

## کاربرد روش‌های هوشمند و آماری در تخمین مقاومت فشاری تک محوری ماسه سنگ‌ها

امیر آزاد مهر<sup>۱</sup>، امین ایرجی\*<sup>۲</sup>، مسعود دانش<sup>۲</sup>، محسن صفاریان<sup>۳</sup>

پذیرش مقاله: ۱۴۰۳/۱۱/۰۷

دریافت مقاله: ۱۴۰۳/۰۶/۱۰

### چکیده

اندازه گیری دقیق مقاومت فشاری تک محوره (UCS) در پروژه‌های عمرانی و معدنی ضروری و اجتناب ناپذیر است. اندازه گیری مستقیم این پارامتر با وجود دقت بالا، زمان بر، پر هزینه و دشوار است. هدف از تحقیق حاضر، تعیین غیرمستقیم مقاومت فشاری تک محوره به روش‌های آماری و هوشمند می‌باشد. بدین منظور ابتدا خصوصیات فیزیکی، شاخص بار نقطه‌ای، سرعت موج تراکمی و سختی اشمیت و مقاومت فشاری تک محوره نمونه‌های ماسه سنگ ساخته شده سیاه بیشه و نمونه‌های ماسه سنگ حاصل از شهر دماوند اندازه گیری شد. سپس عملکرد مدل‌های مختلف جهت تخمین UCS بر اساس سرعت موج تراکمی، سختی چکش اشمیت، شاخص بار نقطه‌ای و دانسیته با استفاده از رگرسیون خطی چند متغیره، الگوریتم جنگل تصادفی (RFA)، K-نزدیک‌ترین همسایه (KNN)، شبکه عصبی مصنوعی (ANN) و سیستم استنتاج فازی عصبی تطبیقی (ANFIS) بررسی شد. نتایج نشان داد که از میان عوامل موتاثر گذار، شاخص بار نقطه‌ای بیشترین تاثیر را بر مقاومت فشاری دارد. نتایج تخمین UCS به روش‌های هوشمند نشان داد که RFA نتایج دقیقتری نسبت به سایر روش‌های بررسی شده ارائه می‌کند. نتایج این روش نشان داد که مقدار شاخص عملکرد مدل، خطا (RMSE) و ضریب تعیین ( $R^2$ ) به ترتیب ۱،۹۶، ۰،۰۲ و ۰،۹۹ برای مجموعه داده‌های آزمون می‌باشند. درصد اختلاف UCS اندازه گیری شده با میانگین پیش‌بینی شده برابر با ۰،۱۸- درصد می‌باشد که نشان می‌دهد میانگین چهار روش مورد استفاده کمتر از یک درصد اختلاف را با مقدار متوسط اندازه گیری شده نشان می‌دهد و نشانگر کارایی بسیار بالای این روش‌ها در تخمین UCS می‌باشد. در نهایت، نتایج آزمون کروسکال-والیس نشان داد که تفاوت معنی داری بین مقادیر UCS اندازه گیری شده و پیش‌بینی شده وجود ندارد.

**کلید واژه‌ها:** خصوصیات فیزیکی و مکانیکی، مقاومت فشاری تک محوری، پیش‌بینی، روش‌های آماری و هوشمند.

<sup>۱</sup> استادیار، گروه مهندسی معدن، دانشگاه صنعتی بیرجند، بیرجند، ایران

<sup>۲</sup> استادیار، دانشکده فنی و مهندسی، دانشگاه صنعتی ارومیه، ارومیه، ایران

<sup>۳</sup> استادیار، گروه مهندسی صنایع، دانشگاه صنعتی بیرجند، بیرجند، ایران

## ۱. مقدمه

پایداری شیب‌ها، پیش‌بینی سرعت حفاری، طبقه‌بندی توده‌های سنگی، مدل‌سازی‌ها و غیره نیاز به دانستن مقاومت فشاری تک محوره (UCS) سنگ‌ها می‌باشد. پژوهشگران مختلف با استفاده از روش‌های آماری و هوش مصنوعی، UCS ماسه سنگ‌ها را پیش‌بینی کرده‌اند. برخی از این روابط تجربی برای سنگ‌های رسوبی و بخصوص ماسه سنگ‌ها در جدول ۱ ارائه شده است. به دلیل اهمیت تخمین مقاومت فشاری تک محوری، آلودجاره و همکاران (Aladejare et al., 2021) یک پایگاه داده بزرگ از روابط تجربی بین UCS و سایر خواص سنگ را که در ادبیات گزارش شده است، توسعه دادند. تعدادی مدل برای تخمین UCS سنگ‌ها با استفاده از روش‌های جنگل تصادفی (McElroy et al., 2021; Wang et al., 2020; Matin et al., 2018; ) ANFIS (Hudaverdi 2022; Yesiloglu-Gultekin et al., 2022; KNN (Khan et al., 2022; Sun Fathipour-Azar 2022) (et al., 2020; Zhang et al., 2023) توسعه داده شده است. هاشمی نژاد و صادقی (Hasheminezhad and Sadeghi, 2023) سنگ آهک را بر اساس نتایج آزمایش‌های ساده و ارزان با استفاده از ماشین بردار پشتیبان، سیستم استنتاج عصبی فازی تطبیقی و پرسپترون چند لایه تخمین زدند. نتایج آن‌ها نشان داد که ماشین بردار پشتیبان با دقت بالاتری در مقایسه با سایر روش‌ها مورد مطالعه UCS را پیش‌بینی می‌کند. برزگر و همکاران (Barzegar et al., 2016) نیز به پیش‌بینی UCS سنگ‌های تراورتن با استفاده از روش ANFIS پرداختند. همچنین، گال و همکاران (Gül et al., 2021) از روش‌های محاسبات نرم برای تخمین UCS از انواع مختلف سنگ استفاده کردند. سین و همکاران (Singh et al., 2017) نیز با استفاده از روش ANFIS و رگرسیون چند متغیره، UCS سنگ را تخمین زدند. عبدالهدی و همکاران (Abdelhedi et al., 2023) بر پیش‌بینی UCS سنگ‌های کربناته از تکنیک‌های یادگیری ماشین از جمله RFA استفاده کردند. مطالعه آن‌ها پتانسیل الگوریتم‌های یادگیری ماشین را

در تخمین مقاومت سنگ برای این نوع سنگ خاص نشان داد. افولاگبویه و همکاران (Afolagboye et al., 2023) یک مطالعه موردی برای سنگ‌های پرکامبرین از Ado-Ekiti، نیجریه انجام داد. آن‌ها مدل‌های یادگیری ماشینی را برای پیش‌بینی مقاومت فشاری تک محوری توسعه دادند و اثربخشی آن‌ها را در تخمین مقاومت سنگ برجسته کردند. وانگ و همکاران (Wang et al., 2023) از تکنیک‌های پیشرفته مبتنی بر درخت تصمیم بر اساس آزمایش‌های غیر مخرب و پتروگرافی برای پیش‌بینی UCS سنگ‌ها استفاده کرد. مطالعه آن‌ها کارایی الگوریتم‌های یادگیری ماشین را در پیش‌بینی مقاومت سنگ با استفاده از پارامترهای ورودی چندگانه نشان داد. رحمان و سرکار (Rahman and Sarkar, 2023) همبستگی بین مقاومت فشاری تک محوری و خواص دینامیکی را برای شش نوع سنگ مختلف بررسی کردند. مطالعه آن‌ها روابط بالقوه بین مقاومت فشاری تک محوری سنگ و خواص ارتجاعی دینامیکی را برجسته کرد و نکات ارزشمندی را برای پیش‌بینی مقاومت سنگ با استفاده از خواص کشسان ارائه داد. میاه و همکاران (Miah et al., 2020) یک رویکرد یادگیری ماشینی برای مدل‌سازی مقاومت سنگ با استفاده از داده‌های ورود به سیستم پیشنهاد کرد. با ادغام پارامترهای مختلف داده لاگ، آن‌ها یک مدل پیش‌بینی ایجاد کردند که پیش‌بینی‌های دقیقی از مقاومت سنگ را نشان می‌داد و اهمیت ترکیب داده‌های ورود به سیستم را در برآورد مقاومت سنگ نشان داد. زو و همکاران (Xu et al., 2023) مطالعه‌ای در مورد پیش‌بینی مقاومت فشاری تک محوری سنگ با استفاده از مدل‌های مختلف از جمله RFA ارائه کرد. مدل آن‌ها به پیش‌بینی‌های دقیق دست یافت و پتانسیل ترکیب تکنیک‌های مختلف برای تخمین مقاومت سنگ را نشان داد. قبادی و همکاران (۲۰۲۱) مطالعه‌ای جامع جهت ارزیابی و تخمین خصوصیات ژئومکانیکی ماسه‌سنگ‌ها انجام دادند. نتایج نشان داد 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

و رگرسیون فرایند گاوسی در پیش‌بینی مقاومت کششی با استفاده از داده‌های نمونه‌های سنگ مورد ارزیابی قرار گرفت. یافته‌ها نشان داد که ماشین بردار پشتیبان دقیق‌ترین نتایج را به همراه داشته است. به طور مشابه، تحقیقات دیگری نشان داد که روش RFA در هنگام تخمین مقاومت فشاری سنگ عملکرد بهتری از KNN، رگرسیون چند متغیره و شبکه عصبی مصنوعی داشت (Khan et al., 2022). علاوه بر این، تحقیقات سان و همکاران (Sun et al., 2020) نشان داد که در بین روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان، KNN و RFA، روش RFA دقیق‌ترین نتایج را برای تخمین شکنندگی سنگ با استفاده از داده‌های ۱۱۰ نمونه ارائه می‌کند. یوساری و همکاران (Yosri et al., 2023) عملکرد شبکه عصبی مصنوعی، ANFIS و ELM (یادگیری ماشین شدید) را در پیش‌بینی مقاومت برشی ارزیابی کرد. آن‌ها بیان کردند که مدل ANFIS در مقایسه با سایر روش‌ها عملکرد بهتری از خود نشان داد. در مطالعه دیگری برای پیش‌بینی مقاومت فشاری سنگ توسط الگوریتم‌های RFA، شبکه عصبی مصنوعی، ANFIS، KNN، ماشین بردار پشتیبان و رگرسیون فرایند گاوسی بر روی ۶۸ نمونه، ماشین بردار پشتیبان به عنوان دقیق‌ترین روش ظاهر شد (Zhang et al., 2023).

هدف این مطالعه پیش‌بینی UCS سنگ‌های رسوبی بر اساس متغیرهایی از جمله شاخص بار نقطه‌ای، دانسیته، سختی اشمیت و سرعت موج تراکمی با استفاده از روش‌های شبکه عصبی مصنوعی، رگرسیون چند متغیره، الگوریتم جنگل تصادفی، کای نزدیکترین همسایه (KNN)، و ANFIS می‌باشد.

سرعت موج طولی در حالت خشک و اشباع وجود دارد. چانگ و همکاران (Chang et al., 2006) با مرور تحقیقات سایر پژوهشگران یازده رابطه تجربی بین مقاومت تراکمی تک محوری ماسه سنگ‌ها و خصوصیات فیزیکی آن‌ها ارائه نمودند. حیدری و همکاران (۲۰۱۳) رابطه بین ویژگی پتروگرافی و خواص مهندسی ماسه سنگ‌های ژوراسیک همدان، را بررسی و روابط چند متغیره برای برآورد خواص فیزیکی و مکانیکی از ویژگی‌های پتروگرافی ارائه کردند. ونگ و لی (Weng and Li, 2012) ارتباط بین خواص مکانیکی و تخلخل ماسه سنگ‌ها را بررسی کردند. نتایج تحقیقات ناش و همکاران (Naresh et al., 2007) بر روی ماسه سنگ‌های هیمالیا در نپال نشان داد که درصد تخلخل و خصوصیات پتروگرافی همبستگی بالایی با ویژگی‌های مکانیکی نشان می‌دهند. مرادی و همکاران (۲۰۲۲) خصوصیات زمین‌شناسی مهندسی سنگ آهک‌های سازند ایلام را بررسی کردند و روابطی با دقت بالا جهت تخمین مقاومت فشاری ارائه کردند. قبادی و همکاران (۱۳۹۲) خصوصیات ماسه سنگ‌های سازند آجاجاری را بررسی و روابطی با دقت بالا جهت تخمین مقاومت تک محوری و مدول الاستیسیته ارائه کردند. حیدری و همکاران (۲۰۱۲) خصوصیات ژئوتکنیکی ماسه سنگ‌های منطقه قم در ایران مرکزی را بررسی کردند. عبدی و خانلری (۱۳۹۷) خصوصیات مکانیکی ماسه سنگ‌های سازند قرمز بالایی با استفاده از ویژگی‌های فیزیکی در چرخه‌های مختلف آزمایش انجماد - ذوب را بررسی کردند. در مطالعه‌ای توسط ژنگ و همکاران (Zheng et al., 2023)، عملکرد رگرسیون چند متغیره، ANFIS، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

جدول ۱- روابط محققین مختلف جهت تخمین مقاومت فشاری تک محوری سنگ با استفاده از روش‌های آماری

Equation	References	Lithology	Equation No.
$UCS=46.8+19.95 \text{ EXP } (-0.70*M)$	Tomor et al. (2023)	Sandstone	1
$UCS=58.20\ln(Vp) -412.39$	Momeni and Abdi (2022)	Limestone	2
$UCS = 12.29PLV^{1.233}$	Teymen and Mengüç (2020)	Different Rocks	3
$UCS = 2.304(Vp)^{2.43}$	Kılıç and Teymen (2008)	Different Rocks	4
$UCS = 0.043 Vp - 136.8$	Barham et al. (2020)	Basalt	5

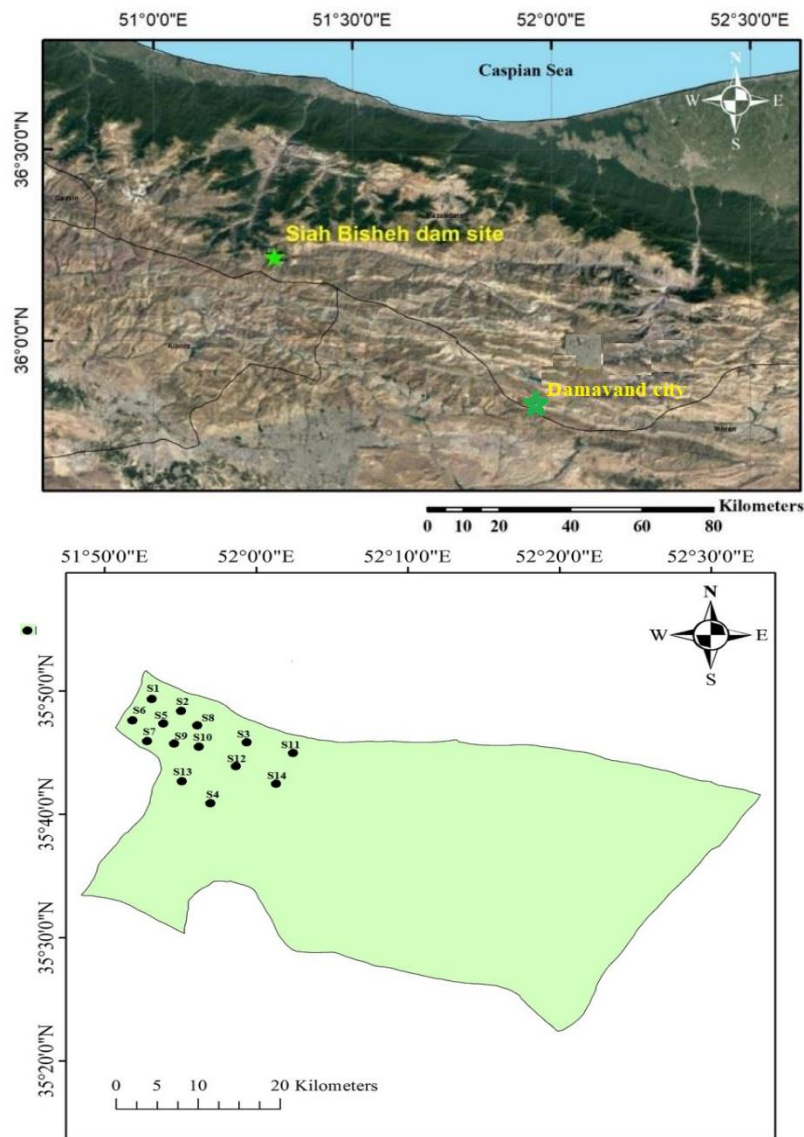
$UCS = 17.6PLV + 13.5$	Aliyu et al. (2019)	Sedimentary Rocks	6
$UCS = 14.3PLV$	Aladejare (2020)	Sedimentary Rocks	7
$UCS = 0.00021 \times Rn^{3.55}$	Yilmaz and Goktan (2019)	Different Rocks	8
$UCS = 0.00004 Rn^{4.164}$	Daoud et al. (2018)	Carbonate Rocks	9
$UCS = 0.007 * Rn^{3^2.443}$	Bolla and Paronuzzi (2021)	Sedimentary Rocks	10
$UCS = 2.56EXP(0.063 Rn)$	Hebib et al. (2017)	Sedimentary Rocks	11
$UCS = 0.007 * Rn^{2.443}$	Selçuk and Yabalak (2015)	Different Rocks	12
$UCS = 287.7 \gamma - 615.90$	Mishra and Basu (2013)	Sandstone	13
$126.40 - UCS = 0.05 Vp$	Mishra and Basu (2013)	Sandstone	14
$UCS = 3.73 * Vp^{2.1}$	Ghafoori et al. (2018)	Limestone	15
$UCS = 9.95 Vp^{1.21}$	(2001) Kahraman	Sedimentary Rocks	16
$86.36 - UCS = 0.034p$	Wen et al. (2018)	Limestone	17
$UCS = -5.10P + 110.79$	Edet (2018)	Sandstone	18
$UCS = 0.025 Vp - 8.619$	Azimian (2017)	Limestone	19
$UCS = 6.6 Vp^{1.6}$	Uyanik et al. (2019)	Sedimentary Rocks	20
$UCS = 22.18Vp - 30.32$	Selçuk and Nar (2016)	Different Rocks	21
$UCS = 0.041Vp - 15.40$	Abdi & Khanlari (2019)	Sandstone	22
$UCS = 10 - 5\gamma^{16.7}$	Aladejare (2020)	Sedimentary Rocks	23
$UCS = 3.62Rn - 42.57$	Abdi & Khanlari (2019)	Sandstone	24
$UCS = 1.151Rn + 10.52$	Ghobadi et al., (2019)	Sandstone	25
$UCS = -77.85 + 3.79Rn$	Moradi et al., 2021	Sandstone	26

Vp: سرعت موج تراکمی،  $\gamma$  دانسیته، W: جذب آب، P: تخلخل، M: رطوبت، UCS: مقاومت فشاری تک محوری و Rn: سختی اشمیت

شمشک با ضخامت بیش از ۲۵۰۰ متر مهم‌ترین سازند منطقه لار و البرز است و از ماسه سنگ، شیل و سیلت استون تشکیل شده است. در برخی مناطق، این سازند دارای لایه‌هایی از زغال سنگ است. سن این سازند تریاس پسین (رتین) تا ژوراسیک میانی گزارش شده است. ماسه سنگ‌های سازند لالون و سازند شمشک پی سنگ بسیاری از سازه‌های عمرانی شمال استان تهران را در بر می‌گیرند و از این جهت بررسی خصوصیات مهندسی آن‌ها حائز اهمیت می‌باشد.

