. در واقع، پارامترهای ورودی، انتخاب‌هایی در دست طراحان هستند و عمدتاً به قضاوت مهندسی وابسته هستند.

در این مطالعه، یک روش نسبتاً جدید در زمینه پیش‌بینی مقاومت فشاری تک محوره سنگ، یعنی روش مدیریت داده‌ها به صورت گروهی (GMDH) معرفی شده است. بررسی مطالعات انجام شده بوسیله روش GMDH در سایر مسائل نشان دهنده قابلیت بالای روش انتخاب شده در حل مسائل مهندسی عمران و زمین‌شناسی مهندسی است. به جهت مقایسه کاربردی بودن روش مورد مطالعه، روش‌های پیش‌بینی دیگر، یعنی شبکه عصبی مصنوعی (ANN) و رگرسیون ماشین بردار پشتیبان (SVR) در نظر گرفته شد. در بخش‌های زیر، ابتدا اصول و مبانی نظری روش‌های اشاره شده هوش مصنوعی به

مهم‌ترین چالش آن است که تعیین یک شبکه عصبی از نوع GMDH به گونه‌ای صورت پذیرد که مربع اختلافات بین خروجی واقعی و پیش‌بینی شده، کمینه گردد، به عبارتی:

$$\sum_{i=1}^M [f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow \min \quad (3)$$

روابط کلی بین پارامترهای ورودی و خروجی را می‌توان با استفاده از فرم گسسته سری Volterra به شکل زیر بیان کرد:

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \dots \quad (4)$$

که در آن  $y$  به‌طور کلی به عنوان چند جمله‌ای Kolmogorov-Gabor شناخته می‌شود. این شکل کامل توصیف ریاضی را می‌توان با یک سیستم چند جمله‌ای درجه دو جزیی که تنها متشکل از دو متغیر (نورون‌ها) است، به شکل زیر نشان داد:

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + \dots \quad (5)$$

طراحی شبکه‌های عصبی GMDH دربرگیرنده دو مفهوم اصلی هستند: پارامترها و ساختار ساختار یک سیستم GMDH با چهار ورودی مدل، در شکل ۱ نشان داده شده است. هنگامی که GMDH طراحی می‌شود، باید به خاطر داشته باشید که تمام چند جمله‌ای‌های نورون‌ها که در هر یک از لایه‌های شبکه وجود دارند، مشابه یکدیگر هستند و شبکه براساس فرآیندهای مشابه طراحی شده است. در حقیقت چند جمله‌ای مرتبه دوم، ساختار بنیادی شبکه GMDH است که توسط ایواخنکو (Ivakhnenko, 1968) (۱۹۶۸) معرفی شده است. چندجمله‌ای درجه دو شامل شش ضریب وزنی است که می‌تواند با موفقیت مشکلات مهندسی مختلف را حل کند (Najafzadeh and Barani, 2011). از طرف دیگر، با توجه به بررسی مطالعات مربوطه، انتخاب یک چند جمله‌ای در میان انواع مختلف به شدت به دو پارامتر وابسته است که عبارتند از: حداقل خطای تابع هدف و پیچیدگی نوع چند جمله‌ای. همان‌گونه که در شکل ۱ مشخص است، پروسه انتخاب (با توجه به معیارهای مدنظر از قبیل تابع خطا) و ساخت چندجمله‌ای با درجات بالا تا رسیدن به لایه خروجی ادامه می‌یابد و در انتها خروجی سیستم با مقادیر واقعی مقایسه می‌گردند. لازم به ذکر است،

اختصار بیان شده است. لازم به ذکر است با توجه به تخصصی بودن مجله، تعدد روش‌ها و لزوم رعایت اختصار، در این بخش از ذکر مبانی نظری شبکه‌های عصبی که تا حدودی برای مخاطبین آشنا است، خودداری شده است و به توضیح مبانی نظری GMDH و SVR اکتفا شده است. اگرچه بین شبکه‌های عصبی و GMDH به جهت ساختار لایه‌ای، شباهت‌هایی نیز وجود دارد. در ادامه پس از توضیحاتی در خصوص چارچوب تجربی و پس از انجام مدل‌های رگرسیون ساده و رگرسیون چند متغیره، توسعه مدل ANN، GMDH و SVR در پیش‌بینی مقاومت سنگ، شرح داده شده است. در نهایت، مدل‌های پیشنهادی با استفاده از شاخص‌های عملکرد شناخته شده، ارزیابی و مدل یا مدل‌های بهینه برای تخمین UCS معرفی شده‌اند.

## ۲. مبانی نظری مدل‌های پیش‌بینی کننده

### ۱-۲ مدل GMDH

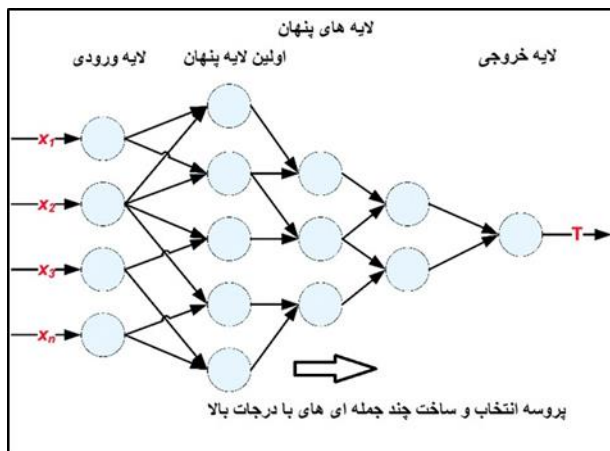
الگوریتم GMDH مبتنی بر مجموعه‌ای از نورون‌های تشکیل شده در لایه‌های مختلف می‌باشد. در هر لایه، زوج نورون‌های مختلف با یک چندجمله‌ای درجه دوم به هم متصل می‌شوند. به این ترتیب، آن‌ها نورون‌های جدیدی را در لایه بعدی تولید می‌کنند. با استفاده از این نوع نمایش، ورودی‌ها را می‌توان به خروجی‌ها منطبق کرد. در این روش تابع  $f$  که تقریباً می‌توان جایگزین تابع  $f$  فرض کرد، به کار گرفته می‌شود به گونه‌ای که برای بردار پارامترهای ورودی  $X = (x_1, x_2, x_3, \dots, x_n)$  قادر به پیش‌بینی خروجی  $\hat{y}_i$  باشد به صورتی که حتی‌الامکان به خروجی واقع  $y_i$  نزدیک باشد. در نتیجه، برای  $M$  مشاهده از داده‌های دارای چند ورودی و یک خروجی، داریم:

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (1)$$

حال، یک شبکه عصبی مبتنی بر GMDH می‌تواند به روشی آموزش ببیند که مقادیر خروجی  $\hat{y}_i$  را برای هر بردار ورودی داده شده در  $X = x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}$  پیش‌بینی کند، یعنی:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (2)$$

تعداد لایه‌های پنهان، جز پارامترهایی است که توسط طراح تعیین می‌گردد.



شکل ۱. ساختار فرضی یک سیستم GMDH با ۴ ورودی.

بعدی نگاشت می‌شوند. متعاقباً با ایجاد یک ابر صفحه، بردارهای ورودی با بیشترین فاصله از یکدیگر جدا می‌شوند. به جهت رفع مشکل چند بعدی بودن و غیر خطی بودن نگاشت و مشکل انجام عملیات در یک فضای با ابعاد زیاد، می‌توان از یک تابع کرنل استفاده کرد. در نتیجه، عملیات می‌تواند با همان سرعت فضای داده‌های ورودی انجام شود.

در حقیقت، هدف SVR تعیین وزن‌های بهینه و اریب (بایاس) تابعی است که به بهترین شکل، روی داده‌ها برازش شود (Yu and Kim, 2012). بانک داده D که به صورت رابطه زیر نشان داده شده است را در نظر بگیرید:

$$D = [(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)], \quad x \in R^n, y \in R \quad (6)$$


و همچنین تابع ساده خطی که ارتباط بین ورودی و خروجی را برقرار می‌کند به صورت زیر در نظر بگیرید:

$$f(x) = \langle w, x \rangle + b, \quad w \in X, \quad b \in R \quad (7)$$

جایی که ضرب داخلی بین وزن‌ها، w و بردار ورودی x است. پارامتر b یک کمیت اسکالر است که اصطلاحاً بایاس نامیده می‌شود. در این مطالعه، ورودی x شامل مقادیر دانسیته خشک (γd)، سرعت سیر موج (Vp) و دوام شکستگی و بار نقطه‌ای است. خروجی Y مقدار UCS است. لازم به ذکر است که هر ورودی x می‌تواند دارای n ویژگی باشد یا اصطلاحاً متعلق به

۲-۲. رگرسیون ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان (Support vector machine, SVM) در حقیقت مدل‌های هوشمندی هستند که با استفاده از الگوریتم‌های آموزشی، جهت آنالیز داده‌ها و یا تشخیص الگوها به کار گرفته می‌شوند. در حقیقت SVM ها که جز روش‌های آموزش نظارت شده هستند، به دو دسته کلی تقسیم می‌شوند که یک دسته جهت طبقه‌بندی و دسته دیگر جهت رگرسیون به کار گرفته می‌شوند. محققین زیادی به قابلیت‌های ماشین بردار پشتیبان در حل مسائل مهندسی ژئوتکنیک و یا زمین‌شناسی مهندسی اشاره کرده‌اند (Armaghani et al., 2019, Hasanipanah et al., 2015, Khandelwal and Monjezi, 2013). ماشین‌های بردار پشتیبان در ابتدا در دهه ۱۹۶۰ توسط واپنیک و لرنر (۱۹۶۳) (Vapnik and Lerner, 1963) ابداع گردید. تحقیقات روی توسعه ماشین بردار پشتیبان ادامه یافت و در ادامه، مطالعه واپنیم و همکاران (۱۹۹۷) (Vapnik and et al., 1997) نشان داد که SVM ها می‌توانند در حل و پیش‌بینی مسائل غیرخطی نیز به کار گرفته شوند. در حقیقت، همان‌گونه که در مطالعه احمدی و امیری بختیار (۱۳۹۷) اشاره شده است، رگرسیون بردار پشتیبان یا (Support Vector Regression) روشی است که به منظور پیش‌بینی و تخمین یک تابع بر مبنای داده‌های آموزش استفاده می‌گردد. بردارهای ورودی در این قبیل مسائل (رگرسیون)، به یک فضای چند



شکل ۲. محدوده‌ی قابل اغماض در SVR (سمت چپ) و

تابع  $\zeta_\epsilon$  سمت راست.