## ۲. موقعیت جغرافیایی و زمین‌شناسی

به منظور انجام این مطالعه، ۱۴ بلوک سنگی از شمال غرب شهر دماوند و ۶ بلوک از ساختگاه سد سیاه بیشه تهیه شد و به آزمایشگاه منتقل و برای انجام آزمایش‌های آزمایشگاهی آماده گردیدند. موقعیت ساختگاه‌ها در شکل ۱ ارائه شده است. ماسه سنگ‌های مورد مطالعه از سازند لالون در شمال غرب شهر دماوند و سازند شمشک در ساختگاه سد سیاه بیشه نمونه برداری شدند. سازند لالون از سازندهای زمین شناسی ایران در البرز با سن کامبرین پیشین است. سازند



شکل ۱- موقعیت ساختگاه‌های مورد مطالعه (بالا) و مختصات بلوک‌های برداشت شده از شهر دماوند (پایین)

### ۳. مواد و روش‌ها

#### ۳-۱. مواد مورد استفاده

نمونه‌های استوانه‌ای با استفاده از دستگاه مغزه‌گیر تهیه و برای برش و ساب دو سر نمونه‌ها از دستگاه برش اره‌ای و ماشین ساب استفاده گردید. در تهیه و آماده سازی نمونه‌های مورد نیاز این تحقیق از روش‌های پیشنهادی انجمن بین‌المللی مکانیک سنگ استفاده شده است (ISRM 1981). قطر نمونه-های استوانه‌ای تهیه شده 54mm و نسبت طول به قطر آنها حدود ۲,۵ می‌باشد. از میان نمونه‌های جمع آوری شده، نمونه‌هایی با درزه و ترک از تجزیه و تحلیل حذف شدند.

زیرا رفتار ناهمسانگرد نمونه‌های دارای درزه، ترک‌ها و ناپیوستگی‌ها باعث تمرکز تنش در نقاط ضعیف و ایجاد خطا در خواص مکانیکی اندازه‌گیری شده می‌شود. سنگ‌های ناهمسانگرد دارای خواص مکانیکی متفاوتی در جهات مختلف می‌باشند که باید در طراحی سازه‌ها مورد توجه قرار گیرد (Lotfollahi et al., 2018; Naseri et al., 2017). بیشتر سنگ‌های دگرگونی (مانند شیست) ساختار ورقه‌ای دارند و ناهمسانی قابل توجهی در رفتار مکانیکی آن‌ها مشاهده می‌شود (Behnamnia and Barati 2019; Oshnavieh and

راستای قرارگیری چکش دارد. طبق پیشنهاد ISRM بهتر است که چکش در یکی از سه وضعیت قائم به سمت بالا، افقی و یا قائم به سمت پایین قرار بگیرد. در هر حالت مقدار انحراف چکش نباید بیشتر از مثبت و منفی ۵ درجه باشد (ISRM, 1981).

آزمایش مقاومت تراکم تک محوری بر اساس روش‌های پیشنهادی انجمن بین‌المللی مکانیک سنگ و با نرخ ثابت بارگذاری بر روی نمونه‌ها انجام شد (ISRM 1981). نرخ بارگذاری (۰,۷ مگاپاسکال بر ثانیه) باید در محدود پیشنهاد شده توسط روش پیشنهادی ISRM باشد. نرخ بارگذاری پیشنهاد شده توسط ISRM بین ۰,۵ تا ۱ مگاپاسکال بر ثانیه می‌باشد.

آزمایش شاخص بار نقطه‌ای بر روی نمونه‌های استوانه‌ای و همچنین نمونه‌های بی‌شکل مطابق استاندارد ASTM D5731 انجام شد (ASTM, 2002). سپس شاخص بار نقطه‌ای برای برای قطر ۵۰ میلیمتر (PLV) اصلاح شد. دانسیته (γ) و تخلخل (P) نمونه‌ها نیز بر اساس روش‌های پیشنهادی انجمن بین‌المللی مکانیک سنگ انجام شد. تخلخل نمونه‌ها به روش اشباع و غوطه‌وری تعیین شد. برای تعیین نوع ماسه سنگ‌ها، مقاطع نازک تهیه شد و نامگذاری نمونه‌ها نیز به روش فولک انجام شد (Folk (1974)). تصاویری از عملیات آزمایشگاهی در شکل‌های ۲ و ۳ ارائه شده است.

Bagherzadeh Khalkhali (2019). شکل ۲ تصاویری از

بلوک‌ها را نشان می‌دهد.

۲-۳. آزمایش‌های آزمایشگاهی

آزمایش‌های فیزیکی، مکانیکی و دینامیکی بر روی ۵۸ نمونه در شرایط خشک و ۱۸ نمونه در شرایط اشباع انجام شد. آزمایش سرعت موج تراکمی (Vp) مطابق استاندارد ASTM D2845 انجام شد (ASTM D2845 1983). سرعت امواج بستگی به مقاومت سنگ یا به طور کلی کیفیت سنگ دارد. قبل از انجام آزمایش سر و ته نمونه‌ها با استفاده از گریس صیقلی شد. فرکانس مورد استفاده در این آزمایش‌ها ۰,۵ MHz می‌باشد.

در مطالعه حاضر، قبل از آزمایش UCS سختی نمونه‌ها با استفاده از چکش اشمیت (نوع N) برای آزمایش چکش اشمیت استفاده شد. این آزمایش در آزمایشگاه روی ۷۶ نمونه انجام شد و میانگین ۱۰ قرائت در یک محدوده برای هر نمونه محاسبه شد. در این تحقیق از چکش اشمیت به صورت عمودی برای تمامی نمونه‌ها استفاده شد. در مکانیک سنگ کاربرد اصلی چکش اشمیت (علاوه بر اندازه‌گیری سختی بازگشتی سنگ‌ها) محاسبه مقادیر مقاومت فشاری و مدول الاستیسیته سنگ است که از طریق نمودارها و روابط تجربی قابل محاسبه است (Bolla and Paronuzzi 2021; Selçuk and Yabalak 2015). مقدار سختی به دست آمده بستگی به



ت) نمونه ۱۴-قبل از  
آزمایش UCS  
t) Sample 14-  
before UCS test



د) نمونه ۱۴-بعد از  
آزمایش UCS  
d) Sample 14-after  
UCS test



ج) نمونه ۱-قبل از  
آزمایش UCS  
c) Sample 1 - before  
the UCS test




ب) نمونه ۱ - بعد از آزمایش  
UCS  
b) Sample 1 - after UCS  
test



الف) تصویری از بلوک‌ها در صحرا  
A) A picture of blocks in the  
desert

شکل ۲. تصاویری از بلوک‌ها و نمونه‌ها قبل و بعد از آزمایش مقاومت فشاری تک محوری



شکل ۲. مقاطع نازک از نمونه‌ها (سمت راست: نمونه خشک از ساختگاه سد سیاه بیشه و سمت چپ: نمونه خشک از شهر دماوند)، (Q: کوارتز، Op: کانی‌های تیره، CR: خرده‌های کربناته و F: فلدسپات)

تعداد متغیر انتخاب شده در هر گره و تعداد درخت می‌باشند که لازم است برای آن‌ها مقادیر مناسبی تعیین گردد (Harris and Grunsky, 2015). در این روش در هر بار نمونه‌گیری با جایگزینی اطلاعات، برخی اطلاعات هرگز نمونه‌گیری نمی‌شوند و برخی دیگر شاید چند بار نمونه‌گیری شوند. به عبارتی دیگر برخی داده‌های ورودی برای برخی درخت‌ها در اصطلاح نمونه خارج از کیسه خواهند بود یعنی در ایجاد برخی درخت‌ها مشارکت نخواهند داشت. این داده‌ها عمل یک اعتبارسنج داخلی برای هر درخت را دارند که این اعتبارسنجی از طریق برآورد خطای خارج از کیسه انجام می‌شود. اگر خود داده‌های خارج از کیسه از طریق درختان پیش‌بینی شوند، برای این پیش‌بینی‌ها خطا وجود خواهد داشت و میانگین این خطاها، خطای خارج از کیسه نامیده می‌شود که نشان دهنده میزان تأثیر نمونه‌های انتخاب نشده بر میزان خطای نتیجه نهایی جنگل تصادفی است (James et al., 2013). شکل ۴ شماتیکی از ایده الگوریتم جنگل تصادفی را نشان می‌دهد.

۳-۴. K نزدیکترین همسایه

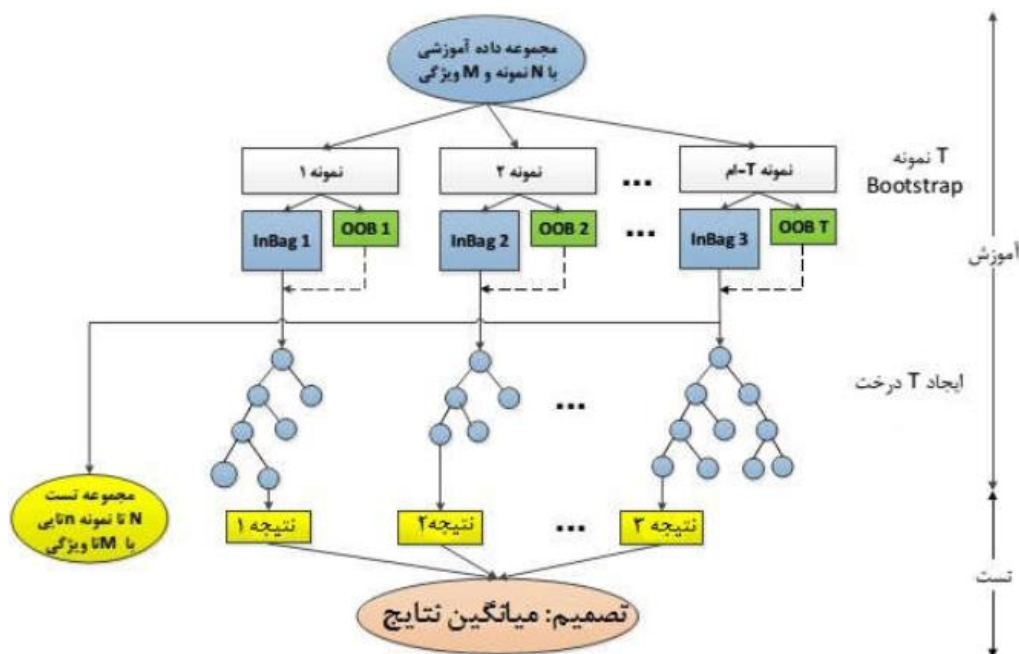
الگوریتم KNN مبتنی بر نمونه است و بر اساس K همسایه نزدیک، طبقه‌بندی را انجام می‌دهد. این روش بر اساس شباهت داده‌ها طبقه‌بندی را انجام می‌دهد. در واقع

۳-۳. الگوریتم جنگل تصادفی

روش جنگل تصادفی از جمله روش‌های گروهی (Ensemble Methods) می‌باشد. در روش‌های گروهی مدلی که برای دسته‌بندی یا رگرسیون انتخاب می‌شود، ترکیبی از چندین مدل است. هر مدل رأی خود را صادر می‌کند و نتیجه نهایی در مورد مقدار بر اساس این رأی‌ها صادر می‌شود. اغلب صحت یک روش گروهی بهتر از مؤلفه‌های تشکیل دهنده آن یعنی مدل‌ها است. این روش در مکانیک سنگ نیز بطور گسترده مورد استفاده قرار گرفته است (McElroy et al., 2021; Wang et al., 2020; Wang et al., 2023; Matin et al., 2018). تصور کنید مدل‌های استفاده شده در روش گروهی همگی از نوع درخت تصمیم هستند، بدین ترتیب این مجموعه تشکیل یک جنگل را خواهد داد. هر یک از درختان تصمیم با استفاده از یک انتخاب تصادفی صفات خاصی موجود در هر گره جهت تعیین انشعاب ساخته می‌شوند. به عبارت دیگر هر درخت بر اساس مقادیر یک بردار تصادفی ساخته می‌شود. این مقادیر دارای توزیع یکسانی برای تمام درختان موجود در جنگل هستند و به صورت مستقلی نمونه‌گیری می‌شوند. برای دسته‌بندی نیز هر درخت رأی خود را صادر و نتیجه نهایی با رأی اکثریت تعیین می‌شود (Liaw and Wiener 2002). پارامترهای مهم در الگوریتم جنگل تصادفی،

های برچسب دار؛ بنابراین اضافه کردن یا حذف هر گونه نمونه به نمونه‌های آموزشی، بر تصمیم نهایی طبقه بندی کننده، KNN تأثیر می‌گذارد و (۳) معیار فاصله. در، KNN از فاصله اقلیدسی معمولاً به عنوان معیار فاصله برای اندازه گیری فاصله بین دو نمونه استفاده می‌شود. طبقه بندی کننده KNN به صورت تحلیلی قابل ردیابی است و به سادگی پیاده سازی می‌شود، اما یکی از مشکلات اصلی الگوریتم KNN این است که به همه نمونه‌های آموزشی نیاز دارد که در زمان اجرا در حافظه باشند؛ به همین دلیل، طبقه بندی مبتنی بر حافظه نامیده می‌شود (Duda et al., 2012; Tharwat et al., 2013). این الگوریتم نیز همانند سایر الگوریتم استفاده شده در تحقیق حاضر، پس از فراخوانی داده‌ها در محیط برنامه، داده‌ها را به دو بخش داده‌های آموزشی و داده‌های تست تقسیم نموده و مدل - K نزدیکترین همسایه را ساخته و داده‌های آموزشی را وارد مدل کرده تا مدل آموزش ببیند. در ادامه برای مشخص نمودن دقت مدل، داده‌های تست را وارد مدل کرده تا پیش‌بینی کند و در مقایسه با برچسب‌های داده‌های تست دقت پیش‌بینی را ارزیابی نماید.

برای هر داده‌ی آزمایشی جدید، فواصل K همسایه نزدیک را محاسبه کرده و برچسبی مشابه برچسب غالب این K همسایه برای نقطه مورد نظر را تعیین می‌کند (Aghighi et al., 2017). طبقه بندی کننده K-نزدیکترین همسایه، یکی از الگوریتم‌های طبقه بندی شناخته شده و ساده می‌باشد. این اولین بار به عنوان یک الگوریتم ناپارامتری معرفی شد که هیچ فرضی بر توزیع داده‌های ورودی ایجاد نمی‌کند؛ بنابراین به طور گسترده در کاربردهای مختلف استفاده می‌شود (Duda et al., 2012). در طبقه بندی کننده KNN، یک نمونه ناشناخته براساس شباهت بین نمونه‌های شناخته شده آموزش دیده یا برچسب‌دار بر مبنای محاسبه فاصله بین نمونه‌های ناشناس با نمونه‌های برچسب‌دار، شناخته می‌شود. سپس K نزدیکترین نمونه‌ها به عنوان پایه برای طبقه بندی انتخاب می‌شوند و نمونه نامشخص (Xtest) به کلاسی اختصاص می‌یابد که بیشترین نمونه‌ها را در میان نزدیکترین نمونه‌ها دارد. به همین منظور، الگوریتم طبقه بندی کننده KNN بستگی دارد به: (۱) تعداد k همسایه عدد صحیح و تغییر مقدار پارامتر k که ممکن است نتایج طبقه بندی را تغییر دهد. (۲) مجموعه داده-



شکل ۴- ایده الگوریتم جنگل تصادفی (اقتباس از جیمز و همکاران (۲۰۱۳))

## ۳-۵. سیستم استنتاج فازی عصبی-تطبیقی

خصوصیات یادگیری شبکه‌های عصبی را با هم ترکیب می‌کنند. سیستم‌های Neuro-Fuzzy مختلفی توسعه پیدا کرده‌اند که در مقالات با نام‌های مخفف معرفی می‌شوند. ANFIS که به وسیله جانگ (Jang, 1993) توسعه پیدا کرده، یکی از سیستم‌های Neuro-Fuzzy می‌باشد که اجازه می‌دهد سیستم‌های فازی با یک الگوریتم پس انتشار، پارامترها را یاد بگیرند. سه نوع از سیستم‌های استنتاجی فازی مانند مدل‌های فازی Mamdani, Sugeno, Tsukamoto به طور گسترده در کاربردهای مختلف بکار گرفته می‌شوند. تفاوت این سه روش در نتیجه قواعد فازی است که بکار گرفته شده‌اند. در این مطالعه سیستم استنتاج فازی نوع Sugeno استفاده شده که هر قاعده به عنوان ترکیب خطی از متغیرهای ورودی تعریف شده است. خروجی نهایی از سیستم استنتاج فازی، ساده شده‌ای از متوسط وزن داده شده هر قاعده خروجی می‌باشد. یک سیستم استنتاج فازی Sugeno ترکیبی از دو متغیر ورودی  $x, y$  می‌باشد برای مثال یک متغیر خروجی  $f$  به دو قاعده فازی سوق داده می‌شود:

$$\begin{aligned} \text{Rule 1: If } x \text{ is } A_1, y \text{ is } B_1 \text{ then } f_1 &= p_1x + q_1y + r_1 \\ \text{Rule 2: If } x \text{ is } A_2, y \text{ is } B_2 \text{ then } f_2 &= p_2x + q_2y + r_2 \end{aligned} \quad (28)$$

خلاصه کار با سیستم ANFIS به این صورت است که ابتدا ورودی و خروجی‌ها به سیستم معرفی شده و سیستم مرحله یادگیری را انجام می‌دهد. سپس برای معتبر سازی مدل، آزمایش سیستم انجام می‌شود. در این مطالعه تلاش گردید تا با استفاده از سیستم ANFIS به عنوان ترکیبی از منطق فازی با شبکه‌های عصبی، برای یافتن ارتباطی منطقی میان مقاومت فشاری تک محوری با ویژگی‌های فیزیکی، شاخص بار نقطه‌ای، سرعت موج تراکمی و سختی سنگ‌های رسوبی اقدام شود. قبل از مدل کردن، نتایج آزمایشگاهی به دو دسته آموزشی و آزمایشی به ترتیب با نسبت ۷۵٪ و ۲۵٪ داده‌های مبنای، برای جلوگیری از پیوندهای اضافی تقسیم شدند.