مسئله بهینه‌سازی مشخص شده در رابطه ۱۰ را با در نظر گرفتن قیدهای آن (به عنوان مثال رابطه ۱۱)، می‌توان به کمک استخراج فرم دوگانه آن‌ها و با استفاده از توابع و ضرایب لاگرانژ حل کرد که به جهت رعایت اختصار از توضیح آن خودداری می‌گردد. در نهایت پس از تبدیل مسئله اصلی به یک مساله دوگانه می‌توان مدل رگرسیونی را به فرم زیر نمایش داد:

$$\mathbf{w} = \sum_{i=1}^k (\alpha_i - \alpha_i^*) \mathbf{x}_i \quad (11)$$

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) \langle \mathbf{x}_i, \mathbf{x} \rangle + b \quad (12)$$

جایی که مقدار  $b$  با استفاده از شرایط (Karush-Kuhn) Tucker تعیین می‌گردد (Karush, 1939, Kuhn and Tucker, 1951, Smola and Schölkopf, 2004). لازم به ذکر است که ضرایب  $\alpha_i$  نشان داده شده در روابط ۱۱ تا ۱۴، ضرایب لاگرانژ هستند. همان‌گونه که در ابتدای این قسمت اشاره شد، برای تبدیل مسائل خطی به مسائل غیرخطی، می‌توان از توابع کرنل استفاده کرد. در این‌گونه مسائل، رابطه ۱۲ به فرم رابطه ۱۴ نوشته می‌شود، که در آن  $k(\mathbf{x}_i, \mathbf{x})$  تابع کرنل است. مطالعات متعددی از جمله علی پور و همکاران (۱۳۹۹)، حسنی پناه و همکاران (۲۰۱۵) (Hasanipanah et al., 2015) استفاده از تابع کرنل گوسین شعاعی را در SVR توصیه کرده‌اند. لازم به ذکر است، در این مقاله نیز از توصیه‌های این مطالعات استفاده شده است.

$$b = \begin{cases} y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle - \epsilon & \text{for } 0 < \alpha_i < C \\ y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle + \epsilon & \text{for } 0 < \alpha_i^* < C \end{cases} \quad (13)$$

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) k(\mathbf{x}_i, \mathbf{x}) + b \quad (14)$$

فضایی با  $n$  بعد باشد. همان‌گونه که در رابطه ۸ مشخص است، برای به دست آوردن مقدار تابع  $f$  نیازمند تعیین دو پارامتر  $w$  و  $b$  هستیم. بدیهی است که ساده‌ترین شکل تابع، زمانی خواهد بود که پارامتر  $w$ ، صفر باشد. به همین دلیل، کمینه کردن مقادیر  $w$  حائز اهمیت است. مقادیر بهینه  $w$  و  $b$  با حل و کمینه کردن رابطه زیر تخمین زده می‌شوند.

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) \quad (8)$$

مشروط بر اینکه:

$$\begin{cases} y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle - b \leq \epsilon + \zeta_i \\ \langle \mathbf{w}, \mathbf{x}_i \rangle + b - y_i \leq \epsilon + \zeta_i^* \\ \zeta_i, \zeta_i^* \geq 0 \end{cases} \quad (9)$$

در روابط بالا  $\zeta_i$  و  $\zeta_i^*$  متغیرهای مرتبط با تخطی (slack variables) نامیده می‌شوند چرا که بیانگر میزان تخطی از محدوده‌ی قابل قبول می‌باشند. لازم به ذکر است در رگرسیون بردار پشتیبان با در نظر گرفتن مقداری خطای قابل اغماض ( $\epsilon$ ) می‌توان یک مرز یا حاشیه بالا و پایین برای بهترین خط برازش شده روی داده‌ها در نظر گرفت (رج. شکل ۲). به عبارت دیگر مادامی که داده‌ها در محدوده‌ی خطای قابل اغماض ( $\epsilon$ ) قرار دارند، فضای قابل قبول محسوب می‌گردد، ولیکن برای داده‌هایی که خارج از محدوده یا حاشیه‌های مجاز بالا و پایین قرار دارند، SVR اصطلاحاً جرایمی را با معرفی یک تابع زیان یا خطا  $\zeta_\epsilon$ ، در نظر می‌گیرد به گونه‌ای که چنانچه میزان خطا بین خروجی واقعی و خروجی تخمینی کمتر از  $\epsilon$  بود، مقدار  $\zeta_\epsilon$  صفر در نظر گرفته می‌شود (رج. شکل ۲). در غیراین صورت،  $\zeta_\epsilon$  مقداری مثبت خواهد بود. تابع  $\zeta_\epsilon$  را می‌توان به صورت رابطه ۱۰ نیز نشان داد. لازم به ذکر است که پارامتر  $C$  در رابطه ۱۰، یک پارامتر ثابت کنترل کننده است که مقدار آن طی یک فرآیند سعی و خطا توسط کاربر تعیین می‌گردد. در حقیقت قسمت اول رابطه ۱۰ مربوط به کمینه کردن مقادیر وزن‌ها و قسمت دوم رابطه ۱۰ مربوط به کمینه کردن تابع  $\zeta_\epsilon$  می‌باشد.

$$|\zeta|_\epsilon = \begin{cases} 0 & |\zeta| \leq \epsilon \\ |\zeta| - \epsilon & \text{otherwise} \end{cases} \quad (10)$$

### ۳. مواد و روش‌ها

به‌منظور انجام این مطالعه، ۵ بلوک سنگ آهک در ابعاد تقریبی  $20 * 30 * 30$  سانتی‌متر از نقاط مختلف استان همدان جمع‌آوری شده و به آزمایشگاه انتقال داده شده‌اند (شکل ۳). در آزمایشگاه با استفاده از یک دستگاه مغزه‌گیر دورانی، تعداد ۶۰ نمونه مغزه استوانه‌ای با قطر  $54/1$  میلی‌متر و نسبت طول به قطر  $2/5$ ، مطابق با دستورالعمل ISRM تهیه شده است. همچنین، انتهای هر نمونه در جهت عمود بر محور آن کاملاً مسطح شده است. شکل ۴ برخی از بلوک‌های جمع‌آوری شده و یک نمونه آزمایش مقاومت فشاری تک محوری را نشان می‌دهد. برای تمام نمونه‌های جمع‌آوری شده، ویژگی‌های فیزیکی، یعنی دانسیته خشک ( $\gamma_d$ )، سرعت سیر موج ( $V_p$ ) و دوام شکستگی ( $Id_2$ ) تعیین شده است. علاوه بر این، آزمایش بار نقطه‌ای به منظور اندازه‌گیری مقدار شاخص بار نقطه‌ای ( $I_{s50}$ ) برای تمام نمونه‌ها، استفاده شده است. همچنین، آزمایش

مقاومت فشاری تک محوری برای تعیین مقاومت فشاری نامحصور همه نمونه‌ها (UCS) مطابق با دستورالعمل (۱۹۸۱) ISRM انجام شده است. به‌طور کلی یک پایگاه اطلاعاتی شامل ۶۰ مجموعه داده برای مدل‌سازی تکنیک‌های پیش‌بینی کننده، ANN SVR و GMDH مورد استفاده قرار گرفته است. به این منظور، پارامترهای دانسیته خشک، سرعت موج، شاخص دوام و شاخص بار نقطه‌ای به‌عنوان ورودی استفاده شده‌اند و UCS به عنوان پارامتر خروجی در نظر گرفته شده است. بر اساس نتایج آزمایش‌های فیزیکی و مکانیکی ارائه شده در جدول ۱، مقادیر دانسیته خشک، سرعت موج، دوام، بار نقطه‌ای و مقاومت فشاری نامحصور به ترتیب بین  $2/59 - 2/77$  گرم بر سانتی‌متر مکعب،  $3478 - 6697$  متر بر ثانیه،  $97/64 - 99/71$  درصد،  $5/46 - 1/19$  مگاپاسکال و  $39/41 - 103/99$  مگاپاسکال تغییر می‌کند (ر.ج شکل ۵).



شکل ۳. موقعیت نقاط نمونه‌برداری در استان همدان.



شکل ۴. تصاویری برخی از بلوک‌های جمع‌آوری شده و آزمایش مقاومت فشاری تک محوری.

جدول ۱. نتایج آزمایش های فیزیکی و مکانیکی سنگ های آهکی مورد مطالعه

No.	Vp (m/sec)	Is50 (MPa)	Dry density (gr/cm <sup>3</sup> )	Id2 (%)	UCS (MPa)
1	6410.00	4.86	2.689	99.5	99.31
2	6176.12	3.39	2.754	99.68	88.02
3	4295.42	3.13	2.64	99.11	89.53
4	3832.13	2.56	2.61	97.64	39.41
5	3796.58	2.66	2.62	97.76	46.57
6	6426.20	5.19	2.72	99.47	101.06
7	4426.69	2.88	2.67	99.21	75.91
8	5488.48	4.33	2.68	98.89	89.54
9	5670.34	4.10	2.69	99.05	89.18
10	4021.98	2.90	2.64	98.92	71.50
11	5670.34	4.10	2.69	99.05	89.18
12	5596.67	3.92	2.69	99.12	87.76
13	5627.53	4.70	2.68	99.44	96.86
14	4400.40	3.82	2.67	98.11	76.93
15	3967.97	2.92	2.63	98.79	62.48
16	4270.10	3.30	2.66	99.26	93.06
17	4528.69	3.15	2.65	98.98	71.40
18	4013.24	3.03	2.63	98.84	70.17
19	3478.03	1.19	2.59	97.77	43.15
20	4198.40	3.28	2.65	99.08	86.61
21	5033.77	2.16	2.69	98.55	71.40
22	4602.16	2.68	2.70	98.48	79.95
23	5310.00	4.87	2.67	99.36	93.39
24	5111.89	4.24	2.68	98.33	84.73
25	5395.25	4.70	2.68	99.42	97.41
26	3983.28	3.22	2.635	98.54	67.25
27	3761.03	2.75	2.62	98.87	53.72
28	5812.09	3.51	2.73	99.65	89.542
29	5276.14	3.42	2.71	98.63	87.45
30	5217.62	2.76	2.72	98.6	81.491
31	5187.02	2.58	2.691	98.62	76.123
32	5032.11	2.37	2.685	98.54	71.302
33	4882.17	1.52	2.682	98.5	66.76
34	4322.14	3.84	2.71	99.45	93.13
35	4307.31	3.61	2.7	99.4	90.42
36	4311.09	3.56	2.682	99.32	89.241
37	4278.34	3.35	2.671	99.41	92.34
38	4236.54	3.41	2.66	99.27	97.32
39	5401.23	4.79	2.681	99.48	100.07
40	5389.26	4.61	2.679	99.36	94.74



41	5309.64	4.53	2.673	99.4	93.321
42	5231.09	5.46	2.668	99.32	92.123
43	6029.2	4.29	2.66	99.012	87.023
44	5901.11	2.16	2.664	99.11	84.141
45	5876.04	3.92	2.653	98.904	83.41
46	5939.19	3.78	2.641	98.79	91.02
47	5437.19	2.65	2.63	98.65	78.25
48	6440.38	3.66	2.767	99.71	90.98
49	6332.03	4.6	2.761	99.7	91.324
50	6283.32	3.62	2.75	99.66	89.651
51	6697.21	5.37	2.741	99.69	103.99
52	6532.06	5.301	2.73	99.58	101.61
53	6367.19	5.19	2.721	99.39	98.031
54	6108.34	4.903	2.703	99.23	100.62
55	5978.32	4.86	2.694	98.89	96.02
56	5785.19	4.59	2.69	98.46	92.23
57	5706.61	4.51	2.67	98.31	89.31
58	4674.09	4.11	2.671	98.09	82.11
59	4202.35	3.81	2.67	98.14	83.59
60	4324.76	3.55	2.663	98.11	65.09
Min	3478.03	1.19	2.59	97.64	39.41
Max	6697.21	5.46	2.77	99.71	103.99
Avg	5138.35	3.70	2.68	98.96	83.99
STD	868.08	0.98	0.04	0.53	14.39

#### ۴. تحلیل مدلی

یا R انجام شده است. مقدار R را با استفاده از رابطه زیر می‌توان محاسبه کرد:

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 (Y_i - \bar{Y})^2}} \quad (15)$$

جایی که  $X_i$  و  $Y_i$  به ترتیب مقادیر اندازه‌گیری شده آزمایشگاهی و مقادیر پیش‌بینی شده می‌باشند.  $\bar{X}$  و  $\bar{Y}$  نشان دهنده میانگین مقادیر تعیین شده است. مقدار ضریب همبستگی یا R بزرگ‌تر از ۰/۹ نشان‌دهنده بهترین عملکرد یک مدل پیش‌بینی کننده خواهد بود. اگر مقدار R یک رابطه تجربی بین ۰/۸ تا ۰/۹ باشد، یعنی عملکرد مدل خوب و قابل قبول است. در صورتی که مقدار ضریب همبستگی یا R کم‌تر از ۰/۸ باشد، یعنی عملکرد پیش‌بینی مدل قابل قبول نیست. بر اساس مقادیر R، بهترین نوع معادله تجربی توصیف کننده رابطه بین دانسیته خشک، سرعت موج، دوام، شاخص بار نقطه‌ای و UCS به

در این بخش، ابتدا آنالیز رگرسیون ساده به منظور شناسایی ارتباط بین پارامترهای مستقل و وابسته انجام شده است. در ادامه، بعد از ارزیابی نتایج آنها، مدل‌های ANN و GMDH، SVR به منظور پیش‌بینی UCS مورد بررسی قرار می‌گیرد.

#### ۴-۱. آنالیز رگرسیون ساده و چند متغیره

آنالیز رگرسیون ساده به منظور ارائه روابط تجربی بین پیش‌بینی کننده‌ها ( $V_p, \gamma_d, Id_2, I_{s50}$ ) و UCS نمونه‌های سنگ آهک مورد مطالعه، استفاده شده است. در ابتدا آنالیز روابط بین UCS و متغیرهای مستقل انجام شده است و سپس تعدادی از معادلات نمایی، خطی، توانی و لگاریتمی برای آنالیز رگرسیون ساده پیشنهاد شده است (جدول ۲ را مشاهده کنید). ارزیابی این روابط تجربی با استفاده از مقایسه نتایج ضریب همبستگی

ترتیب توانی، لگاریتمی، لگاریتمی و خطی به دست آمده است. (۱۷)  $UCS = 58.192 \ln(V_p) - 412.39$

روابط تجربی توسعه داده شده با استفاده از دانسیته خشک، (۱۸)  $UCS = 1977.5 \ln(Id_2) - 9001.9$





سرعت موج، دوام و شاخص بار نقطه‌ای به ترتیب در معادلات (۱۹)  $UCS = 11.24 I_{s50} + 42.36$

۱۶ تا ۱۹ نشان داده شده است.

$$UCS = 0.00076 \gamma_d^{9.437} \quad (۱۶)$$

جدول ۲. روابط تجربی توسعه داده شده برای تخمین UCS با استفاده از آنالیز رگرسیون ساده.

Equation type	Predictors	Equation	R
Power	$\gamma_d$	$UCS = 0.00076 \gamma_d^{9.437}$	0.648
	$V_p$	$UCS = 0.0862 V_p^{0.8046}$	0.684
	$Id_2$	$UCS = 1E-53 Id_2^{27.44}$	0.730
	$I_{s50}$	$UCS = 44.027 I_{s50}^{0.494}$	0.732
Exponential	$\gamma_d$	$UCS = 0.0071 e^{3.493 \gamma_d}$	0.643
	$V_p$	$UCS = 37.24 e^{0.0002 V_p}$	0.661
	$Id_2$	$UCS = 1E-10 e^{0.277 Id_2}$	0.729
	$I_{s50}$	$UCS = 47.40 e^{0.1496 I_{s50}}$	0.718
Linear	$\gamma_d$	$UCS = 247.11 \gamma_d - 577.98$	0.642
	$V_p$	$UCS = 0.0113 V_p + 25.921$	0.684
	$Id_2$	$UCS = 20.004 Id_2 - 1895.6$	0.742
	$I_{s50}$	$UCS = 11.24 I_{s50} + 42.36$	0.764
Logarithmic	$\gamma_d$	$UCS = 667.12 \ln(\gamma_d) - 573.31$	0.646
	$V_p$	$UCS = 58.192 \ln(V_p) - 412.39$	0.699
	$Id_2$	$UCS = 1977.5 \ln(Id_2) - 9001.9$	0.742
	$I_{s50}$	$UCS = 36.457 \ln(I_{s50}) + 37.718$	0.762