برای آموزش مدل در انفیس از روش ترکیبی (ترکیب انتشار بازگشتی خطا با کمترین مربعات) استفاده شد. در شکل ۵

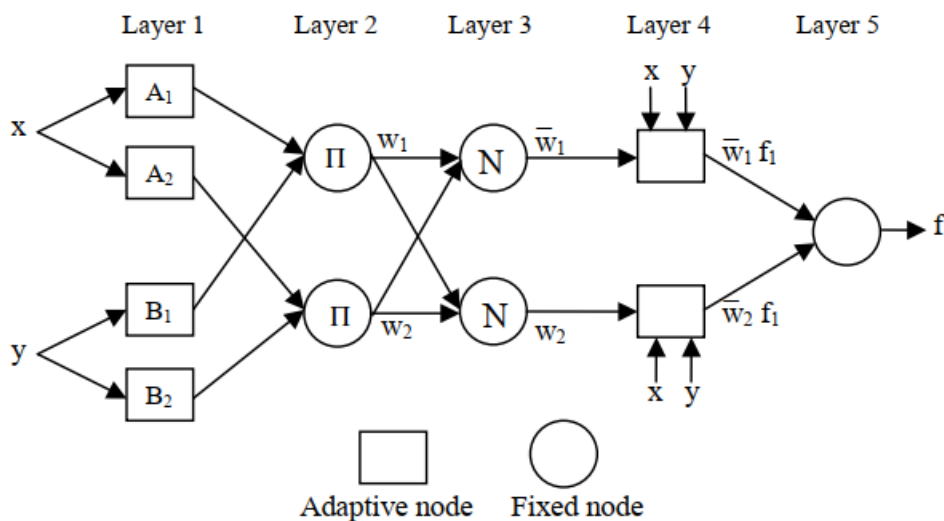
سیستم استنتاج فازی (ANFIS) ترکیبی از منطق فازی و شبکه‌های عصبی است که برای مدل کردن مسائل پیچیده‌ای که ارتباط بین متغیرهای مدل ناشناخته می‌باشد، بسیار مناسب است. در منطق کلاسیک، ارزش تابع عضویت هر عضو اگر در مجموعه باشد برابر ۱ و اگر نباشد برابر ۰ می‌باشد. در مقابل، هر عضو مجموعه فازی می‌تواند ارزش تابع عضویت بین ۰ تا ۱ داشته باشد. اصطلاح مجموعه فازی تحت عنوان تئوری مجموعه فازی توسط، لطفی زاده معرفی شد (Hudaverdi, 2022; Yesiloglu-Gultekin and Gokceoglu, 2022). بر اساس قوانین ریاضی، این مطلب عموماً به صورت رابطه ۲۷ معرفی می‌شود.

$$A = \{x, \mu_A(x)\} | x \in X \quad (27)$$

فرمول ۲۷ نشان می‌دهد که مجموعه فازی  $A$  شامل جفت‌های مرتب  $x$  و مقدار تابع عضویت  $\mu_A(x)$  برای هر  $x$  از مجموعه  $X$  است. درجه تابع عضویت، مقدار سطح وابستگی عضو به مجموعه فازی را نشان می‌دهد. بعد از مطالعات لطفی زاده بعضی از سیستم‌های استنتاج فازی ارائه شد. در مقالات بین المللی دو نوع مختلف از سیستم فازی بطور متداول استفاده می‌شوند که شامل الگوریتم‌های Mamdani و Sugeno می‌باشد (Hudaverdi, 2022). سیستم‌های استنتاج فازی می‌توانند در قالب سیستم‌های قواعد مبنای، معرفی شوند که از یک مجموعه با قواعد زبانشناختی ساخته شده و قادر هستند هر سیستمی را با دقت بالا نمایش دهند که شبیه تقریب زن‌های همه منظوره کار می‌کنند. سیستم‌های قواعد مبنای تئوری منطق فازی از متغیرهای زبانشناختی استفاده می‌کنند مثل نتایج و قواعد، جایی که قواعد بصورت استنتاج یا نامعادله بیان می‌شوند. سیستم قواعد مبنای فازی در حقیقت یک سیستم قاعده مبنای if-then می‌باشد که با قاعده if و نتیجه then معلوم می‌شود. سیستم‌های فازی می‌توانند با شبکه‌های عصبی برای تشکیل سیستم‌های Neuro-Fuzzy ترکیب شوند که قابلیت‌های هر دو روش را نشان می‌دهند. سیستم‌های Neuro-Fuzzy زبان طبیعی توصیف سیستم‌های Fuzzy و

نشانهگر بخش مقدم قوانین فازی، لایه چهارم شامل بخش تالی قوانین فازی و لایه پنجم نشان دهنده مرحله فازی زدایی است.

ساختار کلی روش انفیس نشان داده شده است. همانطور که مشاهده می‌شود، انفیس از یک شبکه عصبی پنج لایه تشکیل شده است که لایه اول شامل ورودی‌ها، لایه دوم شامل ترم های کلامی ورودی‌ها یا به عبارتی توابع عضویت، لایه سوم



شکل ۵. ساختار کلی روش انفیس.

در روابط ۲۹ تا ۳۱، مقدار UCS اندازه گیری شده است، مقدار UCS تخمین زده شده، و n تعداد کل داده‌ها است. داده‌ها نیز بر اساس رابطه ۳۳ بین ۱- و ۱ نرمال سازی شدند. زمانی که مقادیر خطای مدل ها صفر باشد و شاخص عملکرد برابر با ۲ باشد و مقادیر ضریب همبستگی و VAF برابر با ۱۰۰ درصد باشد، کارایی مدل‌ها حداکثر می‌باشد.

$$X_i = 2 \left( \frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) - 1 \quad (33)$$

در این رابطه X مقدار اندازه گیری می‌شود، Xmin حداقل داده و Xmax حداکثر داده است.

#### ۴. نتایج و بحث

در این بخش، پس از ارائه و مقایسه نتایج آزمایش‌های آزمایشگاهی با استانداردهای موجود در ساختگاه‌های مورد مطالعه، برخی روابط و مدل‌های تجربی برای تخمین مقاومت فشاری ارائه می‌شود.

#### ۳-۶. ارزیابی عملکرد مدل‌ها

برای ارزیابی مدل‌ها از ضریب همبستگی، میانگین درصد مطلق خطا (MAPE) (رابطه ۲۹)، ریشه میانگین مربعات خطا (RMSE) (رابطه ۳۰)، واریانس محاسبه شده (VAF) (رابطه ۳۱)، و شاخص عملکرد (PI) (رابطه ۳۲) استفاده شد. همچنین از آزمون کروسکال والیس برای بررسی معنی داری اختلاف مقدار UCS اندازه گیری شده و UCS تخمین زده شده توسط روش‌ها استفاده شد. این معیارها بطور گسترده توسط محققین جهت ارزیابی مدل‌ها استفاده شده‌اند (Zhang et al., 2023).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y - y'}{y} \right| * 100 \quad (29)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - y')^2} \quad (30)$$

$$VAF = 100 \left[ 1 - \frac{\text{var}(y - y')}{\text{var}(y)} \right] \quad (31)$$

$$PI = R^2 + (VAF/100) - RMSE \quad (32)$$

پتروگرافی باعث تغییر در مقاومت فشاری نمونه‌ها می‌شود (Lerman et al., 2021; Ghavami and Rajabi, 2021; Etemadi et al., 2020). با افزایش مقدار کانی‌های رسی، مقاومت نمونه‌ها کاهش می‌یابد (Abbasi Dezfouli, 2021). همچنین رطوبت نمونه‌ها تاثیر ویژه‌ای بر مقاومت نمونه‌های حاوی کانی‌های رسی دارد (Taheri and Ziad, 2021). در نمونه‌های ماسه‌سنگ تحقیق حاضر، رس و گچ یافت شد. سیمان نمونه‌ها گچ و کلسیت می‌باشد. دانه‌های این ماسه سنگ‌ها نیمه گرد تا زاویه دار هستند و درجه بندی متوسط تا ضعیف دارند. بررسی مقاطع نازک نمونه‌ها نشان داد که نمونه‌هایی با میزان رس بالاتر، ویژگی‌های مقاومت کمتری را نشان می‌دهند. ماسه سنگ‌ها به دلیل تنوع در ترکیب سنگ شناسی از خصوصیات فیزیکی و مکانیکی بسیار متغیری برخوردار هستند (Ghobadi and Mousavi, 2014). میزان تخلخل، مقدار و نوع سیمان و نیز ترکیب و بافت ذرات تشکیل دهنده مقاومت این سنگ‌ها را تحت تاثیر قرار می‌دهند. به طوریکه ماسه سنگ‌های با سیمان شدگی بیشتر و تخلخل کمتر مقاومت بالاتری دارند (عبدی و خانلری ۲۰۱۹) به همین دلیل آگاهی از خصوصیات مقاومت و تغییرشکل آن‌ها به هنگام احداث سازه‌های عمرانی به پیش بینی رفتار مهندسی این سنگ‌ها کمک خواهد کرد.

یکی از روش‌های غیر مستقیم برآورد خواص مهندسی، استفاده از روابط تجربی و مدل‌های هوشمند است (Zheng et al., 2023; Xu et al., 2023; Wani et al., 2023; Saghi et al., 2019). در سال‌های اخیر ارائه مدل‌ها و روابط برای برآورد خواص سنگ بر اساس نتایج آزمایش‌های آزمایشگاهی، توجه محققان را به خود جلب کرده است (حیدری و همکاران ۲۰۱۲). مزایای روش‌های غیرمستقیم این است که در مراحل اولیه بررسی محل پروژه‌ها، می‌توان خواص مکانیکی سنگ‌ها را بر اساس آزمایش‌های ارزان قیمت به دست آورد. این روش‌ها زمانی اهمیت بیشتری پیدا می‌کنند که سنگ‌ها ضعیف و درزدار باشند و نمونه‌برداری دشوار باشد (قبادی و همکاران ۲۰۲۱). تهیه نمونه‌های استاندارد برای آزمایش‌های مخرب (مانند آزمایش مقاومت فشاری) از این نوع سنگ‌ها مستلزم صرف هزینه و زمان زیادی است (Tofighkhan et al., 2023; Zheng et al., 2023).

#### ۱-۴- خواص ژئومکانیکی نمونه‌ها

مقادیر حداکثر، حداقل و میانگین خواص مهندسی روی ۷۶ نمونه نمونه ماسه سنگ در جداول ۲، ۳ و ۴ ارائه شده است. میانگین UCS مجموع نمونه‌ها ۶۰/۴۲ مگاپاسکال است که بر اساس طبقه بندی ISRM (۱۹۸۱)، در رده مقاومتی بالا قرار می‌گیرد (جدول ۳). ویژگی‌های فیزیکی، کانی شناسی و

جدول ۲- نتایج آزمایشگاهی بر روی مجموع نمونه‌ها در شرایط خشک و اشباع

Table 2. Laboratory results on all samples in dry and saturated conditions

Vp (km/s)	$\gamma$ (g/cm <sup>3</sup> )	PLV (MPa)	P (%)	UCS (MPa)	Rn	Statistical properties
4.62	2.64	2.57	5.61	60.42	36.07	Average
0.11	0.01	0.14	0.41	3.33	2.00	Standard error
0.94	0.12	1.20	3.57	29.05	17.39	Standard deviation
0.89	0.02	1.44	12.74	843.88	302.58	Sample variance
0.12	(0.54)	(0.66)	0.15	(0.59)	(0.95)	kurtosis
0.81	(0.26)	0.65	0.28	0.74	0.58	skewness
2.90	2.35	0.74	0.04	17.78	10.00	Min
7.14	2.84	5.00	15.00	120.00	70.00	Max

Vp: سرعت موج تراکمی،  $\gamma$ : دانسیته، PLV: مقدار شاخص بار نقطه‌ای، P: تخلخل، UCS: مقاومت فشاری تک محوری، و Rn: سختی چکش اشمیت

مقاومت نمونه‌ها در شرایط خشک و اشباع می‌شود. کانی‌های رسی با جذب آب، باعث کاهش شدید مقاومت می‌شوند. سنگ‌هایی با تخلخل زیاد هنگامی که اشباع هستند می‌توانند دامنه زیادی از سرعت امواج را نشان دهند (Török and Vásárhelyi, 2010). افزایش سرعت امواج می‌شود. و آسارهیلی ۱۴ بیان کرد که UCS ماسه سنگ‌های مناطق مختلف کشور انگلستان در شرایط اشباع حدود ۷۵/۶ درصد آن در شرایط خشک می‌باشد (Vásárhelyi, 2003).

خصوصیات نمونه‌های خشک و اشباع به تفکیک در جداول ۳ و ۴ ارائه شده است. با مقایسه میانگین مقادیر خصوصیات بررسی شده در این جدول مشاهده می‌شود که اشباع شدن نمونه‌ها باعث افزایش سرعت موج تراکمی شده است. بر عکس، مقادیر مقاومت فشاری تک محوری، سختی و شاخص بار نقطه‌ای در حالت اشباع کمتر از مقادیر این پارامترها در حالت خشک می‌باشد. کاهش مقاومت فشاری در حالت اشباع توسط دیگر محققین نیز تایید شده است (Vásárhelyi, 2003, 2005; Andriani and Walsh, 2010). لیتولوژی، تخلخل، جذب آب نمونه‌ها، نوع و مقدار کانی‌ها، نوع سیمان و مقدار آن از عواملی می‌باشند که باعث تغییر در