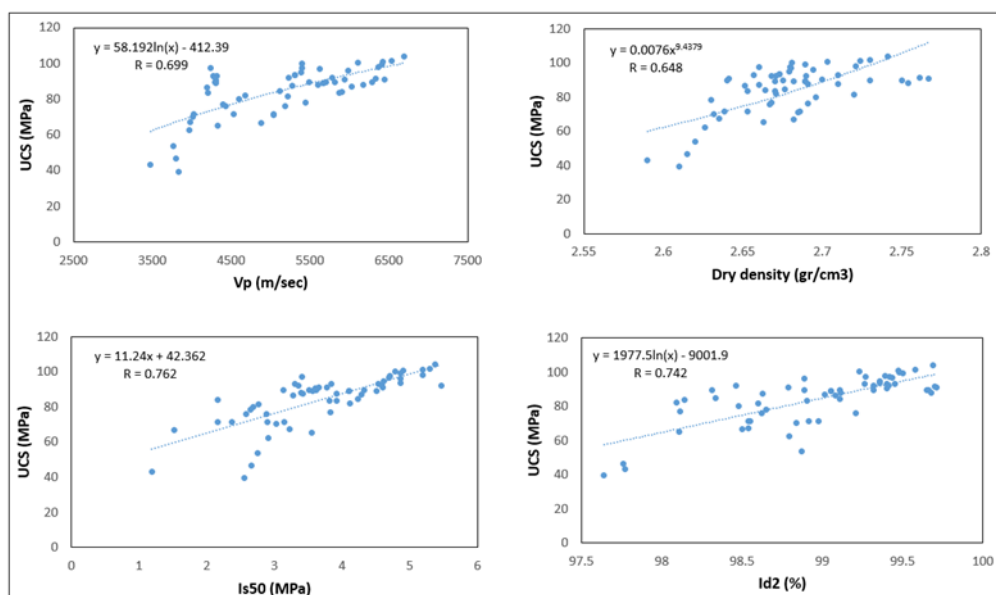


شکل ۵. مقادیر ۶۰ مجموعه داده (ورودی‌ها و خروجی استفاده شده در مرحله مدل سازی این مطالعه)


شکل ۶ ارتباط بین پارامترهای دانسیته خشک، سرعت موج، دوام و شاخص بار نقطه‌ای را با UCS نمونه‌های سنگ آهک مورد مطالعه نشان می‌دهد. همان‌طور که در این شکل نشان داده شده است، مقادیر ضریب همبستگی (R) این پیش‌بینی‌کننده‌ها به ترتیب ۰/۶۴۸، ۰/۶۹۹، ۰/۷۴۲ و ۰/۷۶۲ است که غیر قابل قبول می‌باشند. اگرچه، به نظر می‌رسد این نتایج زمانی که سطح بالایی از دقت مورد نیاز باشد، کافی نمی‌باشند. بنابراین، به منظور داشتن سطح دقت بالاتر برای پیش‌بینی مقاومت فشاری محدود نشده سنگ، همه پیش‌بینی‌کننده‌های مدل می‌توانند در توسعه تکنیک‌های چند ورودی مانند MLR مورد استفاده قرار گیرند. با توسعه مدل MLR، می‌توان یک رابطه چند متغیره خطی بین ورودی‌ها و خروجی (UCS) مدل پیدا کرد. در حقیقت، در این مدل اثرات همه ورودی‌های مدل بر روی نتایج خروجی در نظر گرفته می‌شود. مدل ذکر شده، در چندین مطالعه مرتبط، به‌منظور حل مسائل و مشکلات مهندسی استفاده شده است (Khandelwal and Monjezi, 2013, Gordan et al., 2016, Mohamad et al., 2017a).

$$UCS = 54.165\gamma_d + 0.002V_p + 10.141Id_2 + 6.596I_{s50} - 1097.744 \quad (16)$$

شکل ۷، ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده UCS را با استفاده از آنالیز رگرسیون چند متغیره یا MLR (معادله ۱۶) نشان می‌دهد. با توجه به اینکه مقدار ضریب همبستگی (R) معادله MLR پیشنهاد شده ۰/۸۸۳ است، عملکرد این معادله در پیش‌بینی UCS خوب و قابل قبول است. اگرچه، این نتایج بر اساس روش‌های آماری به دست آمده‌اند و به نظر می‌رسد اگر سیستم‌های هوش مصنوعی شبیه ANN و GMDH یا SVR مورد استفاده قرار گیرند، نتایج با دقت بالاتری حاصل گردد.



شکل ۶. ارتباط بین پارامترهای پیش‌بینی‌کننده و UCS.



شکل ۷. ارتباط بین مقادیر اندازه‌گیری شده و پیش بینی شده UCS با استفاده از MLR.

دو برابر تعداد ورودی ها رو به عنوان معیار تعیین نودهای مخفی پیشنهاد داده‌اند. در این مطالعه، با در نظر گرفتن این روابط و همچنین تجربه نویسندگان، آنالیز حساسیتی برای تعیین نودهای مخفی به کار گرفته شد و عملکرد شبکه با تعداد متفاوت نودهای مخفی ارزیابی شد. به جهت رعایت اختصار، نتایج این آنالیز حساسیت در این مطالعه ذکر نشده است. نتایج آنالیز حساسیت تعداد نود مخفی نشان داد که عملکرد مدل مبتنی بر شبکه عصبی زمانی که از ۵ نود مخفی استفاده می شود، بهینه است. به جهت کم کردن اثر تصادف، مدل بهینه، پنج بار تکرار شد و نتایج آن بر مبنای ضریب همبستگی یا R در جدول ۳ آورده شده است. همان گونه که در این جدول نشان داده شده است، سومین مدل، بهترین عملکرد را داشته است. لازم به ذکر است در شرایط یکسان، داده‌های آزمایش معیار انتخاب هستند. متوسط نتایج داده‌های آزمایش (R= ۰/۹۰۳) نشان دهنده کاربردی بودن مدل مبتنی بر شبکه عصبی (در مقایسه با مدل های رگرسیونی) جهت پیش بینی UCS سنگ آهک است.

جدول ۳. عملکرد مدل مبتنی بر شبکه عصبی در پیش بینی

مقدار UCS		ANN Model
Test	Train	
0.872	0.952	1
0.921	0.952	2
0.955	0.972	3
0.794	0.988	4
0.970	0.893	5
0.903	0.951	average

۲-۴. مدل شبکه عصبی پیش بینی کننده UCS

این بخش به فرآیند ایجاد مدل ANN برای پیش بینی UCS نمونه‌های سنگ آهک می‌پردازد. در ابتدا، تمام داده‌های مورد استفاده در مرحله آموزش و آزمایش به منظور ارزیابی و توسعه مدل باید از هم جدا شوند. نلسون و ایلینگورث (۱۹۹۱) (Nelson and Illingworth, 1991) پیشنهاد کردند که بین ۲۰ تا ۳۰ درصد کل داده‌ها باید به عنوان داده‌های آزمایش مدل مورد استفاده قرار بگیرد. بر این اساس، ما ۲۰ درصد (۱۸ داده) کل داده‌ها را برای آزمایش شبکه در نظر گرفته‌ایم. از آنجائی که بکارگیری موفق الگوریتم آموزش لونیبرگ-مارکوئث در بسیاری از مطالعات گزارش شده است (Hajihassani et al., 2015; Mohamad et al., 2017b)، در این مطالعه نیز به منظور طراحی ANN از این الگوریتم استفاده شده است. علاوه بر این، ANN با یک لایه مخفی قادر است که هر تابع پیوسته‌ای را تخمین بزند (Jahed Armaghani et al., 2016).

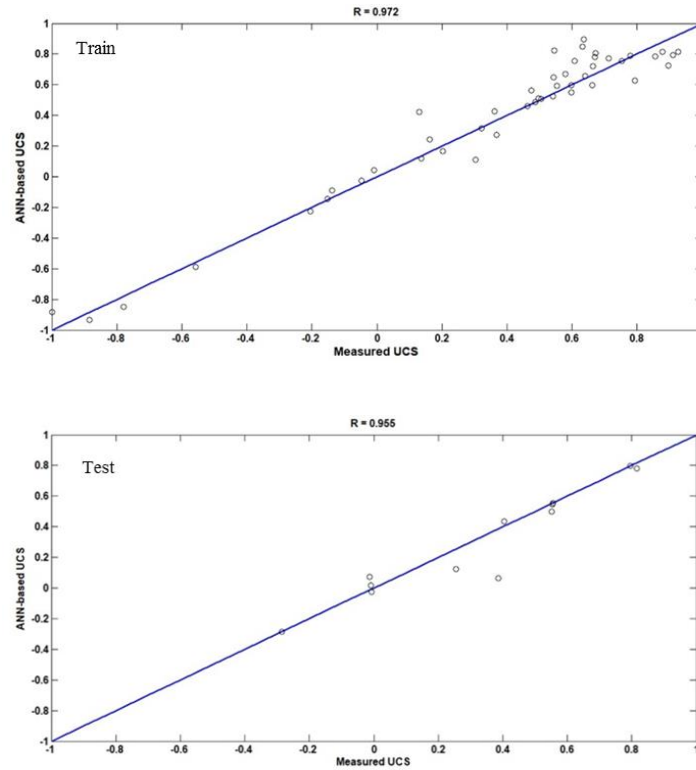
در مورد تعداد بهینه نودهای مخفی، دو توصیه غالب وجود دارد. برخی پژوهشگران، توصیه کرده‌اند که از روش سعی و خطا برای تعیین تعداد نودهای مخفی استفاده شود و برخی دیگر، روابطی را پیشنهاد کرده‌اند. به عنوان مثال، مسترز (۱۹۹۴) (Masters, 1994) مجذور حاصل ضرب تعداد ورودی در تعداد خروجی را برای تعیین تعداد نود مخفی توصیه کرده است. در حالی که کاسترا و بوید (۱۹۹۶) (Kaastra and Boyd, 1996)،