جدول ۳- نتایج آزمایشگاهی روی نمونه‌ها در شرایط خشک

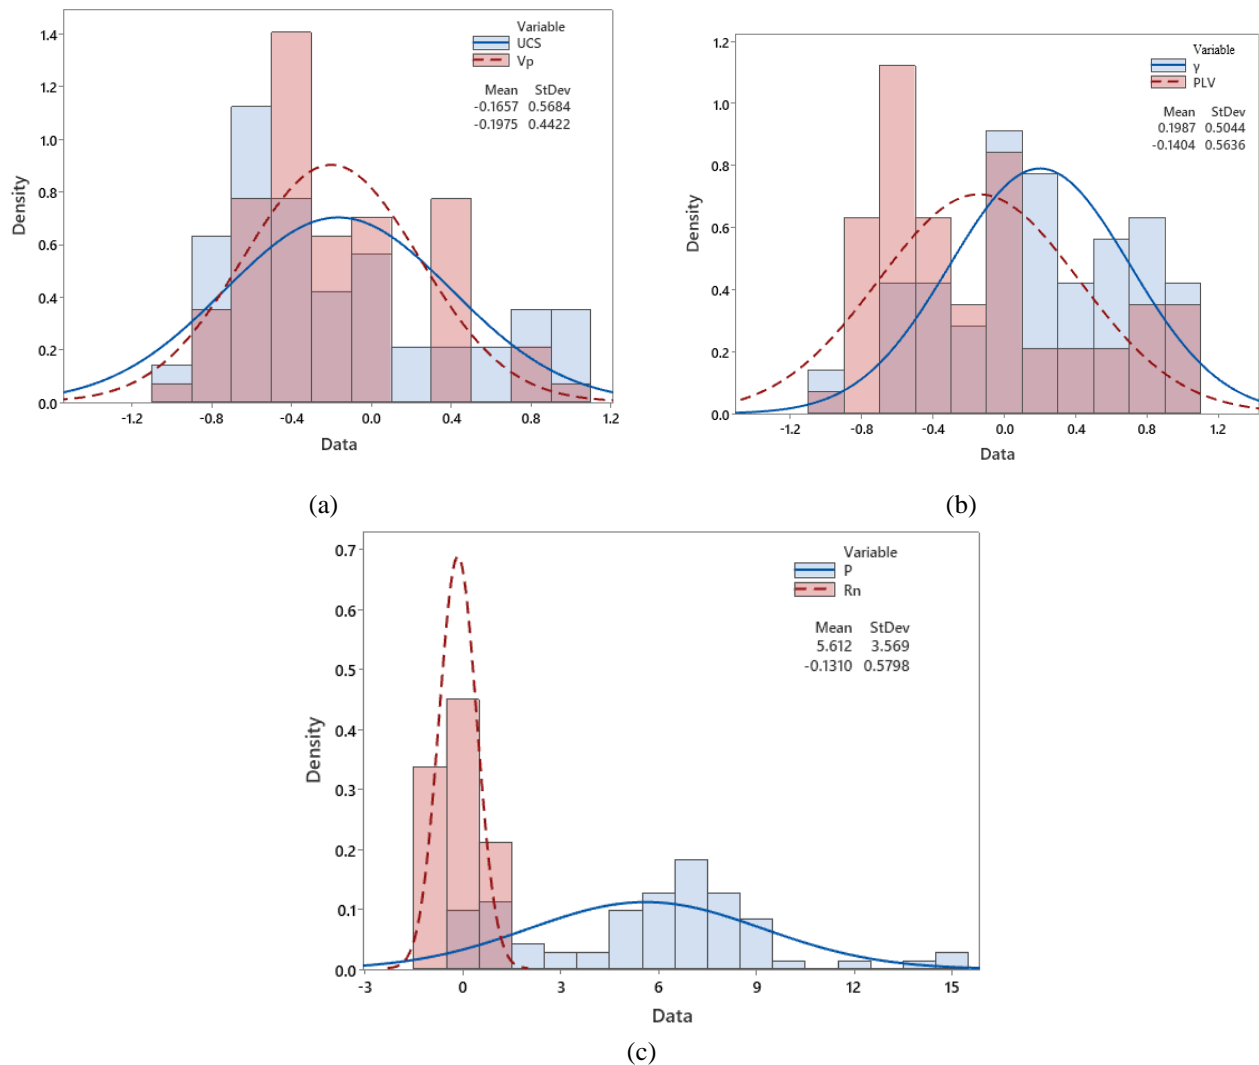
Vp (km/s)	$\gamma$ (g/cm <sup>3</sup> )	PLV (MPa)	P (%)	UCS (MPa)	Rn	Statistical properties
4.84	2.67	3.01	4.39	70.57	42	Average
0.12	0.02	0.14	0.38	3.50	2.08	Standard error
0.93	0.12	1.08	2.91	26.69	15.81	Standard deviation
0.87	0.01	1.16	8.45	712.36	249.85	Sample variance
(0.27)	(0.75)	(0.92)	(1.36)	(0.98)	(1.25)	kurtosis
0.79	(0.32)	0.55	(0.17)	0.62	0.37	skewness
3.45	2.43	1.62	0.04	38.85	18.00	Min
7.14	2.84	5.00	9.00	120.00	70.00	Max
58	58	58	58	58	58	Number of samples

جدول ۴- نتایج آزمایشگاهی روی نمونه‌ها در شرایط اشباع

Vp (km/s)	$\gamma$ (g/cm <sup>3</sup> )	PLV (MPa)	P (%)	UCS (MPa)	Rn	Statistical properties
4.96	2.56	1.29	9.20	30.54	17.83	Average
0.15	0.03	0.06	0.68	1.28	0.74	Standard error
0.63	0.11	0.24	2.89	5.41	3.15	Standard deviation
0.40	0.01	0.06	8.34	29.23	9.91	Sample variance
(0.73)	(0.17)	0.73	0.13	0.41	1.26	kurtosis
0.48	(0.51)	(0.41)	1.15	(0.79)	(1.09)	skewness
2.90	2.35	0.74	6.43	17.78	10.00	Min
5.10	2.72	1.75	15.00	37.42	22.00	Max
18	18	18	18	18	18	Number of samples

داده از بیش از ۲۵ داده (۷۶ نمونه) تشکیل شده است، با فرض توزیع نرمال می‌توان از همبستگی پیرسون استفاده کرد.

شکل ۶ هیستوگرام متغیرها را نشان می‌دهد. همانطور که مشاهده می‌شود، داده‌ها توزیع نرمال را برای تجزیه و تحلیل آماری نشان می‌دهند. علاوه بر این، با توجه به اینکه مجموعه



شکل ۶. هیستوگرام متغیرها: (a) مقاومت فشاری تک محوری و سرعت موج تراکمی؛ (b) چگالی و شاخص بار نقطه‌ای؛ (c) چگالی و عدد اشمیت

نمی‌گذارد. مطالعات متعددی روابط خطی با دقت بالا بین شاخص بار نقطه‌ای و سختی با UCS را گزارش کرده‌اند (Aliyu et al., 2019; Aladejare 2020). آزمایش شاخص بار نقطه‌ای و سختی از آزمون‌هایی می‌باشند که انجام آن‌ها سخت و پرهزینه نیست. در این مطالعه، نتایج رابطه بین این پارامترها و UCS نشان می‌دهد که شاخص بار نقطه‌ای و سختی اشمیت دقت بسیار بالایی برای تخمین UCS نشان می‌دهند (جدول ۵).

## ۲-۴- ماتریس همبستگی متغیرها

برای مطالعه تأثیر پارامترهای ژئومکانیکی بر UCS، ماتریس همبستگی (جدول ۵) مورد تجزیه و تحلیل قرار گرفت. نتایج امکان برآورد UCS بر اساس  $V_p$ ، دانسیته ( $\gamma$ )، سختی اشمیت ( $R_n$ ) و شاخص بار نقطه‌ای (PLV) را نشان داد (جدول ۵). زیرا ضرایب همبستگی بالاتر از ۰٫۷۰ دارند. در همین حال، تداخل به طور قابل توجهی بر UCS تأثیر

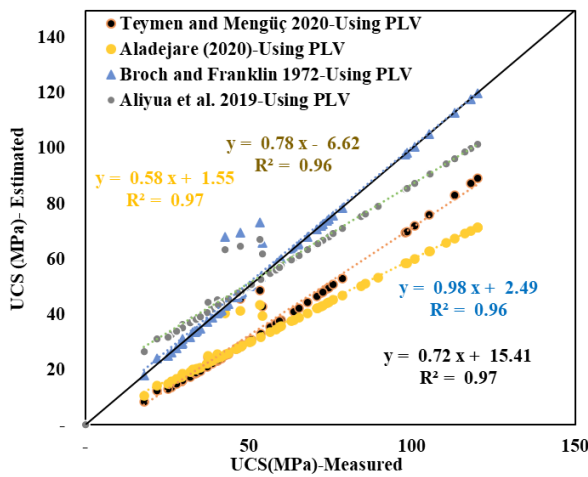
جدول ۵- ماتریس همبستگی بین متغیرها و UCS

	Vp	$\gamma$	IS50	P	UCS	Rn
Vp	1.00					
$\gamma$	0.77	1.00				
PLV	0.71	0.71	1.00			
P	(0.63)	(0.57)	(0.65)	1.00		
UCS	<b>0.72</b>	<b>0.73</b>	<b>0.99</b>	<b>(0.61)</b>	<b>1.00</b>	
Rn	0.71	0.72	0.98	(0.61)	<b>0.98</b>	1.00

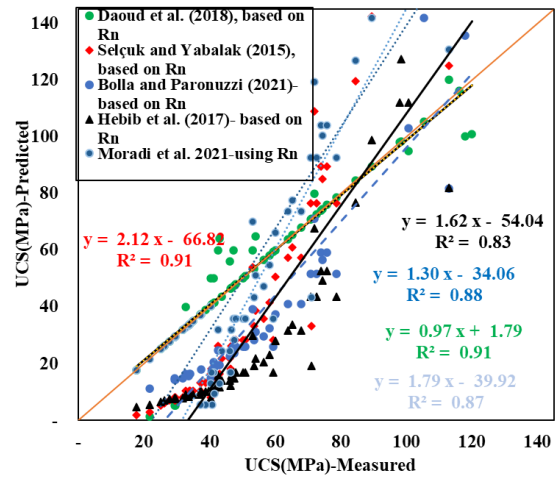
## ۳-۴- مقایسه نتایج با مطالعات بین المللی

کننده کاربرد روابط قبلی برای تخمین مقاومت سنگ‌ها در مناطق دیگر است. با افزایش نرخ بارگذاری، نمونه سریعتر می‌شکند و مقاومت بیشتری نشان می‌دهد (Yagiz et al., 2012). نرخ بارگذاری پیشنهادی توسط ISRM بین ۰,۵۰ و ۱ MPa/s است (ISRM 1981) به عنوان مثال، نرخ بارگذاری ۰,۷۰ MPa/s در این مطالعه استفاده شد.

چندین معادله تجربی برای پیش بینی UCS توسعه داده شده است (جدول ۱). در این مطالعه با استفاده از روابط محققین قبلی، UCS برای هر نمونه برآورد شد. به عبارت دیگر، برای هر یک از ۷۶ نمونه پژوهش حاضر، بر اساس هر یک از روابط تجربی جدول ۱، UCS تخمین زده شد. سپس دقت UCS برآورد شده با اندازه گیری شده مورد بررسی قرار گرفت. شکل ۷ توزیع داده‌ها و دقت روابط بر اساس  $PI^{\pm}$  و ضریب تعیین را نشان می‌دهد. مقایسه نتایج با تحقیقات بین المللی نشان می‌دهد که سازگاری مناسبی بین UCS اندازه گیری شده با UCS پیش بینی شده بر اساس مطالعات قبلی وجود دارد (شکل ۷). شاخص عملکرد (PI) توسط یاگیز و همکاران (Yagiz et al., 2012) برای ارزیابی معادلات و مدل‌های تجربی معرفی شد. مقدار این شاخص در بهترین حالت برابر با دو می‌باشد و هرچه کمتر باشد عملکرد روابط کمتر می‌باشد. چنانچه مشاهده می‌شود اگرچه ضریب تعیین روابط بالاست ولی شاخص عملکرد همه روابط ارزیابی شده بجز رابطه براش و فرانکلین (Broch and Franklin, 1972)، منفی می‌باشد که نشانگر عملکرد ضعیف روابط محققین قبلی در تخمین مقاومت سنگ‌های مورد مطالعه می‌باشد (Yagiz et al., 2012). به همین دلیل محققین مختلف تاکید کرده‌اند که روابط تجربی برای هر منطقه تعیین شود (Zhang et al., 2023; Ghafouri et al., 2018). نوع سنگ، مقدار مقاومت، روش انجام آزمایش‌ها، شرایط آزمایش (مانند میزان بارگذاری)، پتروگرافی نمونه‌های مربوط به هر مطالعه، تعیین

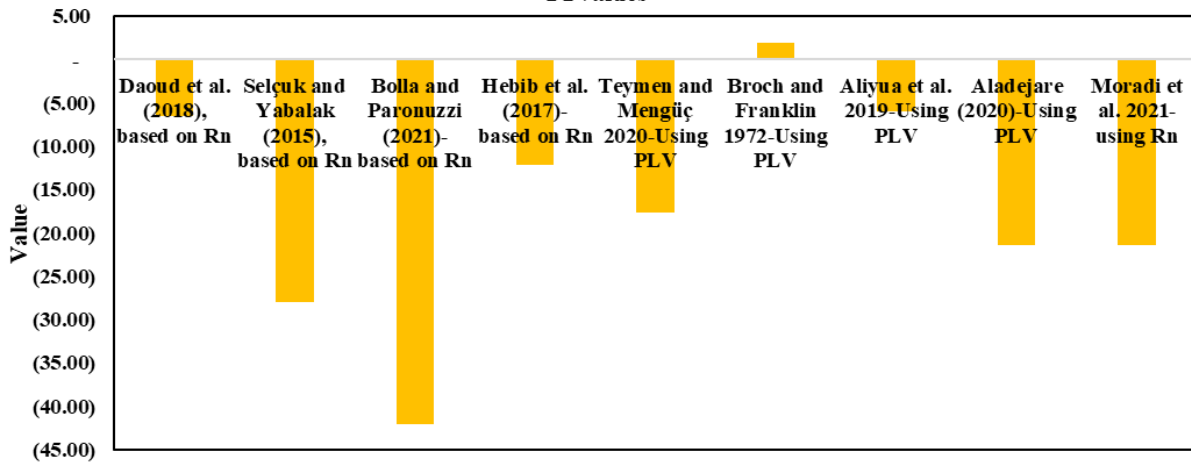


(a)

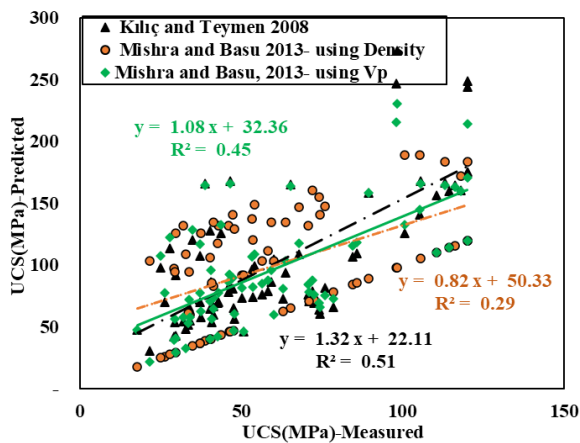


(b)

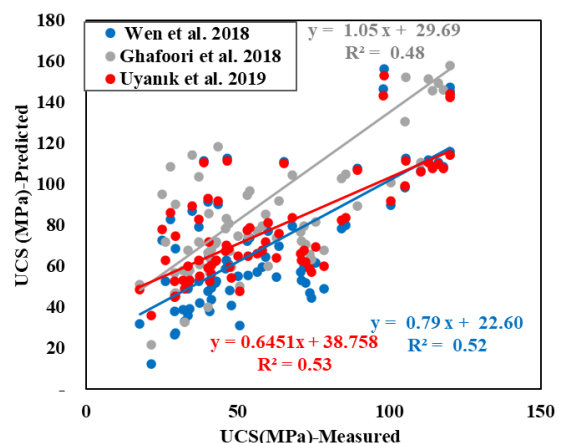
PI values



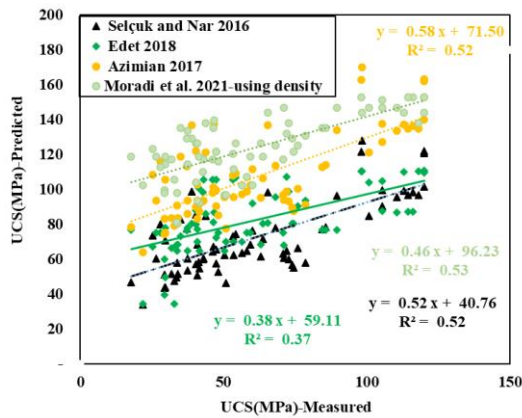
(c)



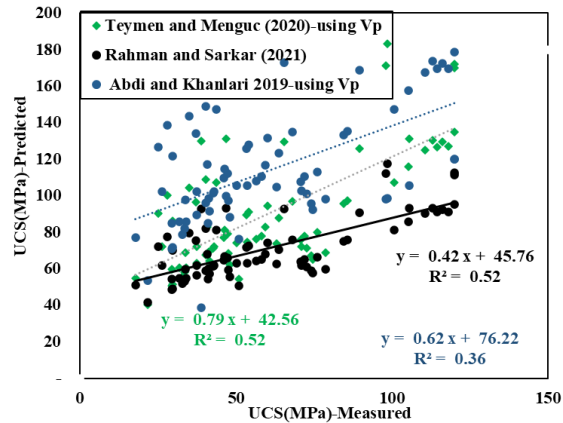
(d)




(e)



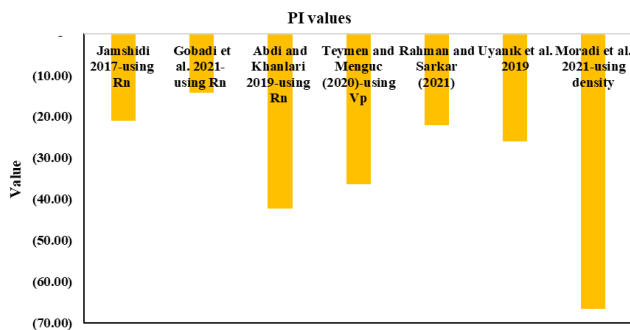
(f)



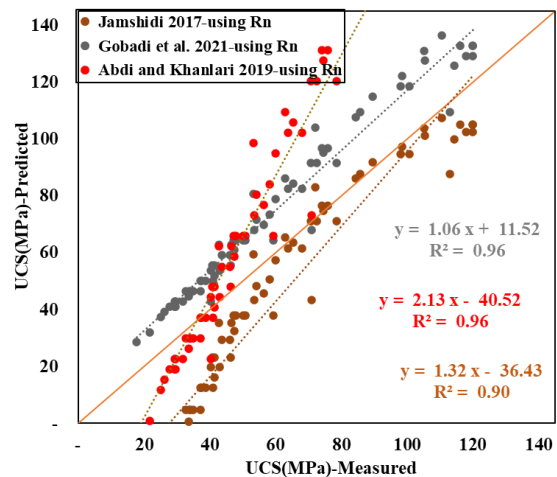
(g)



(h)



(i)



(j)

شکل ۷. رابطه بین UCS اندازه گیری شده با UCS پیش بینی شده بر اساس مطالعات قبلی به همراه شاخص عملکرد.

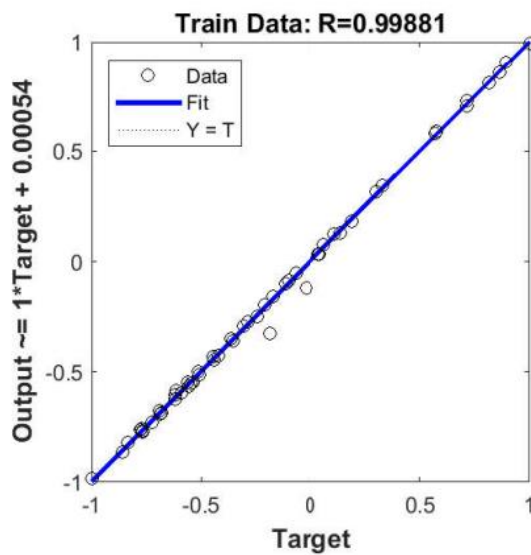
#### ۴-۴- نتایج حاصل از مدل سازی با استفاده از روش RFA

پس از آموزش، مدل توسط داده های آزمایشی مورد ارزیابی قرار گرفت و نتایج مربوط مطابق شکل ۸ به دست آمد. کلیه فرایند مدل سازی با استفاده از روش RFA با بسته نرم افزار R


انجام شد. به طور تصادفی، ۷۵ درصد نمونه ها برای آموزش مدل و ۲۵ درصد نمونه به منظور ارزیابی مدل های ساخته شده مورد استفاده

مدل، مدل توسط داده‌های آزمایشی مورد ارزیابی قرار گرفت. یکی از مزایای الگوریتم جنگل تصادفی این است می‌تواند اهمیت متغیرها را در یک مسئله مشخص کند. در این تحقیق اهمیت پارامترهای ورودی بر اساس شاخص اهمیت جینی و اهمیت جایگشتی به دست آمده است (Khan et al., 2022). شاخص بار نقطه‌ای دارای اهمیت بالاتری نسبت به سایر پارامترها می‌باشند. در شکل ۸ میزان خطا و نمودار مقادیر واقعی اندازه‌گیری شده و مقادیر پیش‌بینی شده مقاومت تراکمی توسط مدل RFA برای داده‌های کل، آزمون و آموزشی ترسیم شده است. همان‌طور که در شکل نیز به خوبی دیده می‌شود، نتایج به خط نیم‌ساز نزدیک هستند و می‌توان گفت مقادیر را با دقت بسیار بالایی پیش‌بینی کرده است. از لحاظ تئوری اگر  $R^2$  برابر ۱۰۰ درصد شود تمامی مقادیر مشاهده شده با مقادیر برازش شده یکسان خواهند بود و همه نقاط داده‌ها بر روی خط برازش شده قرار خواهند گرفت (Khan et al., 2022).

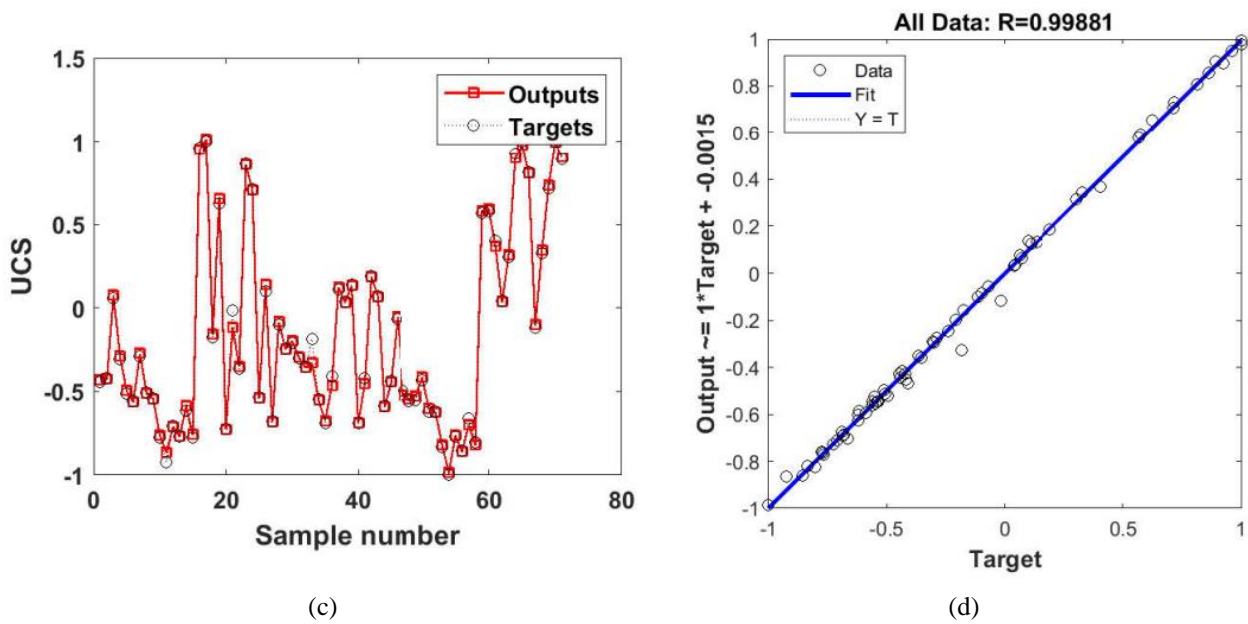
قرار گرفت. در روش RFA به منظور تعیین تعداد متغیر انتخاب شده در هر گره درخت (mtry) و همچنین تعداد درخت (ntree) از روش ۱۰-fold cross validation استفاده شده است. این روش یکی از تکنیک‌های ارزیابی مدل‌های یادگیری ماشین است که به منظور بررسی عملکرد مدل و کاهش بیش‌برازش استفاده می‌شود. در این روش، داده‌ها به ۱۰ بخش مساوی تقسیم می‌شوند. سپس، در هر تکرار (fold)، ۹ بخش به عنوان داده‌های آموزشی و ۱ بخش به عنوان داده‌های آزمایشی در نظر گرفته می‌شود. این فرآیند ۱۰ بار تکرار می‌شود تا همه بخش‌ها یک بار به عنوان داده‌های آزمایشی استفاده شوند. در نهایت، میانگین نتایج همه تکرارها به عنوان دقت نهایی مدل گزارش می‌شود. این روش به کاهش وابستگی نتایج به بخش‌بندی خاصی از داده‌ها کمک می‌کند (Kohavi, 1995). مطابق این روش تعداد ۴۸۰ درخت و ۴ متغیر در هر گره مطلوبترین شرایط برای مدل فراهم کرد. لذا این مقادیر به منظور مدلسازی استفاده شد. پس از ساخت



(a)



(b)



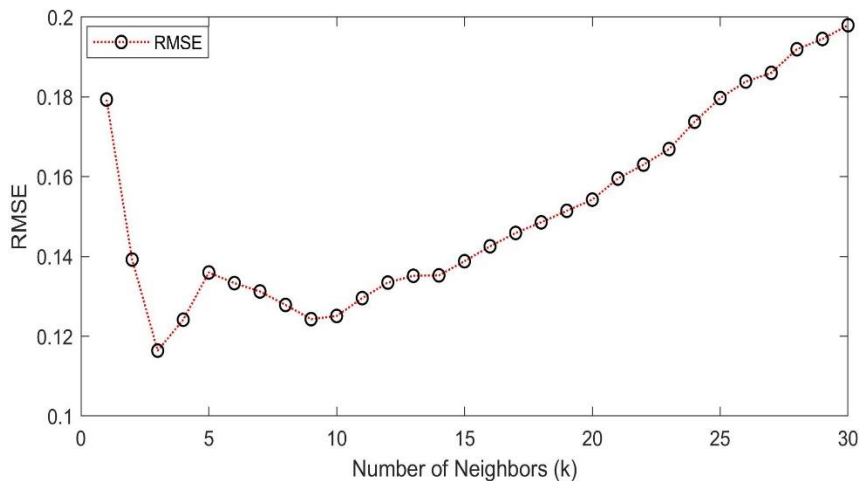
شکل ۸- دقت UCS پیش بینی شده با استفاده از RFA

Regression equation	R <sup>2</sup>	B	VAF	MAE	RMSE	Independent variables
UCS (MPa)= -9557.65+4070.5 $\gamma_d$ +0.26Vp	0.96	0.098	0.915	14.868	17.256	Specific Weight-Vp
UCS (MPa)= -13033.11+6311.7 $\gamma_d$ -38.9n	0.94	0.067	0.953	13.343	16.003	Specific Weight-Porosity
UCS (MPa)= -715.8+0.34Vp-22.9n	0.94	0.089	0.911	17.160	19.826	Vp-Porosity
UCS (MPa)= -926.1+0.13Vp+14R	0.96	0.126	0.971	25.193	27.670	Schmidt Hammer Rebound Hardness-Vp

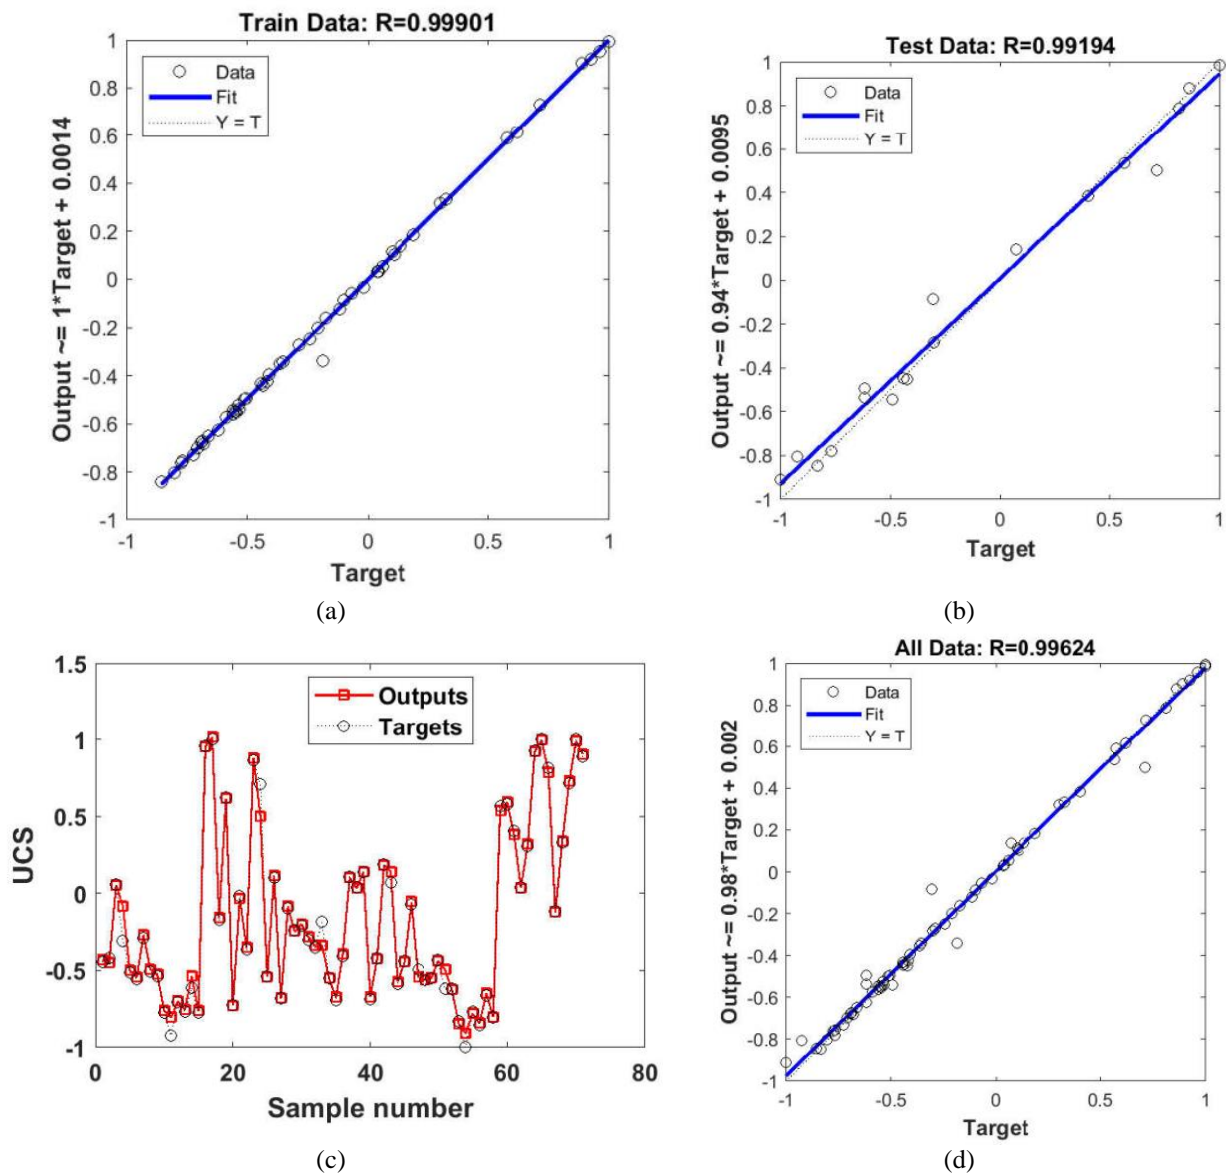
ترتیب برای آموزش و آزمون مدل استفاده شد. نتایج نشان داد که کمترین خطای برآورد UCS در K=3 به دست آمد (شکل ۹). خطای این شبکه برای تخمین UCS با توجه به مقادیر K برابر با ۰,۱۱ است (شکل ۹). شکل ۱۰ نتایج KNN را برای تخمین UCS نشان می‌دهد.

#### ۵-۴- نتایج روش KNN

به منظور اعمال روش KNN بر روی داده‌ها و همچنین تعیین بهترین مقدار K، الگوریتم KNN در قالب یک برنامه در نرم افزار متلب نوشته شد که ۳۲۰ بار برای مقادیر K از ۱ تا ۳۰ مقدار اجرا شدند و میزان خطای اندازه گیری شده در شکل ۹ ارائه شده است. به طور تصادفی، ۷۵٪ و ۲۵٪ از کل داده‌ها به



شکل ۹ - RMSE برای مقادیر مختلف K جهت تخمین UCS با استفاده از الگوریتم KNN



شکل ۱۰ - دقت UCS پیش بینی شده با استفاده از KNN

عدد می باشد و توابع عضویت داده های خروجی که در نهایت خروجی آن مقاومت فشاری تک محوره است، در شکل ۱۲ نمایش داده شده است. در لایه Inputmf ورودی‌ها از توابع عضویت (Membership functions) عبور می‌کنند. توابع عضویت هر تابع، پارامتر مناسبی می‌تواند باشد که در اکثر موارد توابع گوسی (Gaussian function) انتخاب می‌شوند. در این تحقیق نیز از تابع عضویت گوسی استفاده شد. درجه تابع عضویت مقدار سطح وابستگی عضو به مجموعه

#### ۶-۴- نتایج ANFIS جهت تخمین UCS

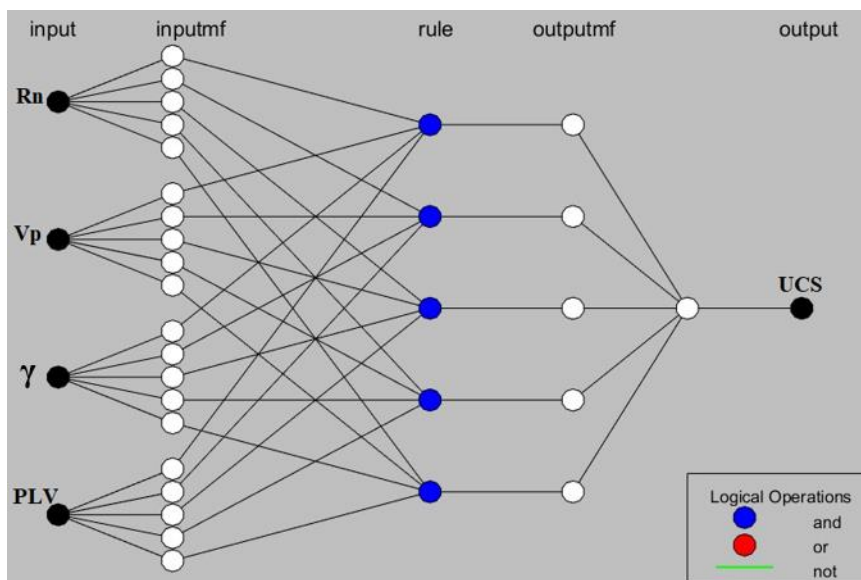
در این روش همانند سایر روش‌ها، داده‌های ورودی برای مدل کردن شامل شاخص بار نقطه‌ای، سختی اشمیت، سرعت موج تراکمی و دانسیته ۷۶ نمونه در منطقه مورد مطالعه می‌باشند و پارامتر خروجی UCS سنگ است. این مدل دارای یک ساختار معادل می‌باشد که ورودی، خروجی، قواعد مورد استفاده و نرون‌ها را نشان می‌دهد (شکل ۱۱). در این مدل توابع عضویت داده های ورودی برای هر یک از متغیرها ۴

فازی را نشان می‌دهد (Singh et al., 2017).