شده‌است. به خاطر داشته باشید که این تحقیق پارامتری، با استفاده از ۶ نورون و فشار انتخاب ۶۰ درصد انجام شد. تعداد مناسب نورون یا نودهای مخفی همانند شبکه عصبی، براساس سعی و خطا به دست آمد. ستون آخر جدول ۳، مدل GMDH شماره ۱۶ با ۷ لایه بهترین عملکرد (بالاترین رتبه) را در بین همه مدل‌ها نشان می‌دهد. بر اساس نتایج، برای مدل GMDH با ۷ لایه، بهترین عملکرد متوسط به دست آمد. مقادیر متوسط ضریب همبستگی یا R در مرحله آموزش و آزمایش به ترتیب ۰/۹۳۹ و ۰/۹۶۵ به دست آمد. اگرچه، همان‌گونه که در جدول ۴ نشان داده شده است، مدل ۱۶ با مقادیر R معادل با ۰/۹۴۴ و ۰/۹۷۵ برای داده‌های آموزش و آزمایش، بهترین عملکرد پیش‌بینی را داشته است، مدل شماره ۱۷ که نزدیک به بهترین مدل است، جهت مقایسه نهایی انتخاب شد. زیرا که عملکرد این مدل به متوسط عملکرد نزدیک تر بود و با توجه به اینکه هدف این مقاله، بررسی امکان کاربرد روش GMDH در پیش‌بینی UCS است، مقایسه بهتری صورت خواهد گرفت. در مجموع، مقادیر ضریب همبستگی داده‌های آزمایش مدل GMDH نشان داد که می‌توان مدلی مبتنی بر GMDH را به عنوان یک ابزار پیش‌بینی کننده کاربردی و مناسب در تخمین مقادیر UCS سنگ در نظر گرفت. توجه داشته باشید که در مدل GMDH توسعه داده شده، مقادیر ۷، ۶ و ۶۰٪ به ترتیب برای تعداد لایه، تعداد نورون و فشار انتخاب در نظر گرفته شده‌اند. در شکل ۹، ارتباط بین مقادیر UCS اندازه‌گیری شده در آزمایشگاه و مقادیر پیش‌بینی شده توسط مدل GMDH توسعه داده شده در این مطالعه (مدل شماره ۱۷)، برای مراحل آموزش و آزمایش نشان داده شده است.

همچنین در شکل ۸، بهترین عملکرد پیش‌بینی UCS (مقدار R آموزش ۰/۹۷۲ و R آزمایش ۰/۹۵۵) در بین مدل‌های مختلف ANN نشان داده شده است. این نتایج تأیید می‌کند که مدل ANN بهینه برای پیش‌بینی UCS سنگ آهک‌های مورد نظر، بایستی ساختار ۱-۵-۴ داشته باشد. همان‌گونه که در این شکل نشان داده شده است، ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده UCS معنادارتر از مدل‌های مبتنی بر رگرسیون هستند.

#### ۳-۴. توسعه مدل GMDH


برای طراحی یک مدل GMDH، لازم است که مهم‌ترین پارامترها شامل تعداد لایه‌های GMDH، تعداد نرون‌ها و همچنین پارامتر فشار انتخاب، مورد بررسی قرار بگیرند. فشار انتخاب، سیستم را قادر می‌سازد که چند جمله‌ای‌های بهینه را در هر مرحله انتخاب کرده و آن‌ها را به لایه‌های بعدی انتقال دهد. این فرآیند تا زمانی تکرار می‌شود که معیارهای از پیش تعیین‌شده، خطای سیستم مدنظر، محقق گردد. نتیجه مطالعه پارامتریک انجام شده نشان داد که درصد مناسب پارامتر فشار انتخاب، ۶۰ درصد می‌باشد. بنابراین، این مقدار برای بقیه فرآیند مدل‌سازی به کار گرفته شد. یک تحقیق پارامتری دیگر برای طراحی پارامتر کارآمد دیگر (تعداد لایه‌ها) در مدل GMDH مورد نیاز بود. به این منظور، براساس توصیه‌های برخی مطالعات انجام‌شده قبلی (Koopialipoor et al., 2018b)، تعداد ممکن لایه‌ها از ۲ تا ۸ تنظیم شده‌اند. سپس، ۲۱ مدل GMDH برای پیش‌بینی UCS سنگ آهک‌های مورد مطالعه، ساخته شدند و نتایج آن‌ها براساس ضریب همبستگی (R) داده‌های مرحله آموزش و آزمایش، در جدول ۴ نشان داده



شکل ۸. ارتباط بین مقادیر UCS اندازه گیری شده و پیش بینی شده توسط ANN در مرحله آموزش (Train) و آزمایش (Test).

جدول ۴. نتایج مطالعه پارامتریک بر روی تعداد لایه ها.

GMDH model No.	No. of hidden layer	R				Rank		
		Train	Test	Average train	Average test	Train	Test	Overall
1	2	0.926	0.943					
2	2	0.934	0.912	0.936	0.930	5	3	8
3	2	0.949	0.937					
4	3	0.908	0.906					
5	3	0.905	0.939	0.915	0.922	1	1	2
6	3	0.933	0.922					
7	4	0.947	0.912					
8	4	0.915	0.972	0.935	0.929	4	2	6
9	4	0.943	0.909					
10	5	0.923	0.9600					
11	5	0.932	0.977	0.933	0.959	3	6	9
12	5	0.946	0.940					
13	6	0.919	0.923					
14	6	0.935	0.956	0.928	0.955	2	5	7
15	6	0.929	0.987					
16	7	0.944	0.975					
17	7	0.947	0.966	0.939	0.965	6	7	13
18	7	0.925	0.955					
19	8	0.952	0.948					
20	8	0.934	0.940	0.933	0.951	3	4	7
21	8	0.913	0.967					



شکل ۹. ارتباط بین مقادیر اندازه گیری شده و پیش بینی شده UCS توسط مدل GMDH در مرحله آموزش و آزمایش.

به ذکر است که در مقایسه با جدول ۳ که نشان‌دهنده عملکرد متوسط مدل شبکه عصبی بود، مدل SVR نوسان کم‌تری در نتایج نشان داد که با توجه به ضعف‌های شبکه عصبی پس انتشار درگیر کردن در مینیمم نسبی دور از انتظار نیست، به همین دلیل گاه‌ا از الگوریتم‌های بهینه‌ساز نظیر ازدحام ذرات (Momeni et al., 2015a) برای بهبود عملکرد شبکه عصبی پس انتشار استفاده می‌گردد، اگرچه شبکه‌های عصبی پس انتشار، با توجه به شناخته شده بودن، همواره به عنوان ابزار مقایسه‌ای متداول مورد استفاده قرار می‌گیرند.

شکل ۱۰، نتایج عملکرد مدل SVR در پیش‌بینی مقاومت فشاری تک محوری آهک‌های مورد مطالعه را در مرحله آموزش و آزمایش نشان می‌دهد. بر اساس نتایج، ارتباط مناسبی بین مقادیر پیش‌بینی شده و اندازه‌گیری شده UCS در هر دو مرحله آموزش و هم در مرحله آزمایش به‌دست آمده است. ملاحظه می‌گردد که مقدار R بین مقادیر پیش‌بینی شده و اندازه‌گیری شده در مراحل آموزش و آزمایش به ترتیب ۰/۹۶۵ و ۰/۹۵۹ حاصل شده است. این نتایج حاکی از این است که به


#### ۴-۴. توسعه مدل SVR

همان‌گونه که در بخش مبانی نظری SVR ذکر گردید، در فرآیند ساخت مدل پیش‌بینی کننده SVR بهینه‌سازی، دو پارامتر حائز اهمیت است: ثابت کنترل کننده C و پارامتر مرتبط با خطای قابل اغماض (E). همان‌گونه که در مطالعه علی پور و همکاران (۱۳۹۹) ذکر گردیده است پارامترهای C و E را می‌توان با استفاده از یک آنالیز حساسیت تعیین کرد. به عبارت دیگر، تأثیر مقادیر مختلف این دو پارامتر را روی خروجی سیستم، می‌توان طی یک تحقیق پارامتری و سعی و خطا تعیین کرد. به جهت رعایت اختصار و با توجه به تعدد روش‌ها، از ذکر جزئیات تحقیق پارامتری خودداری می‌گردد. نتایج آنالیز حساسیت نشان داد که بهترین عملکرد پیش‌بینی زمانی حاصل شد که مقادیر C و E به ترتیب برابر ۱۰ و ۰/۰۵ اتخاذ گردید. شبیه مدل شبکه عصبی، در جدول ۵ عملکرد مدل SVR طی ۵ آنالیز نشان داده شده است. متوسط نتایج داده‌های آزمایش (R = ۰/۹۴۰) نشان دهنده کاربردی بودن مدل مبتنی بر SVR (در مقایسه با مدل های رگرسیونی) جهت پیش‌بینی UCS سنگ آهک است. لازم

صورت نسبی مدل SVR نیز قابلیت مطلوبی در پیش بینی مقادیر UCS سنگ‌های مورد مطالعه دارد.

جدول ۵. عملکرد مدل مبتنی بر SVR در پیش بینی مقدار UCS.

R		SVR Model
Test	Train	
0.959	0.965	1
0.917	0.966	2
0.947	0.958	3
0.932	0.965	4
0.946	0.962	5
0.940	0.963	Average



شکل ۱۰. ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده UCS توسط SVR در مرحله آموزش و آزمایش.

#### ۵. مقایسه عملکرد مدل های هوشمند

به منظور ارزیابی و مقایسه عملکرد مدل‌های توسعه داده شده در این مطالعه، از دو شاخص ارزیابی عملکرد یعنی ضریب همبستگی (R)، و RMSE استفاده شده است. محققین زیادی به صورت گسترده از شاخص‌های ذکر شده در بالا برای ارزیابی عملکرد مدل در کارهای مرتبط گذشته استفاده کرده اند

( Armaghani et al. 2020b, a; Han et al. 2020; Zhang et al. 2020).

در ادامه، فرمول محاسبه RMSE، ارائه شده است:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{ipred} - x_{imeas})^2} \quad (17)$$

جایی که،  $x_{ipred}$  و  $x_{imeas}$  به ترتیب مقادیر اندازه‌گیری شده و پیش‌بینی شده هستند و N نشان‌دهنده کل داده‌ها است. برای شاخص‌های  $R^2$  یا R و RMSE، در صورتی که یک مدل پیش‌بینی کننده کامل نیاز داشته باشیم، به ترتیب مقادیر یک و صفر




شده UCS در آزمایشگاه همراه با مقادیر پیش‌بینی شده به وسیله روش‌های ANN، GMDH و SVR در شکل ۱۱ ترسیم شده اند. ملاحظه می‌گردد که مقادیر UCS پیش‌بینی شده توسط ANN، GMDH و SVR به مقادیر اندازه‌گیری شده نسبتاً نزدیک بوده و هر سه مدل تقریباً عملکردی نزدیک به هم دارند. مقایسه عملکرد این ۳ مدل نسبت به مدل‌های رگرسیونی اشاره شده در بخش ۴-۱ مؤید این مطلب است. هرچند که بر اساس نتایج جداول ۳ و ۴ مشخص شد که برای بانک داده در نظر گرفته شده در این پژوهش، عملکرد مدل GMDH در مرحله آزمایش نسبت به دو مدل دیگر تا حدودی بهتر است. اگرچه به لحاظ فنی نمی‌توان به صورت عام در مورد برتری و رجحان روش‌های هوش مصنوعی نسبت به یکدیگر قضاوت کرد اما با توجه به مقایسه به عمل آمده می‌توان به کاربردی بودن روش GMDH اذعان کرد و این روش را قبل از ارزیابی و طراحی پروژه‌های ژئوتکنیکی به‌منظور پیش‌بینی UCS سنگ مورد استفاده قرار داد.

لازم است. نتایج محاسبه شده شاخص‌های ذکر شده برای پیش‌بینی مدل‌های ANN، GMDH و SVR در جدول ۵ لیست شده‌اند. بر اساس نتایج، کاملاً واضح است که هر سه مدل ANN، GMDH و SVR عملکرد موفق‌تری در مقایسه با مدل MLR دارند و می‌توان به کاربردی بودن هر ۳ روش اذعان کرد. همچنین، ملاحظه می‌گردد که نتایج GMDH در مرحله آزمایش تا حدودی بهتر از نتایجی است که توسط مدل ANN و SVR به دست آمده است. با توجه به این نکته که در مقایسه نهایی بهترین مدل ANN استفاده شده است، ذکر این نکته ضروری است که عملکرد متوسط SVR به مراتب بهتر از ANN بود. لازم به ذکر است که مقادیر R، RMSE برای مرحله آزمایش بهترین مدل ANN، GMDH و SVR به ترتیب (۰/۹۶۶، ۰/۱۱) ، (۰/۹۵۵، ۰/۱۰) و (۰/۹۵۹، ۰/۱۶) می‌باشند. مقایسه نتایج (ر.ج. جدول ۶) در مجموع نشان می‌دهد که مدل GMDH قادر است که یک روش پیش‌بینی کننده را فراهم کند که بدون نیاز به آزمایش UCS ارزیابی مناسبی از مقاومت فشاری محدود نشده سنگ آهک داشته باشیم. به‌منظور اینکه درک بهتری از نتایج مرحله آزمایش داشته باشیم، همه ۱۲ داده اندازه‌گیری

جدول ۶. شاخص‌های عملکرد محاسبه شده برای بهترین مدل‌های هوشمند ANN و GMDH.

Model	Data	R	RMSE
GMDH	Test	0.966	0.11
ANN	Test	0.955	0.10
SVR	Test	0.959	0.16



### شکل ۱۱. مقایسه بین عملکرد پیش بینی مدل های GMDH، ANN و SVR.

نتایج مشابهی توسط ترابی کاوه و همکاران (۲۰۱۴) گزارش شده است. آنها گزارش کردند که شبکه عصبی مصنوعی ( $R=0.955$ ) از قابلیت بالاتری در مقایسه با روش های رگرسیونی برای پیش بینی مقاومت فشاری تک محوری سنگ های آهکی با استفاده از ویژگی های آهکی برخوردار است. در مطالعه آنها ۳ پارامتر فیزیکی سرعت موج، دانسیته خشک و تخلخل به عنوان پارامترهای ورودی مورد استفاده قرار گرفته اند. همچنین در مطالعه ای دیگر، کریان و همکاران (۲۰۱۲) (Ceryan et al., 2012) با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره به پیش بینی مقاومت فشاری تک محوری سنگ های آهکی پرداخته اند. نتایج آنها حاکی از دقت بالاتر شبکه عصبی مصنوعی دارد. بر اساس مطالعه آنها، ضریب رگرسیون ( $R^2$ ) بین مقادیر پیش بینی شده و مقادیر واقعی در شبکه عصبی مصنوعی و رگرسیون چند متغیره به ترتیب  $0/812$  و  $0/740$  گزارش شده است. علاوه بر این جاهد ارمغانی و همکاران (۲۰۱۶) (Jahed Armaghani et al., 2016) با استفاده از تکنیک های مدل سازی مختلف به پیش بینی مقاومت فشاری تک محوری ماسه سنگ ها پرداختند. آنها متوجه شدند که مدل شبکه عصبی مصنوعی به مراتب عملکرد بهتری ( $R^2=0.949$ ) در مقایسه با آنالیز رگرسیون چند متغیره خطی ( $R^2=0.608$ ) دارد. در مطالعه ای دیگری که توسط لی و همکاران (۲۰۲۰) (Li et al., 2020) انجام شده است، ملاحظه شد که مدل GMDH عملکرد بهتری در مقایسه با مدل ANN و آنالیز رگرسیون برای پیش بینی مقاومت فشاری تک محوری گرانیته ها دارد. آنها گزارش کردند که مقدار  $R^2$  برای GMDH و ANN به ترتیب  $0/863$  و  $0/823$  به دست آمده است.

۵. نتیجه گیری

هدف از این مطالعه، توسعه یک مدل مبتنی بر هوش مصنوعی یعنی GMDH به منظور پیش بینی مقاومت فشاری تک محوری سنگ های آهکی است. به همین منظور، تعداد ۶۰ نمونه مغزه

سنگی از سنگ آهک های استان همدان تهیه شد و مطالعات آزمایشگاهی شامل آزمایش های تعیین دانسیته خشک، سرعت سیر موج، دوام شکستگی، بار نقطه ای و مقاومت فشاری تک محوری بر روی آنها انجام شده است. در ابتدا، چندین معادله تجربی برای پیش بینی UCS با استفاده از  $\gamma_d$ ،  $V_p$  و  $Id_2$  و  $Is50$  پیشنهاد شده است. با توجه به اینکه مقدار ضریب همبستگی یا  $R$  این معادلات بین  $0/642$  تا  $0/764$  متغیر است، این معادلات از دقت کافی برای پیش بینی UCS سنگ های مورد مطالعه برخوردار نیستند. علاوه بر این، مقدار  $R$  معادل  $0/883$  برای معادله MLR پیشنهاد شده نشان داد که به صورت نسبی معادله گفته شده از دقت قابل قبول تری برخوردار است، هر چند که نتایج MLR نشان داد که این مطالعه نیاز به توسعه مدل جدیدی دارد. بنابراین، مدل GMDH برای پیش بینی UCS این دسته از سنگ ها پیشنهاد شد. به منظور انجام یک مقایسه، یک ANN از قبل ساخته شده به عنوان یک بِنج مارک در روش های هوش مصنوعی، و همچنین یک مدل مبتنی بر رگرسیون ماشین بردار پشتیبان یا SVR نیز برای پیش بینی UCS سنگ ساخته شد. پس از فرآیند مدل سازی GMDH، ANN و SVR، مقادیر ضریب همبستگی ( $R$ ) متوسط برای مرحله آزمایش مدل GMDH، ANN و SVR به ترتیب  $0/945$ ،  $0/903$  و  $0/940$  می باشند. اگرچه، هر سه روش هوش مصنوعی مطالعه شده در این مقاله می توانند به عنوان ابزاری کاربردی در پیش بینی UCS سنگ ها به کار گرفته شوند، نتایج مطالعه نشان می دهد که روی بانک داده در نظر گرفته شده در این پژوهش، مدل GMDH و SVR به مراتب بهتر از مدل ANN (به عنوان یک مدل مقایسه ای پایه و شناخته شده)، قادر هستند که UCS سنگ های مورد مطالعه را پیش بینی کنند. فرآیند ایجاد مدل GMDH بررسی شده در این مقاله می تواند توسط طراحان و محققان در حل مشکلات مشابه، البته با در نظر گرفتن جوانب احتیاط مورد استفاده قرار گیرد.