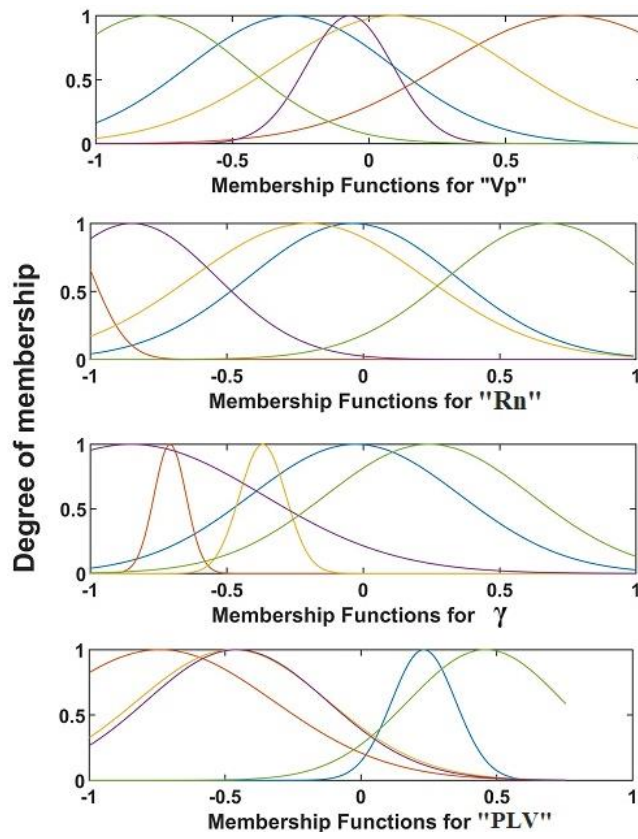
در این تحقیق مدل‌های انفیس ساخته شده بر مبنای روش سوگنو می‌باشد. برای تشکیل انفیس به شیوه خوشه بندی تفریقی از دستور GENFIS2 استفاده می‌گردد. بهترین عملکرد مدل ANFIS پس از ۵۰۰ دوره آموزش هنگامی که شعاع خوشه بندی روی ۰,۷۰ تنظیم شد، به دست آمد. پنج تابع عضویت گوسی برای متغیرهای ورودی مدل ANFIS

استخراج شد (شکل ۱۲).


مدل منجر به تشکیل ۴ قانون برای UCS شد که بهترین جواب را در بین مدل‌های انفیس با خوشه‌بندی تفریقی داشته است. شکل ۱۳ همبستگی مدل anfis\_s18 را در مراحل کل، آزمایش و آزمون نشان می‌دهد. میزان خطا برای نمونه‌ها نیز در این شکل نیز ارائه شده است.




شکل ۱۱- ساختار مدل ANFIS، تعداد ورودی، و خروجی



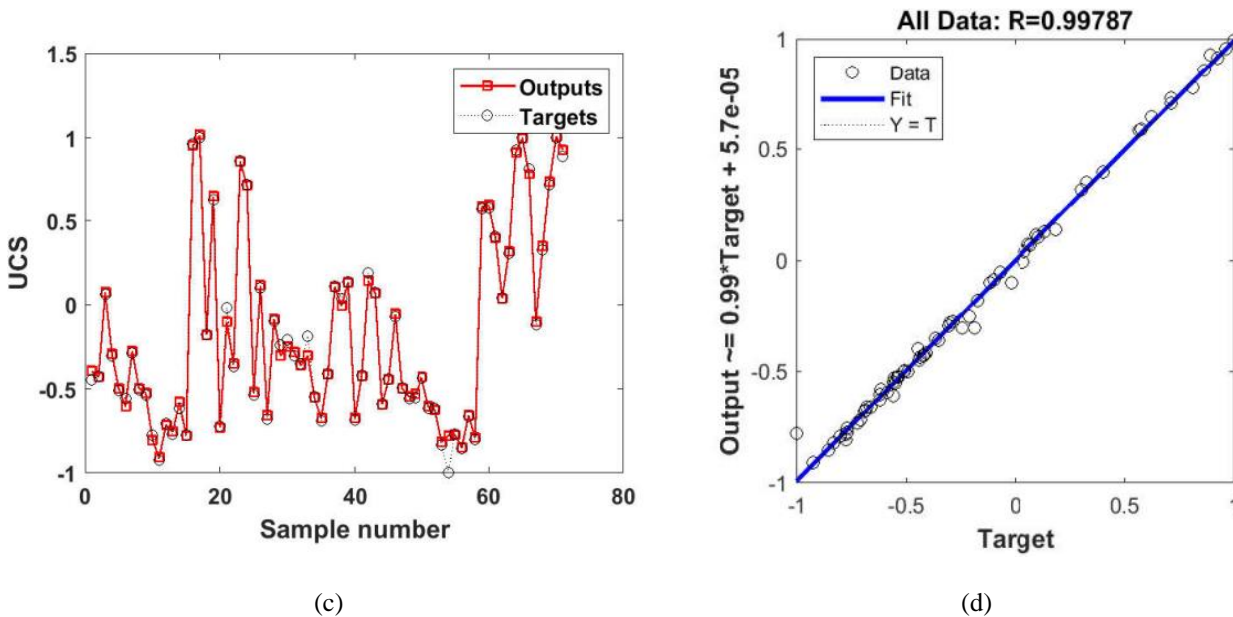
شکل ۱۲- توابع عضویت گوسی تولید شده به روش Sugeno-FIS برای متغیرهای ورودی مدل ANFIS



(a)



(b)



شکل ۱۳- همبستگی بین UCS واقعی و پیشبینی شده و میزان خطا برای هر نمونه با استفاده از مدل ANFIS

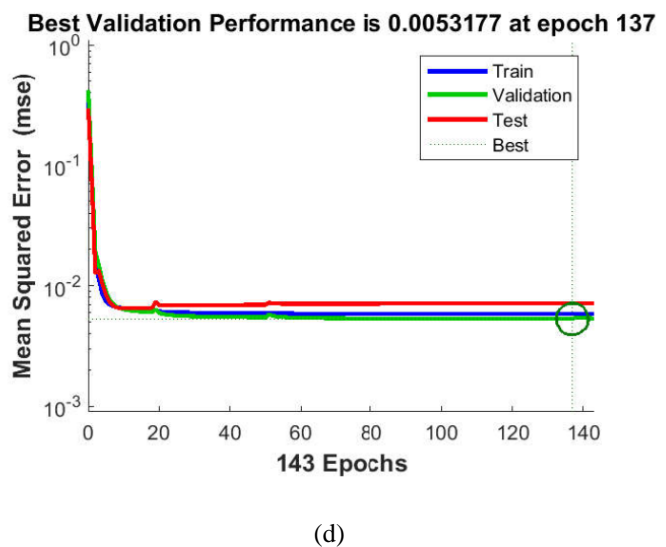



بالاترین ضریب همبستگی و کمترین خطا به عنوان مدل بهینه در نظر گرفته می‌شود (Hassanzadeh et al., 2021; Joseph and Swalih 2023). یک تابع انتقال Sigmoid بین لایه‌های ورودی و پنهان و یک تابع انتقال خطی بین لایه‌های پنهان و خروجی اعمال شد. الگوریتم لونیگ مارکواریت (LM)، برای آموزش ANN مورد استفاده قرار گرفت. نتایج بالاترین دقت را در تخمین UCS برای نورون اول با ۴ ورودی و الگوریتم آموزشی LM نشان داد (شکل ۱۴). الگوریتم LM دارای قابلیت تنظیم نرخ یادگیری تطبیقی است که استفاده از آن در حل مسائل مهندسی سودمند است (Ansari and Hashemi, 2017; Shamsashtiany and Ameri, 2018).

۷-۴- نتایج شبکه عصبی مصنوعی جهت تخمین UCS در این تحقیق، از شبکه عصبی مصنوعی از نوع پیشخور چند لایه استفاده شد. لایه ورودی بر اساس متغیرهای مستقل دارای ۴ نورون می‌باشد و لایه خروجی دارای یک خروجی واحد UCS می‌باشد. داده‌ها به طور تصادفی به دو گروه آموزش (۵۷ نمونه) و آزمایش (۱۹ نمونه) تقسیم شدند. مجموعه آموزش وزن‌های مدل را تعیین می‌کند و مجموعه آزمایش عملکرد مدل را ارزیابی می‌کند (Zhang et al., 2023). با استفاده از معادلات پیشنهادی توسط محققان مختلف (جدول ۶)، نورون‌های ۱ تا ۴ برای یافتن نورون بهینه برای پیش بینی UCS با استفاده از شبکه عصبی مصنوعی مورد بررسی و ارزیابی قرار گرفتند (جدول ۶). مدل

جدول ۶. تعداد نورون‌های به دست آمده بر اساس معادلات قبلی

محققین	Hecht-Nielsen (1987)	Hush (1989)	Ripley (1993)	Wang (1994)	Kaastra and Boyd (1996)
Relationships presented to determine the number of neurons	$2*N_o+1$	$3*N_o$	$(N_o + N_i)/2$	$(2*N_o)/3$	$\sqrt{N_o * N_i}$
The number of neurons obtained to be evaluated in the present study	3.00	3.00	2.50	0.67	2.00

No and Ni are the number of independent variables and the number of dependent variables, respectively.



شکل ۱۴- همبستگی بین UCS واقعی و پیش‌بینی شده و میزان خطا با استفاده از مدل ANN

نسبت به آزمون آنالیز واریانس، ضرایب معادله را ارزیابی می‌کند (جدول ۸). ضریب تعیین، معیاری است که نشان می‌دهد مدل چقدر تغییرپذیری را در متغیر وابسته توضیح می‌دهد، به طور قابل توجهی بالا است، بیش از ۹۸٫۱۲٪. علاوه بر این، مقادیر شاخص عملکرد (PI) معادله توسعه‌یافته ۱٫۸۷۱٫۳۲ می‌باشد که نشان‌دهنده اثربخشی مثبت آن در پیش‌بینی UCS است. نتایج نشان می‌دهد که این رابطه آماری معنی‌دار، که توسط شاخص‌های مختلف در جدول ۷ مشخص شده‌اند، می‌تواند عملاً مورد استفاده قرار گیرد. PI

۷-۴- نتایج رگرسیون چند متغیره خطی جهت تخمین UCS تجزیه و تحلیل رگرسیون چند متغیره خطی شامل استفاده از نرم افزار Minitab (نسخه ۲۰) برای توسعه معادله پیش‌بینی کننده UCS بر اساس سرعت موج تراکمی، دانسیته، سختی و شاخص بار نقطه‌ای می‌باشد (جدول ۷). تحلیل واریانس (ANOVA) دقت مدل را نیز ارزیابی می‌کند. نتایج در جداول ۸ و ۹ نشان می‌دهند که سطح معنی‌داری در آزمون تی و آنالیز واریانس زیر ۰٫۵٪ می‌باشد. این نشانگر مناسب بودن معادله برای تخمین UCS را تأیید می‌کند. آزمون تی بطور جزئی‌تر

چالش برانگیز است. برای چنین شرایط زمین‌شناسی، تهیه نمونه‌های استاندارد برای آزمایش‌های مخرب مانند آزمایش‌های UCS هم زمان‌بر و هم پرهزینه است (قبادی و همکاران ۲۰۲۱).

توزیع باقیمانده‌های مدل نیز نشان می‌دهد که مدل ارائه شده از دقت کافی برای تخمین UCS برخوردار است (شکل ۱۵).

مثبت دلالت بر قابلیت اعتماد بالای رابطه ارائه شده دارد و این روابط را برای تخمین UCS ارزشمند می‌کند (Yagiz et al., 2012). روش‌های غیرمستقیم از جمله روابط تجربی با امکان ارزیابی مقرون‌به‌صرفه خواص مکانیکی سنگ، مزایایی را در مرحله بررسی پروژه‌های عمرانی ارائه می‌کنند. این رویکرد نیاز به اجرای آزمایش‌های گران‌قیمت را دور می‌زند، به ویژه در هنگام برخورد با سنگ‌های درزدار که نمونه‌برداری

#### جدول ۷. معادله رگرسیون و معیارهای ارزیابی جهت تخمین UCS به روش رگرسیون خطی چند متغیره

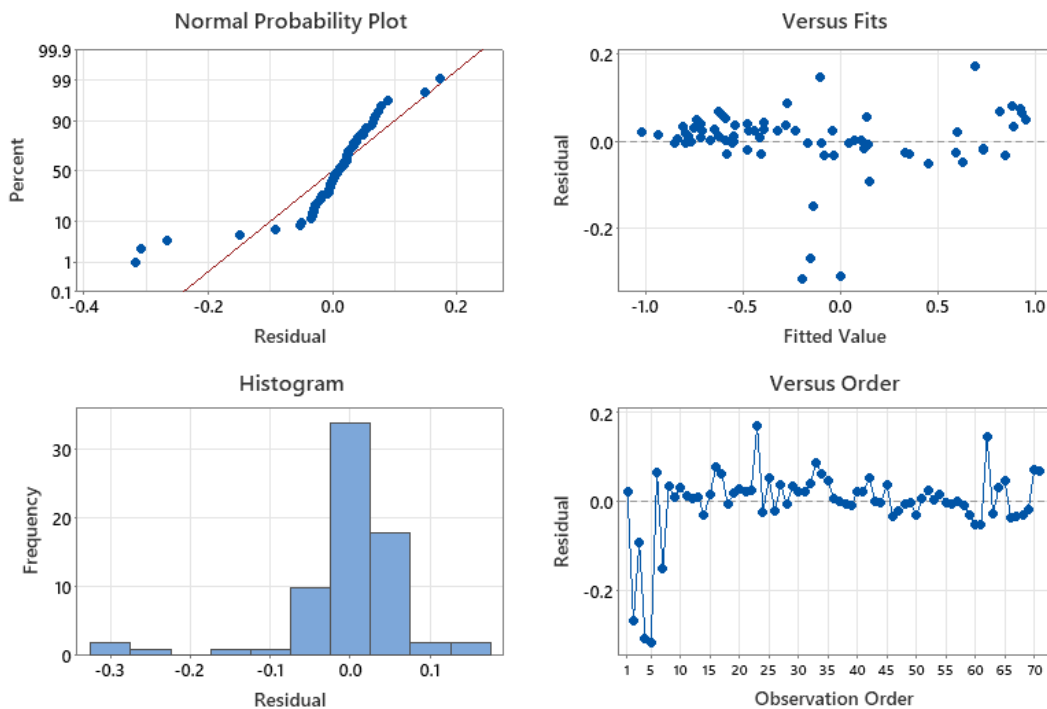
Regression equation	R-sq	RMSE	MAPE	VAF	PI
$UCS = -0.03 + 0.03V_p + 0.02\gamma + 0.59PLV + 0.40R_n$	98.12%	0.09	4.22	97.85	1.87

#### جدول ۸ ضرایب، آزمون تی جهت تخمین UCS به روش رگرسیون خطی چند متغیره

Term	Coef	SE Coef	T-Value	P-Value
Constant	-0.0310	0.0154	-2.01	0.049
Vp	0.0289	0.0350	0.83	0.012
$\gamma$	0.0165	0.0319	0.52	0.05
PLV	0.5916	0.0782	7.57	0.000
Rn	0.3757	0.0757	4.97	0.000

#### جدول ۹- نتایج تحلیل واریانس (Analysis of Variance) جهت تخمین UCS به روش رگرسیون خطی چند متغیره

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	4	22.1876	5.54690	859.78	0.000
Vp	1	0.0044	0.00441	0.68	0.012
$\gamma$	1	0.0017	0.00171	0.27	0.04
PLV	1	0.3693	0.36933	57.25	0.000
Rn	1	0.1591	0.15910	24.66	0.000



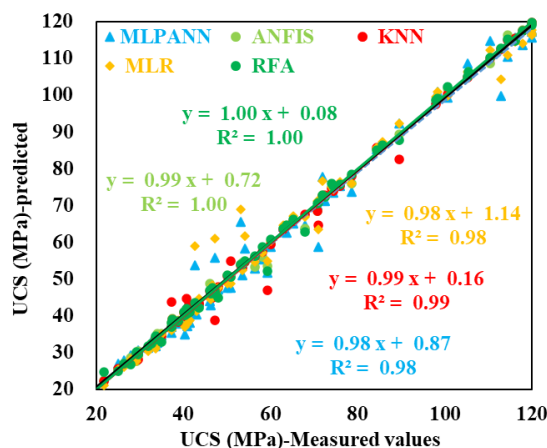
شکل ۱۵- نمودار باقیمانده‌ها جهت تخمین UCS به روش رگرسیون خطی چند متغیره

ورودی و اثرات آن‌ها را بر مقاومت فشاری نشان می‌دهند و قابلیت‌های تعمیم قوی برای داده‌های جدید را نشان می‌دهند. در حالی که نتایج مدل ایجاد شده برای هر منطقه مقداری کمی قابلیت تعمیم را ارائه می‌دهد، توسعه روابط محلی برای مناطق خاص بسیار مهم است (Zhang et al., 2023; Khan et al., 2022). علاوه بر این، ارزیابی عملکرد مدل‌های مختلف برای تعیین مدل بهینه برای هر منطقه ضروری است. مدل‌های ارائه شده برای پیش‌بینی مقاومت زمانی که مقادیر پیش‌بینی‌کننده در محدوده مشابه این تحقیق قرار دارند، قابل استفاده هستند. مدل‌های آینده باید بر روی مجموعه داده‌های بزرگتر آزمایش شوند تا دقت پیش‌بینی‌ها افزایش یابد.


#### ۷-۴- ارزیابی و مقایسه روش‌ها

برای مقایسه روش‌ها، آماره‌های متعددی محاسبه شد (شکل ۱۶). همانطور که مشاهده می‌شود RFA بهترین دقت را برای پیش‌بینی UCS نشان می‌دهد. بعد از ANFIS، RFA بالاترین دقت را در پیش‌بینی UCS نشان می‌دهد. دقت روش‌ها تحت تأثیر تعداد ورودی‌ها، تعداد نمونه‌ها و انتخاب الگوریتم آموزشی است (Zhang et al., 2023). محققین قبلی بیان نموده‌اند هنگامی که تعداد نمونه‌ها کم باشد روش ماشین بردار پشتیبان به دلیل استفاده از قضیه ریسک ساختاری در مقایسه با روش شبکه عصبی دقیقتر عمل می‌کند (Kookalani and Cheng 2021).