نتایج مشابهی توسط ترابی کاوه و همکاران (۲۰۱۴) گزارش شده است. آنها گزارش کردند که شبکه عصبی مصنوعی ( $R=0.955$ ) از قابلیت بالاتری در مقایسه با روش های رگرسیونی برای پیش بینی مقاومت فشاری تک محوری سنگ های آهکی با استفاده از ویژگی های آهکی برخوردار است. در مطالعه آنها ۳ پارامتر فیزیکی سرعت موج، دانسیته خشک و تخلخل به عنوان پارامترهای ورودی مورد استفاده قرار گرفته اند. همچنین در مطالعه ای دیگر، کریان و همکاران (۲۰۱۲) (Ceryan et al., 2012) با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره به پیش بینی مقاومت فشاری تک محوری سنگ های آهکی پرداخته اند. نتایج آنها حاکی از دقت بالاتر شبکه عصبی مصنوعی دارد. بر اساس مطالعه آنها، ضریب رگرسیون ( $R^2$ ) بین مقادیر پیش بینی شده و مقادیر واقعی در شبکه عصبی مصنوعی و رگرسیون چند متغیره به ترتیب  $0/812$  و  $0/740$  گزارش شده است. علاوه بر این جاهد ارمغانی و همکاران (۲۰۱۶) (Jahed Armaghani et al., 2016) با استفاده از تکنیک های مدل سازی مختلف به پیش بینی مقاومت فشاری تک محوری ماسه سنگ ها پرداختند. آنها متوجه شدند که مدل شبکه عصبی مصنوعی به مراتب عملکرد بهتری ( $R^2=0.949$ ) در مقایسه با آنالیز رگرسیون چند متغیره خطی ( $R^2=0.608$ ) دارد. در مطالعه ای دیگری که توسط لی و همکاران (۲۰۲۰) (Li et al., 2020) انجام شده است، ملاحظه شد که مدل GMDH عملکرد بهتری در مقایسه با مدل ANN و آنالیز رگرسیون برای پیش بینی مقاومت فشاری تک محوری گرانیته ها دارد. آنها گزارش کردند که مقدار  $R^2$  برای GMDH و ANN به ترتیب  $0/863$  و  $0/823$  به دست آمده است.

## منابع

- اجل لوئیان، ر.، منصور، ح.، محمدی، م.، (۱۳۹۱). پیش‌بینی مدول الاستیک سنگ آهک با استفاده از رگرسیون چند متغیره و شبکه عصبی مصنوعی. مجله انجمن زمین شناسی مهندسی ایران، پائیز و زمستان ۱۳۹۱، جلد پنجم، شماره ۳ و ۴، صفحه ۳۳ تا ۳۸.
- احمدی، ر.، امیری بختیار، م. (۱۳۹۷). به کارگیری مدل رگرسیون ماشین بردار پشتیبان به منظور تخمین میزان اشباع شدگی آب سازند یکی از میدان‌های نفتی بزرگ جنوب غرب ایران. نشریه پژوهش‌های ژئوفیزیک کاربردی. ۴ (۲) ۱۹۹-۲۱۰.
- عبدی، ی.، قاسمی دهنوی، آ. (۱۳۹۸). پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیک ماسه‌سنگ‌ها با استفاده از شبکه عصبی مصنوعی و آنالیز رگرسیون چند متغیره. یافته‌های نوین زمین شناسی کاربردی، دوره ۱۳ شماره ۲۶ ف پاییز و زمستان ۱۳۹۸.
- علیپور، ع.، مختاریان اصل، م.، اسدی زاده، م.، (۱۳۹۹). تخمین حفاری ویژه انفجار در تونلهای کوچکمقطع با استفاده از ماشین بردار پشتیبان. مجله انجمن زمین شناسی مهندسی ایران، جلد سیزدهم، شماره ۱، صفحه ۱ تا ۱۳.
- Abdi, Y., Garavand, A.T., Sahamieh, R.Z., 2018. Prediction of strength parameters of sedimentary rocks using artificial neural networks and regression analysis. *Arabian Journal of Geosciences*, 11:587.
- Armaghani, D.J., Asteris, P.G., Fatemi, S.A., et al. 2020a. On the Use of Neuro-Swarm System to Forecast the Pile Settlement. *Applied Sciences*, 10:1904.
- Armaghani, D.J., Faradonbeh, R.S., Momeni, E., et al. 2018. Performance prediction of tunnel boring machine through developing a gene expression programming equation. *Engineering with Computer*, 34:129–141.
- Armaghani, D.J., Hatzigeorgiou, G.D., Karamani, C., et al. 2019. Soft computing-based techniques for concrete beams shear strength. *Procedia Structural Integrity*, 17:924–933.
- Armaghani, D.J., Kumar, D., Samui, P., et al. 2020b. A novel approach for forecasting of ground vibrations resulting from blasting: modified particle swarm optimization coupled extreme learning machine. *Engineering with Computer*, <https://doi.org/10.1007/s00366-020-00997-x>.
- Armaghani, D.J., Mohamad, E.T., Hajihassani, M., et al. 2016a. Application of several non-linear prediction tools for estimating uniaxial compressive strength of granitic rocks and comparison of their performances. *Engineering with Computer*, 32:189–206.
- Armaghani, D.J., Mohamad, E.T., Momeni, E., et al. 2016b. Prediction of the strength and elasticity modulus of granite through an expert artificial neural network. *Arabian Journal of Geosciences*, 9:48.
- Beiki, M., Majdi, A., Givshad, A., 2013. Application of genetic programming to predict the uniaxial compressive strength and elastic modulus of carbonate rocks. *International Journal of Rock Mechanics and Mining Sciences*, 63:159-169.
- Bejarbaneh, B.Y., Bejarbaneh, E.Y., Fahimifar, A., et al. 2018. Intelligent modelling of sandstone deformation behaviour using fuzzy logic and neural network systems. *Bulletin of Engineering Geology and the Environment*, 77:345–361.
- Bunawan, A.R., Momeni, E., Armaghani, D.J., Rashid, A.S.A., 2018. Experimental and intelligent techniques to estimate bearing capacity of cohesive soft soils reinforced with soil-cement columns. *Measurement*, 124:529–538.
- Ceryan, N., Okkan, U., Kesimal, A. 2012. Application of generalized regression neural networks in predicting the unconfined compressive strength of carbonate rocks. *Rock Mechanics and Rock Engineering*, 45:1055–1072.
- Diamantis, K., Gartzos, E., Migiros, G., 2009. Study on uniaxial compressive strength, point load strength index, dynamic and physical properties of serpentinites from Central Greece: test results and empirical relations. *Engineering Geology*, 108:199–207.
- Fang, Q., Bejarbaneh, B.Y., Vatandoust, M., et al. 2019. Strength evaluation of granite block samples with different predictive models. *Engineering with Computer*, <https://doi.org/10.1007/s00366-019-00872>.
- Gordan, B., Armaghani, D.J., Adnan, A.B., Rashid, A.S.A., 2016. A New Model for Determining Slope Stability Based on Seismic Motion Performance. *Soil Mechanics and Foundation Engineering*, 53:344–351. doi: 10.1007/s11204-016-9409-1.
- Hajihassani, M., Abdullah, S.S., Asteris, P.G., Armaghani, D.J., 2019. A Gene Expression Programming Model for Predicting Tunnel Convergence. *Applied Sciences*, 9:4650.