به طور کلی، می‌توان نتیجه گرفت که هر چهار روش هوشمند ارائه شده در تحقیق حاضر به طور موثر روابط بین پارامترهای



(a)

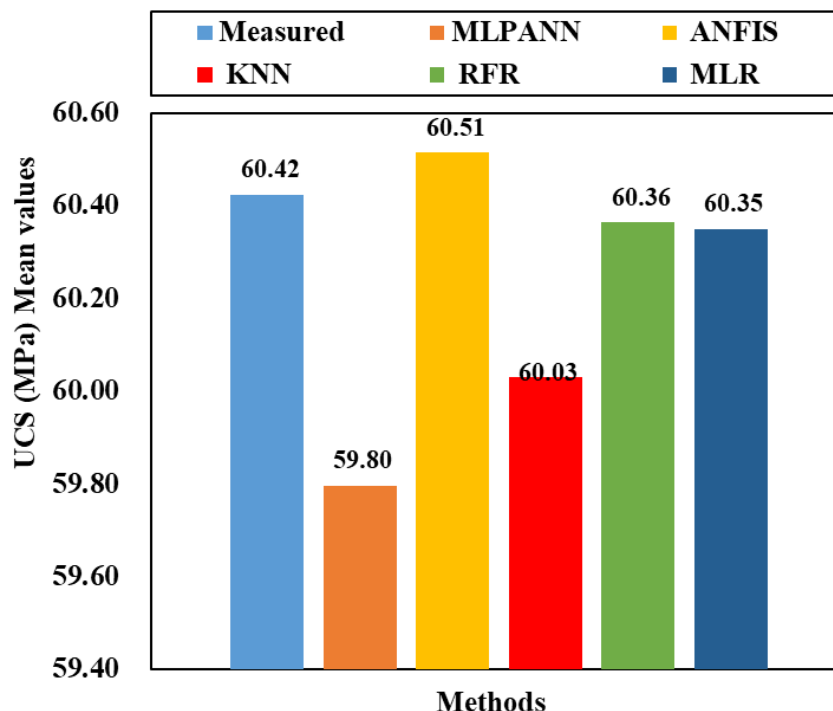


(b)

شکل ۱۶- دقت روش‌ها برای پیش‌بینی UCS

تخمین UCS دارد (شکل های ۱۶ و ۱۷). میانگین مقادیر برآورد شده UCS توسط مدل‌های شبکه عصبی مصنوعی، رگرسیون خطی چند متغیره، KNN و RFA کمتر از مقادیر واقعی می‌باشد (شکل ۱۹)، که نشان‌دهنده گرایش محافظه‌کارانه این چهار روش در برآورد UCS است. از سوی دیگر، روش ANFIS چنین رفتار محافظه‌کارانه‌ای را در برآورد UCS نشان نمی‌دهد.

هر چهار روش هوشمند دقت بسیار بالایی در تخمین مقاومت فشاری نشان دادند. درصد اختلاف میانگین این چهار روش با مقدار اندازه گیری شده در آزمایشگاه ۰,۱۸ درصد به دست آمد. این مقدار اختلاف کمتر از ۱ درصد بوده و نشانگر قابلیت بالای روش‌های هوشمند در تخمین UCS می‌باشد. مقایسه میانگین UCS اندازه گیری شده با میانگین UCS پیش‌بینی شده نشان می‌دهد که روش RFA بالاترین دقت را در




شکل ۱۷- مقادیر حاصل از روش‌های مدل‌سازی جهت تخمین مقاومت فشاری تک محوری

برآورد شده با استفاده از روش‌ها

۵-۷- بررسی معنی داری اختلاف UCS اندازه گیری و

شاپیرو-ویلک، که با Sig. نشان داده می‌شود، بیشتر از ۵ درصد باشد، می‌توان داده‌ها را با اطمینان بالا نرمال فرض کرد. در غیر این صورت نمی‌توان گفت که توزیع داده‌ها نرمال است. با توجه به جدول ۱۰ و مقادیر سطح معنی داری Sig که در هر دو آزمون کولموگروف-اسمیرنوف و شاپیرو-ویلک کمتر از ۵ درصد است، فرض توزیع نرمال متغیر UCS رد می‌شود. به عبارت دیگر همانطور که در شکل ۱۸ (نمودار احتمال) نشان داده شده است، نمی‌توان گفت که توزیع داده‌های این متغیر نرمال است. بنابراین برای بررسی معنی داری اختلاف مقادیر پیش‌بینی‌شده توسط مدل‌ها و اندازه‌گیری شده، از آزمون ناپارامتریک (Kruskal-Wallis) KW استفاده شد.

قبل از بررسی اختلاف UCS اندازه‌گیری شده و برآورد شده با روش‌های مختلف، لازم است نرمال بودن نتایج بررسی شود. در صورت نرمال بودن داده‌ها می‌توان از آزمون پارامتریک استفاده کرد، در غیر این صورت باید از آزمون‌های ناپارامتریک برای بررسی تفاوت بین مقادیر اندازه‌گیری شده و پیش‌بینی شده استفاده کرد. برای بررسی نرمال بودن نتایج به دست‌آمده از روش‌های هوشمند و مقدار UCS اندازه‌گیری شده، از کولموگروف-اسمیرنوف و شاپیرو-ویلک (جدول ۱۰) و نمودار احتمال (شکل ۱۸) استفاده شد. اگر سطح معنی داری در آزمون‌های کولموگروف-اسمیرنوف و



شکل ۱۸ - آزمون نرمال بودن بر روی UCS برآورد شده با روش‌های هوشمند و مقدار اندازه‌گیری شده در آزمایشگاه

جدول ۱۰- آزمون نرمال بودن نتایج حاصل از روش‌های آزمایشگاهی و مدل‌سازی

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
MLPANN	0.1390	76	0.001	0.898	76	0.000
RFA	0.143	76	0.001	0.903	76	0.000
MLR	0.130	76	0.004	0.918	76	0.000
ANFIS	0.148	76	0.000	0.895	76	0.000
KNN	0.152	76	0.000	0.904	76	0.000
M1	0.139	76	0.002	0.908	76	0.000

توجه به اینکه سطح معنی‌داری مشاهده شده با استفاده از آزمون **KW** بالاتر از آستانه پذیرفته شده معمول ۰/۰۵ است، می‌توان فرضیه صفر را قبول کرد. از این رو، مقادیر **UCS** پیش‌بینی‌شده به طور قابل‌توجهی در بین روش‌های مختلف یکسان است. مقایسه‌های چندگانه انجام نمی‌شود زیرا آزمون کلی تفاوت‌های قابل‌توجهی را در بین نمونه‌ها نشان نمی‌دهد.

آزمون **Kruskal-Wallis (KW)** برای تجزیه و تحلیل مقادیر **UCS** پیش‌بینی‌شده در روش‌های مختلف استفاده شد (جدول ۱۱). این آزمون ناپارامتریک برای داده‌هایی مناسب است که به فرضیات **ANOVA** مانند نرمال بودن پایبند نیستند. فرضیه صفر بیان می‌کند که تفاوتی در مقادیر **UCS** پیش‌بینی‌شده در بین روش‌ها وجود ندارد. برعکس، فرضیه جایگزین نشان می‌دهد که اختلاف معنی‌داری وجود دارد. با

جدول ۱۱- نتایج آزمون کراسکول-والیس بر روی مقادیر **UCS** پیش‌بینی‌شده با استفاده از روش‌های هوشمند و مقدار اندازه‌گیری شده

Null hypothesis	Ho: All medians are equal		
Alternative hypothesis	H <sub>1</sub> : At least one median is different		
Method	DF	H-Value	P-Value
Not adjusted for ties	5	0.05	1.000
Adjusted for ties	5	0.05	1.000

در بین روش‌های هوشمند مورد استفاده بصورت محافظه‌کارانه **UCS** را تخمین زد. آزمون **Kruskal-Wallis (KW)** برای تجزیه و تحلیل اختلاف مقادیر **UCS** پیش‌بینی‌شده و اندازه‌گیری‌شده در روش‌های مختلف نشان داد که مقادیر **UCS** پیش‌بینی‌شده در بین روش‌های مختلف یکسان می‌باشد. روش جنگل تصادفی برای حجم داده‌های زیاد به خوبی عمل می‌کند و از دقت بالایی برخوردار است. در این روش به دلیل اینکه با افزایش درخت‌ها میزان خطا کاهش می‌یابد، بنابراین تعداد ۴۸۰ درخت برای فراخوانی مدل استفاده شد و پس از اجرای مدل نتایج مدل به وسیله برآورد خطای خارج از کیسه (OOB) ارزیابی گردید. علاوه بر این، برای کاهش ابعاد و افزایش دقت و قابل‌تفسیر بودن مدل، روش انتخاب ویژگی به کار برده شد و متغیرهای مهم در پیش‌بینی نیز شناسایی گردید. برای همه مدل‌های هوشمند ارائه شده، دقت داده‌های آزمون برابر یا بیشتر از داده‌های آموزشی بود که نشان‌دهنده عدم بیش از حد برازش شدگی در نتایج مدل‌ها و اعتبار بالای آن‌ها در تخمین **UCS** را نشان می‌دهد.

روابط و مدل‌های ارائه شده برای هر منطقه را می‌توان تا حدودی برای مناطق دیگر تعمیم داد. مدل‌های توسعه‌یافته

## ۵. نتیجه‌گیری

مقاومت فشاری سنگ‌ها پارامترهای اساسی برای طراحی سازه‌های مهندسی هستند. برآورد این پارامتر با استفاده از نمونه‌های سالم پرهزینه، دشوار و در برخی موارد غیرممکن است. بنابراین، رویکردهای آماری و هوشمندانه در سال‌های اخیر به طور گسترده برای پیش‌بینی این ویژگی با استفاده از ویژگی‌های شاخص مورد استفاده قرار گرفته‌اند.

در تحقیق حاضر، نتایج بررسی بر روی نمونه‌های ماسه سنگ حاصل از ساختگاه سد سیاه بیسه و نمونه‌های حاصل از غرب شهر دماوند نشان داد که بر اساس مطالعات پتروگرافی، نمونه‌ها در دو گروه فلدسپاتیک لیتارنایت و لیت‌آرنایت طبقه بندی می‌شوند. نتایج بررسی آماری نشان داد که شاخص بار نقطه‌ای، سرعت موج تراکمی، دانسیته و سختی اشمیت بیشترین تاثیر را بر **UCS** دارند و به همین دلیل به عنوان پارامترهای ورودی مدل‌ها به منظور پیش‌بینی **UCS** استفاده شدند. نتایج مدل‌سازی نشان داد که مدل‌های هوش مصنوعی در برآورد **UCS** با دقت بالاتری نسبت به روش‌های آماری عمل می‌کنند. بر اساس معیارهای مختلف آماری و نتایج داده‌های آزمون، از میان روش‌های هوشمند، الگوریتم جنگل تصادفی با بالاترین دقت ( $R^2=0.99$ )، ( $RMSE=0.06MPa$ )

برای پیش‌بینی UCS زمانی مناسب‌تر هستند که شاخص‌های پیش‌بینی‌کننده در محدوده مشابه با این مطالعه باشند. توصیه می‌شود که مدل‌های آینده روی مجموعه داده‌های بزرگتر آزمایش شوند تا دقت پیش‌بینی افزایش یابد.

### منابع

- عبدی، ی.، خانلری، غ. (۱۳۹۷) برآورد خواص مکانیکی ماسه سنگها با استفاده از سرعت موج P و سختی اشमित. یافته‌های نوین زمین شناسی کاربردی، ۱۳(۲۵): ۳۳-۴۷. Doi: 10.22084/NFAG.2018.16623.1322.
- عبدی، ی.، خانلری، غ. (۱۳۹۶) بررسی اثر انجماد-ذوب بر خواص مکانیکی ماسه سنگ‌های سازند قرمز بالایی بر اساس اندازه‌گیری سرعت موج و تخلخل، یافته‌های نوین زمین شناسی کاربردی، ۱۲(۲۳): ۷۵-۷۵. Doi: 10.22084/NFAG.2017.13399.125491.
- حیدری، م.، رفیعی، ب. و طباطبائی، ح. (۱۳۹۱) بررسی ویژگی‌های ژئوتکنیکی ماسه سنگ‌های سازند قم واقع در روستای توجرک (شهرستان فمین)، هشتمین همایش انجمن زمین شناسی مهندسی و زیست محیطی ایران، دانشگاه فردوسی مشهد.
- مرادی، سیامک، امیری، مهرداد، رحیمی شهید، مجتبی، کراری، سید سجاد. (۲۰۲۲). ارائه روابط رگرسیون ساده و چندگانه برای ارزیابی مقاومت فشاری تک محوری سنگ‌های رسوبی و آذرآواری با استفاده از آزمون چکش اشमित، یافته‌های نوین زمین شناسی کاربردی، ۱۶(۳۲). صص ۹۲-۱۰۸. doi: 10.22084/nfag.2021.24761.1480108.
- عقیقی، ف.، عقیقی، ح.، عباتی، (۲۰۱۷) ارزیابی کارایی الگوریتم‌های طبقه‌بندی SVM و KNN برای استخراج اثرات شهری از نقاط ابری LiDAR، دومین کنفرانس بین‌المللی پژوهش‌های مبتنی بر دانش در مهندسی کامپیوتر و فناوری اطلاعات، تهران، دانشگاه مجلسی.
- Abbasi Dezfouli, A (2021) Experimental Investigation into the Metakaolin Used in Concrete. *Journal of civil Engineering and Materials Application*, 5(2): 67-80. Doi: 10.22034/JCEMA.2020.253922.1041
- Abdelhedi, M., Jabbar, R., Said, A.B. et al. (2023) Machine learning for prediction of the uniaxial compressive strength within carbonate rocks. *Earth Science Informatics* 16, 1473–1487. <https://doi.org/10.1007/s12145-023-00979-9>
- Afolagboye, L.O., Ajayi, D.E. and Afolabi, I.O (2023) Machine learning models for predicting unconfined compressive strength: A case study for Precambrian basement complex rocks from Ado-Ekiti, Southwestern Nigeria. *Scientific African*, 20, p.e01715. <https://doi.org/10.1016/j.sciaf.2023.e01715>.
- Akbar Kafash Bazari, A (2023) A Case Study of Cement Performance in Different Concretes. *Journal of Civil Engineering & Materials Application*, 7(1). DOI: 10.22034/JCEMA.2023.365342.1098
- Aladejare AE. (2020). Evaluation of empirical estimation of uniaxial compressive strength of rock using measurements from index and physical tests. *Journal of Rock Mechanics and Geotechnical Engineering*, 12(2), 256-268. <https://doi.org/10.1016/j.jrmge.2019.08.001>.
- Aladejare, A.E., Alofe, E.D., Onifade, M., Lawal, A.I., Ozoji, T.M. and Zhang, Z.X. (2021) Empirical estimation of uniaxial compressive strength of rock: database of simple, multiple, and artificial intelligence-based regressions. *Geotechnical and Geological Engineering*, 39(6), pp.4427-4455. <https://doi.org/10.1007/s10706-021-01772-5>.
- Aliyu MM, Shang J, Murphy W, Lawrence JA, Collier R, Kong F, Zhao Z (2019) Assessing the uniaxial compressive strength of extremely hard cryptocrystalline flint. *International Journal of Rock Mechanics and Mining Sciences*; 113:310-321. <https://doi.org/10.1016/j.ijrmms.2018.12.002>.
- Andriani, G. F. & Walsh, N (2010) Petrophysical and mechanical properties of soft and porous building rocks used in Apulian monuments (south Italy), Geological Society, London, Special Publications, 333(1), 129-141. <https://doi.org/10.1144/SP333.13>
- 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. doi: 10.15412/J.JCEMA.12010301 .
- ASTM (2002a) Standard Test Method for Unconfined Compressive Strength of Intact Rock Core Specimens. In: ASTM D2938-95 ,

- ASTM (2002b) Standard test method for determination of the point load strength index of rock. ASTM International, West Conshohocken D5731 .
- ASTM. (1983) Test methods for ultra violet velocities determination. Designation D2845.
- Azimian A (2017) Application of statistical methods for predicting uniaxial compressive strength of limestone rocks using nondestructive tests. *Acta Geotechnica*, 12(2), 321-333. <https://doi.org/10.1007/s11440-016-0467-3>
- Barham WS, Rabab'ah Aldeeky SR, Al Hattamleh OH (2020) Mechanical and Physical Based Artificial Neural Network Models for the Prediction of the Unconfined Compressive Strength of Rock. *Geotechnical and Geological Engineering*, 38(5): 4779-4792. doi: 10.1007/s10706-020-01327-0.
- Barzegar R, Sattarpour M, Nikudel MR, Moghaddam AA (2016) Comparative evaluation of artificial intelligence models for prediction of uniaxial compressive strength of travertine rocks, case study: Azarshahr area, NW Iran. *Modeling Earth Systems and Environment*, 2(2), p.76. <https://doi.org/10.1007/s40808-016-0132-8>
- 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. doi: 10.22034/JCEMA.2019.99690
- Bolla, A.; Paronuzzi, P. (2021) UCS field estimation of intact rock using the Schmidt hammer: A new empirical approach. In *IOP Conference Series, Environmental Earth Sciences.*, 83, p. 012014, IOP Publishing. DOI 10.1088/1755-1315/833/1/012014
- Broch, E., Franklin, J.A. (1972). The point-load strength test, *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 9.(۶)
- Chang, C., Zoback, M. D., & Khaksar, A. (2006). Empirical relations between rock strength and physical properties in sedimentary rocks, *Journal of Petroleum Science and Engineering*. 51(3), 223-237. <https://doi.org/10.1016/j.petrol.2006.01.003>
- Daoud, H.S.D., Rashed, K.A.R., Alshkane, Y.M.A. (2018) Correlations of uniaxial compressive strength and modulus of elasticity with point load strength index, pulse velocity and dry density of limestone and sandstone rocks in Sulaimani Governorate, Kurdistan Region, Iraq, *Journal of Zankoy Sulaimani-Part A*, , 19, 57-72. Doi:10.17656/jzs.10632.
- Duda, R. O., Hart, P. E., Stork, D.G (2012) *Pattern classification*. John Wiley & Sons.
- Edet A (2018) Correlation between Physico-mechanical Parameters and Geotechnical Evaluations of Some Sandstones along the Calabar/Odukpani-Ikom-Ogoja Highway Transect, Southeastern Nigeria". *Geotechnical and Geological Engineering*, 36(1): 135-149. doi: 10.1007/s10706-017-0311-z.
- Etemadi, M., Pouraghajan, M. and Gharavi, H. (2020) Investigating the effect of rubber powder and nano silica on the durability and strength characteristics of geopolymeric concretes. *Journal of civil Engineering and Materials Application*, 4(4), 243-252. doi: 10.22034/jcema.2020.119979
- Fathipour-Azar, H (2022) Machine learning-assisted distinct element model calibration: ANFIS, SVM, GPR, and MARS approaches. *Acta Geotechnica*, 17(4), pp.1207-1217. <https://doi.org/10.1007/s11440-021-01303-9>
- Folk RL (1974) *Petrology of Sedimentary Rocks*. Hemphill, Austin, 600p.
- Gamal, H., Alsaihati, A., Elkatatny, S., Haidary, S. and Abdulraheem, A (2021) Rock strength prediction in real-time while drilling employing random forest and functional network techniques. *Journal of Energy Resources Technology*, 143(9). <https://doi.org/10.1115/1.4050843>
- Ghafoori M, Rastegarnia A, Lashkaripour GR (2018) Estimation of static parameters based on dynamical and physical properties in limestone rocks. *Journal of African Earth Sciences*, 137: 22-31 <https://doi.org/10.1016/j.jafrearsci.2017.09.008>.
- Ghavami, S. Rajabi, M (2021) Investigating the Influence of the Combination of Cement Kiln Dust and Fly Ash on Compaction and Strength Characteristics of High-Plasticity Clays. *Journal of civil Engineering and Materials Application*, 5(1), pp.9-16. doi:10.22034/JCEMA.2020.250727.1040