- Hajihassani, M., Jahed Armaghani, D., Marto, A., Tonnizam Mohamad, E., 2015. Ground vibration prediction in quarry blasting through an artificial neural network optimized by imperialist competitive algorithm. *Bulletin of Engineering Geology and the Environment*, 74:. doi: 10.1007/s10064-014-0657-x.
- Han, H., Armaghani, D.J., Tarinejad, R., et al. 2020. Random Forest and Bayesian Network Techniques for Probabilistic Prediction of Flyrock Induced by Blasting in Quarry Sites. *Natural Resources Research*, <https://doi.org/10.1007/s11053-019-09611-4>.
- Hasanipanah, M., Monjezi, M., Shahnazar, A., Jahed Armaghani, Danial., Farazmand, A., 2015. Feasibility of indirect determination of blast induced ground vibration based on support vector machine. *Measurement* 75: 289–297.
- ISRM (1981) Rock characterization, testing and monitoring, ISRM suggested methods. *Int Soc for Rock Mech* 211pp
- Ivakhnenko, A.G., 1968. The group method of data of handling; a rival of the method of stochastic approximation. *Sov Autom Control*, 13:43–55.
- Jahed Armaghani, D., Tonnizam Mohamad, E., Hajihassani, M., et al. 2016. Evaluation and prediction of flyrock resulting from blasting operations using empirical and computational methods. *Engineering with Computers*, 32: 109-121. doi: 10.1007/s00366-015-0402-5.
- Jahed Armaghani, D., Mohd Amin, M.F., Yagiz, S., Faradonbeh, R.S., Abdullah, R.A. 2016. Prediction of the uniaxial compressive strength of sandstone using various modeling techniques. *International Journal of Rock Mechanics and Mining Sciences*, 85, 174–186.
- Kaastra I, Boyd M (1996) Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10:215–236.
- Kahraman, S., Gunaydin, O., Fener, M., 2005. The effect of porosity on the relation between uniaxial compressive strength and point load index. *International Journal of Rock Mechanics and Mining Sciences*, 42:584–589.
- Khandelwal, M., 2013. Correlating P-wave velocity with the physico-mechanical properties of different rocks. *Pure Applied Geophysics*, 170:507–514.
- Khandelwal, M., Armaghani, D.J., Faradonbeh, R.S., et al. 2017. Classification and regression tree technique in estimating peak particle velocity caused by blasting. *Engineering with Computers*, 33:45–53.
- Khandelwal, M., Monjezi, M., 2013. Prediction of backbreak in open-pit blasting operations using the machine learning method. *Rock Mechanics and rock Engineering*, 46:389–396.
- Khandelwal, M., Singh, T.N., 2009. Correlating static properties of coal measures rocks with P-wave velocity. *International Journal of Coal Geology*, 79:55–60.
- Koopialipoor, M., Nikouei, S.S., Marto, A., et al. 2018b. Predicting tunnel boring machine performance through a new model based on the group method of data handling. *Bulletin of Engineering Geology and the Environment*, 78:3799–3813.
- Li, D., Jahed Armaghani, D., Zhou, J., Lai, S.H., Hasanipanah, M., 2020. A GMDH Predictive Model to Predict Rock Material Strength Using Three Non-destructive Tests. *Journal of Nondestructive Evaluation*, 39:81.
- Majdi, A., Beiki, M., 2010. Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Sciences*, 47:246–253.
- Marto, A., Hajihassani, M., Momeni, E., 2014. Bearing Capacity of Shallow Foundation's Prediction through Hybrid Artificial Neural Networks. In: *Applied Mechanics and Materials*, Trans Tech Publ, pp 681–686.
- Masters T (1994) *Practical neural network recipes in C++*. Academic Press, Boston MA
- Mohamad, E.T., Armaghani, D.J., Ghoroghi, M., et al. 2017a. Ripping Production Prediction in Different Weathering Zones According to Field Data. *Geotechnical and Geological Engineering*, 35:2381–2399. doi: 10.1007/s10706-017-0254-4.
- Mohamad, E.T., Faradonbeh, R.S., Armaghani, D.J., et al. 2017b. An optimized ANN model based on genetic algorithm for predicting ripping production. *Neural Computing & Applications*, 28:393–406.
- Mohamad, E.T., Jahed Armaghani, D., Momeni, E., Alavi Nezhad Khalil Abad, S.V., 2014. Prediction of the unconfined compressive strength of soft rocks: a PSO-based ANN approach. *Bulletin of Engineering Geology and the Environment*, 74: 745-757. doi: 10.1007/s10064-014-0638-0.
- Momeni, E., Armaghani, D.J., Fatemi, S.A., Nazir, R., 2018. Prediction of bearing capacity of thin-walled foundation: a simulation approach. *Engineering with Computers*, 34:319–327.

- Momeni, E., Armaghani, D.J., Hajihassani, M., Amin, M.F.M., 2015a. Prediction of uniaxial compressive strength of rock samples using hybrid particle swarm optimization-based artificial neural networks. *Measurement*, 60:50–63.
- Momeni, E., Nazir, R., Armaghani, D.J., Maizir, H., 2015b. Application of artificial neural network for predicting shaft and tip resistances of concrete piles. *Earth Science Research Journal*, 19:85–93.
- Momeni, E., Nazir, R., Armaghani, D.J., Mohamad, E.T., 2015c. Prediction of unconfined compressive strength of rocks: a review paper. *Jurnal Teknologi* 77(11): 11-2015.
- Moradian, Z.A., Behnia, M., 2009. Predicting the uniaxial compressive strength and static Young's modulus of intact sedimentary rocks using the ultrasonic test. *International Journal of Geomechanics*, 9:14–19.
- Najafzadeh, M., Barani, G.A., Azamathulla, H.M., 2013. GMDH to predict scour depth around a pier in cohesive soils. *Applied Ocean Research*, 40:35–41.
- Nazir, R., Momeni, E., Armaghani, D. J., Amin, M.M., 2013. Correlation between unconfined compressive strength and indirect tensile strength of limestone rock samples. *Electronic Journal of Geotechnical Engineering*, 18(1), 1737-1746.
- Negara, A., Ali, S., AlDhamen, A., Kesserwan, H., & Jin, G., 2017. Unconfined Compressive Strength Prediction from Petrophysical Properties and Elemental Spectroscopy Using Support-Vector Regression. In SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition. Society of Petroleum Engineers.
- Nelson, M.M., Illingworth, W.T., 1991. A practical guide to neural nets. Addison-Wesley Reading, MA.
- Priddy, K.L., Keller, P.E., 2005. Artificial neural networks: an introduction. SPIE press.
- Rezaei, H., Nazir, R., Momeni, E., 2016. Bearing capacity of thin-walled shallow foundations: an experimental and artificial intelligence-based study. *Journal of Zhejiang University-SCIENCE A*, 17:273–285.
- Singh, R., Kainthola, A., Singh, T.N., 2012 Estimation of elastic constant of rocks using an ANFIS approach. *Applied Soft Computing*, 12:40–45.
- Smola, A.J., Schölkopf, B., 2004. A tutorial on support vector regression. *Statistics and Computing* 14, 199–222 (2004).
- Tiryaki, B., 2008. Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees. *Engineering Geology*, 99:51–60.
- Tonnizam Mohamad, E., Hajihassani, M., Jahed Armaghani, D., Marto, A., 2014. Simulation of blasting-induced air overpressure by means of Artificial Neural Networks. *International Review on Modelling and Simulations*, 5(6):2501-2506.
- Torabi Kaveh, M., Naseri, F., Sanei, S., Sarshari, B. 2014. Application of artificial neural networks and multivariate statistics to predict UCS and E using physical properties of Asmari limestones. *Arabian Journal of Geosciences*, 8(5): 2889-2897.
- Ulusay R, Hudson JA ISRM (2007) The complete ISRM suggested methods for rock characterization, testing and monitoring: 1974–2006. *Comm Test methods Int Soc Rock Mech Compil arranged by ISRM Turkish Natl Group, Ankara, Turkey* 628:
- Xu, H., Zhou, J.G., Asteris, P., et al. 2019. Supervised Machine Learning Techniques to the Prediction of Tunnel Boring Machine Penetration Rate. *Applied Sciences*, 9:3715.
- Yang, H., Liu, J., Liu, B., 2018. Investigation on the cracking character of jointed rock mass beneath TBM disc cutter. *Rock Mechanics and Rock Engineering*, 51:1263–1277.
- Yesiloglu-Gultekin, N., Gokceoglu, C., Sezer, E.A., 2013. Prediction of uniaxial compressive strength of granitic rocks by various nonlinear tools and comparison of their performances. *International Journal of Rock Mechanics and Mining Sciences*, 62: 113-122. doi: 10.1016/j.ijrmms.2013.05.005.
- Yilmaz, I., Yuksek, G., 2009. Prediction of the strength and elasticity modulus of gypsum using multiple regression, ANN, and ANFIS models. *International Journal of Rock Mechanics and Mining Sciences*, 46:803–810.
- Yilmaz, I., Yuksek, A., 2008. An example of artificial neural network (ANN) application for indirect estimation of rock parameters. *Rock Mech Rock Eng*, 41: 781-795.
- Yu, H. and Kim, S., 2012. SVM tutorial: classification, regression, and ranking, *Handbook of Natural Computing*, Springer Berlin Heidelberg, 479-506

- 
- Zhang, H., Zhou, J., Armaghani, D.J., et al. 2020. A Combination of Feature Selection and Random Forest Techniques to Solve a Problem Related to Blast-Induced Ground Vibration. *Applied Sciences*, 10:869.
- Zhou, J., Aghili, N., Ghaleini, E.N., et al. 2019a. A Monte Carlo simulation approach for effective assessment of flyrock based on intelligent system of neural network. *Engineering with Computers*, <https://doi.org/10.1007/s00366-019-00726-z>.
- Zhou, J., Li, E., Yang, S., et al. 2019b. Slope stability prediction for circular mode failure using gradient boosting machine approach based on an updated database of case histories. *Safety Science*, 118:505–518.
- Zhou, J., Shi, X., Li, X., 2016. Utilizing gradient boosted machine for the prediction of damage to residential structures owing to blasting vibrations of open pit mining. *Journal of Vibration and Control*, 22:3986–3997.
- Vapnik, V. and Lerner, A. 1963. Pattern Recognition using Generalized Portrait Method. *Automation and Remote Control* 24: 774-780
- Vapnik, V., Golowich, S., and Smola, A. 1997. Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing. In *Advances in Neural Information Processing Systems 9*, edition M. C. Mozer, M. I. Jordan, and T Petsche, 281-287, Cambridge, Massachusetts: MIT Press.