- Ghobadi, M. H. Mousavi, S. (2014) The effect of pH and salty solutions on durability of sandstones of the Aghajari Formation in Khuzestan province, southwest of Iran, *Arabian Journal of Geosciences*, 7(2), 641-653. <https://doi.org/10.1007/s12517-012-0741-0>
- Ghobadi, M. H., Rafiei, B., Mousavi, S. and Aria Fer, N. (2012) Investigation of geotechnical characteristics of Aghajari Formation sandstones in the east and southeast of Ahvaz, *Journal of Advanced Applied Geology*, 1, 21-33(in Persian).
- Ghobadi, M.H., Amiri, M., Rasouli Farah, M.R (2021) Studying the geotechnical characteristics of Qom formation sandstones and their use as loan resources (case study: Letgah village, north of Hamadan). *New Findings of Applied Geology*, 15(29), 55-70 (in Persian). doi: 10.22084/NFAG.2020.21215.1408
- Gül E, Ozdemir E, Sarıcı DE (2021) Modeling uniaxial compressive strength of some rocks from turkey using soft computing techniques. *Measurement*, 171, 108781. <https://doi.org/10.1016/j.measurement.2020.108781>.
- Harris, J., & Grunsky, E.C (2015) Predictive lithological mapping of Canada's North using Random Forest classification applied to geophysical and geochemical data. *Computers & geosciences*, 80, 9-25. <https://doi.org/10.1016/j.cageo.2015.03.013>
- Hasheminezhad, A. and Sadeghi, A (2023) Indirect Estimation of Uniaxial Compressive Strength of Limestone Using Rock Index Tests Through Computational Methods. *Journal of Civil Engineering and Materials Application*, 7(3), Doi:10.22034/JCEMA.2023.393871.1107
- Hassanzadeh R, Beiranvand B, Komasi M, Hassanzadeh A (2021) Investigation of data 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. Doi: 10.22034/jcema.2021.302238.1063
- Hebib, R.; Belhai, D.; Alloul, B. Estimation of uniaxial compressive strength of North Algeria sedimentary rocks using density, porosity, and Schmidt hardness, *Arab J Geosci*, 2017, 10(17), 1-13. <https://doi.org/10.1007/s12517-017-3144-4>.
- Hecht-Nielsen R. (1987) Kolmogorov's mapping neural network existence theorem. In *Proc Int Conf Neural Networks*, 11–14. IEEE Press: New York, NY, USA.
- Heidari, M., Momeni, A., Rafiei, B., Khodabakhsh, S., Torabi-Kaveh, M. (2013) Relationship between Petrographic Characteristics and the Engineering Properties of Jurassic Sandstones, Hamedan, Iran”, *Rock Mechanics and Rock Engineering*, 46, 1091-1101. <https://doi.org/10.1007/s00603-012-0333-z>.
- Hudaverdi, T (2022) Prediction of flyrock throw distance in quarries by variable selection procedures and ANFIS modelling technique. *Environmental Earth Sciences*, 81(10), pp.1-21. <https://doi.org/10.1007/s12665-022-10408-7>
- Hush D (1989) Classification with neural networks: A performance analysis. In *Proc IEEE Int Conf Syst Eng*, 277–280. IEEE: Piscataway, NJ, USA.
- ISRM (1981) Rock characterization testing and monitoring. In: Brown, E.T. (Ed.), *ISRM Suggested Methods*. Pergamon Press, Oxford.
- James, G., Witten, D., Hastie, T., & Tibshirani, R (2013) *An introduction to statistical learning* (Vol. 112). Springer.
- Jamshidi, A. (2017) Effect of density and porosity on the degree of accuracy of estimating relationships of uniaxial compressive strength and modulus of elasticity of limestone from Schmidt's surface hardness, *New findings of applied geology*, 12(24), 65-76. doi: 10.22084/nfag.2018.15464.1290
- Jang, JSR. (1993) ANFIS: Adaptive-network-based fuzzy inference system, *IEEE Trans. Syst., Man, Cybern.*, 23(3), 665–685 .
- Joseph, J. and Swalih CK, A (2023) Implementation of Machine Learning in Structural Reliability Analysis. *Journal of Civil Engineering and Materials Application*, 7(3): 1-9, doi: 10.22034/JCEMA.2023.396301.1108
- Kaastra I M, Boyd M. (1996) Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10, 215–236. [https://doi.org/10.1016/0925-2312\(95\)00039-9](https://doi.org/10.1016/0925-2312(95)00039-9).

- Kahraman S (2001) Evaluation of simple methods for assessing the uniaxial compressive strength of rock. *Int J Rock Mech Min Sci* 38(7): 981-994. [https://doi.org/10.1016/S1365-1609\(01\)00039-9](https://doi.org/10.1016/S1365-1609(01)00039-9)
- Khan, N. M. Cao, K. Yuan, Q. Mohd Hashim, M. H. B. Rehman, H. Hussain, S. M. Z. Emad, B. Ullah, K. S. Shah, and S. Khan. (2022) Application of machine learning and multivariate statistics to predict uniaxial compressive strength and static Young's modulus using physical properties under different thermal conditions. *Sustainability*, 14(16), 9901. <https://doi.org/10.3390/su14169901> .
- Kılıç A, Teymen A (2008) Determination of mechanical properties of rocks using simple methods. *Bulletin of Engineering Geology and the Environment* 67(2), 237-244 <https://doi.org/10.1007/s10064-008-0128-3>
- Kohavi R (1995) A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference on Artificial Intelligence.*; 14(2):1137–1145.
- 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): 12-23. doi:10.22034.2021.304981.1064
- Lerman N, Aronofsky L, Aghili B (2021) Investigating the microstructure and mechanical properties of metakaolin-based polypropylene fiber-reinforced geopolymer concrete using different monomer ratios, *Journal of civil Engineering and Materials Application*, doi: 10.22034.2021.302140.1062.
- Liaw A, Wiener M (2002). Classification and Regression by Random Forest. *R News*, 2(3), 18-22. <https://CRAN.R-project.org/doc/Rnews/>
- 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. doi: 10.22034/JCEMA.2018.91995
- Matin, S.S., Farahzadi, L., Makaremi, S., Chelgani, S.C. and Sattari, G.H (2018) Variable selection and prediction of uniaxial compressive strength and modulus of elasticity by random forest. *Applied Soft Computing*, 70, pp.980-987. <https://doi.org/10.1016/j.asoc.2017.06.030>
- McElroy, P.D., Bibang, H., Emadi, H., Kocoglu, Y., Hussain, A. and Watson, M.C (2021) Artificial neural network (ANN) approach to predict unconfined compressive strength (UCS) of oil and gas well cement reinforced with nanoparticles. *Journal of Natural Gas Science and Engineering*, 88, p.103816. <https://doi.org/10.1016/j.jngse.2021.103816>
- Miah, M.I., Ahmed, S., Zendejboudi, S. et al. (2020) Machine Learning Approach to Model Rock Strength: Prediction and Variable Selection with Aid of Log Data. *Rock Mechanics and Rock Engineering*, 53, 4691–4715. <https://doi.org/10.1007/s00603-020-02184-2>
- Mishra DA, Basu A (2013) Estimation of uniaxial compressive strength of rock materials by index tests using regression analysis and fuzzy inference system, *Engineering Geology* 160(1): 54-68. Doi: 10.1016/j.enggeo.2013.04.004
- Momeni E., Abdi Y. (2022) Application of Group Data Management Method (GMDH) in predicting uniaxial compressive strength of limestones, *Journal of Engineering Geological Society of Iran*, 15(2), 69-94 (in Persian)
- Naresh, K. T., Shuichiro, Y., Suresh, D (2007) Relationships among mechanical, physical and petrographic properties of Siwalik sandstones, Central Nepal Sub-Himalayas, *Engineering Geology*, 90, 105-123. <https://doi.org/10.1016/j.enggeo.2006.10.005>
- 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. doi: 10.15412/J.JCEMA.12010202
- 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. 10.22034/JCEMA.2019.94190
- Rahman, T. and Sarkar, K (2023) Correlations between uniaxial compressive strength and dynamic elastic properties for six rock types. *International Journal of Geomechanics*, 23(6), p.04023064. <https://doi.org/10.1061/IJGNAI.GMENG-7854>
- Ripley B.D (1993) Statistical Aspects of Neural Networks. In *Netw Chaos–Statist Probabilist Asp* (Eds O E Barndorff-Nielsen, J L Jensen, W S Kendall), Chapman and Hall: London, UK, 40–123.

- Saghi H, Behdani M, Saghi R, Ghaffari AR., 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. DOI: 10.22034/JCEMA.2020.212110.1012.
- Selçuk L, Nar A (2016) Prediction of uniaxial compressive strength of intact rocks using ultrasonic pulse velocity and rebound-hammer number”, *Quarterly Journal of Engineering Geology and Hydrogeology* 49(1): 67-75. <http://dx.doi.org/10.1144/qjegh2014-094> .
- Selçuk, L.; Yabalak, E (2015) Evaluation of the ratio between uniaxial compressive strength and Schmidt hammer rebound number and its effectiveness in predicting rock strength. *Nondestructive Testing and Evaluation.*, 30, 1–12. <http://dx.doi.org/10.1144/qjegh2014-094>
- 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. Doi: 10.22034/JCEMA.2018.91998
- Singh R, Umrao RK, Ahmad M, Ansari MK, Sharma LK, Singh TN (2017) Prediction of geomechanical parameters using soft computing and multiple regression approach. *Measurement*, 99, 108-119. <https://doi.org/10.1016/j.measurement.2016.12.023>
- Sun, D., Lonbani, M., Askarian, B., Jahed Armaghani, D., Tarinejad, R., Thai Pham, B. and Huynh, V.V., (2020) Investigating the applications of machine learning techniques to predict the rock brittleness index. *Applied Sciences*, 10(5), p.1691. <https://doi.org/10.3390/app10051691>
- Taheri, S and Ziad, H (2021) Analysis and Comparison of Moisture Sensitivity and Mechanical Strength of Asphalt Mixtures Containing Additives and Carbon Reinforcement, *Journal of Civil Engineering and Materials Application*. 5(1): 01-08 doi: 10.22034/jcema.2021.128042
- Teymen A, Mengüç EC (2020) Comparative evaluation of different statistical tools for the prediction of uniaxial compressive strength of rocks. *International Journal of Mining Science and Technology*. 30(6):785-97. <https://doi.org/10.1016/j.ijmst.2020.06.008>
- Tharwat, A., Ghanem, A. M., & Hassanien, A. E. (2013). Three different classifiers for facial age estimation based on k-nearest neighbor. In 2013 9th International Computer Engineering Conference (ICENCO) (pp. 55-60). IEEE.
- Tofighkhah, M., Hashemidanesh, N. and Ameri, M (2023) Investigating the Resistance Behavior of the Clayey Sand Soil Improved with Nano-Silica and Carbon Fibers. *Journal of Civil Engineering and Materials Application*, 7(1). DOI: 10.22034/JCEMA.2023.171494.
- Tomor, A.K., Nichols, J.M. and Orbán, Z (2023) Evaluation of the Loss of Uniaxial Compressive Strength of Sandstones Due to Moisture. *International Journal of Architectural Heritage*, pp.1-17. <https://doi.org/10.1080/15583058.2023.2188313>
- Török, Á. & Vászárhelyi, B (2010) The influence of fabric and water content on selected rock mechanical parameters of travertine, examples from Hungary, *Engineering Geology*, 115(3), 237-245. <https://doi.org/10.1016/j.enggeo.2010.01.005>
- Uyanık O, Sabbağ N, Uyanık NA, 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. Doi: 10.1007/s10064-019-01501-6.
- Vászárhelyi, B (2003) Some observations regarding the strength and deformability of sandstones in dry and saturated conditions, *Bulletin of Engineering Geology and the Environment*, 62(3), 245-249. <https://doi.org/10.1007/s10064-002-0186-x>
- Vászárhelyi, B (2005) Statistical analysis of the influence of water content on the strength of the Miocene limestone, *Rock Mechanics and Rock Engineering*, 38(1), 69-76. DOI 10.1007/s00603-004-0034-3
- Wang C. A (1994) *Theory of Generalization in Learning Machines with Neural Application*. Ph.D. Dissertation, The University of Pennsylvania, Philadelphia, PA, USA.
- Wang, M., Wan, W. and Zhao, Y (2020) Prediction of the uniaxial compressive strength of rocks from simple index tests using a random forest predictive model. *Comptes Rendus. Mécanique*, 348(1), pp.3-32. DOI: 10.5802/crmeca.3

- Wang, Y.; Hasanipanah, M.; Rashid, A.S.A.; Le, B.N.; Ulrikh, D.V. (2023) Advanced Tree-Based Techniques for Predicting Unconfined Compressive Strength of Rock Material Employing Non-Destructive and Petrographic Tests. *Materials*, 16, 3731. <https://doi.org/10.3390/ma16103731>
- 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. DOI: 10.22034/JCEMA.2022.354028.1093
- Wen L, Luo Quan Z, Yang Jiao S, Guang Qin Y, Wang W (2018) Correlation of Geo-Mechanics Parameters with Uniaxial Compressive Strength and P-Wave Velocity on Dolomitic Limestone Using a Statistical Method. *Geotechnical and Geological Engineering* 37(2): 1079-1074. doi: 10.1007/s10706-018-0665-x.
- Weng, M.C., Li, H.H (2012) Relationship between the deformation characteristics and microscopic properties of sandstone explored by the bonded-particle model”, *International Journal of Rock Mechanics and Mining Sciences*, 56, 34-43, <https://doi.org/10.1016/j.ijrmms.2012.07.003>
- Xu, B.; Tan, Y.; Sun, W.; Ma, T.; Liu, H.; Wang, D. (2023) Study on the Prediction of the Uniaxial Compressive Strength of Rock Based on the SSA-XGBoost Model. *Sustainability*, 15, 5201. <https://doi.org/10.3390/su15065201>
- Yagiz, S., Sezer, E.A. and Gokceoglu, C (2012) Artificial neural networks and nonlinear regression techniques to assess the influence of slake durability cycles on the prediction of uniaxial compressive strength and modulus of elasticity for carbonate rocks. *International Journal for Numerical and Analytical Methods in Geomechanics*, 36(14), 1636-1650. <https://doi.org/10.1002/nag.1066>
- Yesiloglu-Gultekin N, Gokceoglu C. A (2022) Comparison Among Some Non-linear Prediction Tools on Indirect Determination of Uniaxial Compressive Strength and Modulus of Elasticity of Basalt. *Journal of Nondestructive Evaluation*. 41(1):1-24. <https://doi.org/10.1007/s10921-021-00841-2>
- Yilmaz, N.G.; Goktan, R.M (2019) Comparison and combination of two NDT methods with implications for compressive strength evaluation of selected masonry and building stones. *Bulletin of Engineering Geology and the Environment*, 78, 4493-4503. <https://doi.org/10.1007/s10064-018-1382-7>
- Yosri, A.M. A.I.B. Farouk, S.I. Haruna, A. Farouk Deifalla, W.M. Shaaban. (2023) Sensitivity and robustness analysis of adaptive neuro-fuzzy inference system (ANFIS) for shear strength prediction of stud connectors in concrete. *Case Studies in Construction Materials.*, 18,. e02096. <https://doi.org/10.1016/j.cscm.2023.e02096> .
- Zhang, X., Altalbawy, F.M., Gasmalla, T.A., Al-Khafaji, A.H.D., Iraj, A., Syah, R.B. and Nehdi, M.L., (2023) Performance of Statistical and Intelligent Methods in Estimating Rock Compressive Strength. *Sustainability*, 15(7), 5642, doi: <https://doi.org/10.3390/su15075642>
- Zheng, J. Shen, M. Motahari, M.R. and M., Khajehzadeh (2023) Prediction of Rock Tensile Strength Using Soft Computing and Statistical Methods. *Periodica Polytechnica Civil Engineering*. 67(3) (2023), <https://doi.org/10.3311PPci.22179>