



تخمین مقاومت فشاری تک محوری و مدول الاستیسیته نمونه های کنگلومرا با استفاده از رگرسیون و شبکه عصبی مصنوعی

مجتبی میدری*، بهروز رفیعی^۱، مهران نوری^۱، غلامرضا فانلری^۱، علی اکبر مومنی^۲

(۱) گروه زمین شناسی، دانشکده علوم پایه، دانشگاه بوعلی سینا، همدان، ایران

Heidarim_Enggeol@Yahoo.com

(۲) گروه زمین شناسی، دانشکده علوم پایه، دانشگاه صنعتی شاهرود، شاهرود، ایران

(* عهده دار مکاتبات)

دریافت: ۹۲/۷/۲۸؛ دریافت اصلاح شده: ۹۳/۲/۲۰؛ پذیرش: ۹۳/۳/۶؛ قابل دسترس در تارنما: ۹۴/۸/۳۰

چکیده

تعیین دقیق برخی از خواص مکانیکی سنگ ها، مانند مقاومت فشاری تک محوری (Uniaxial Compressive Strength, UCS) و مدول الاستیسیته (E)، به زمان و هزینه قابل توجهی برای جمع آوری و آماده سازی نمونه های مناسب و آزمون های آزمایشگاهی نیاز دارد. UCS و E از جمله مهمترین خواص سنگ ها می باشند که تعیین آنها برای مطالعات مهندسی سنگ در بسیاری از پروژه های معدنی و مهندسی عمران ضروری می باشد. بنابراین برای به حداقل رساندن زمان و هزینه می توان از روابط تجربی که به طور گسترده ای برای برآورد خواص پیچیده سنگ ها از داده های حاصل از روش های آسان بهره می گیرد، استفاده نمود. هدف از این مطالعه، بررسی روش های شبکه عصبی مصنوعی (Artificial Neural Network, ANN) و رگرسیون چندمتغیره خطی (Multiple linear regression, MLR) به منظور برآورد UCS و E می باشد. در این پژوهش متغیرهای مستقل شاخص مقاومت بار نقطه ای (Point Load Strength Index, Is (50))، سرعت موج (Pressure wave velocity, Vp)، تخلخل (n)، چگالی و درصد رطوبت (water content, Wn) به عنوان پارامترهای ورودی به منظور پیش بینی متغیرهای وابسته (E و UCS) در هر دو روش استفاده شدند. روش MLR، UCS و E را به ترتیب با ضرایب تعیین $R^2=0.73$ و $R^2=0.85$ پیش بینی نموده است. استفاده از شبکه عصبی پرسپترون چند لایه (Multilayer Perceptron, MLP)، ضرایب تعیین را تا سطح قابل قبولی ($R^2=0.98$ برای UCS و $R^2=0.92$ برای E) بهبود بخشید. در این مطالعه، علاوه بر ضریب تعیین (R^2)، شاخص های ریشه میانگین مربعات خطا (Root Mean Square Error, RMSE) و میانگین قدر مطلق خطا (Mean Absolute Error, MAE)، برای ارزیابی قابلیت پیش بینی، مدل های ANN و MLR پیشنهادی نیز محاسبه شدند. نتایج این مطالعه نشان داد که روش ANN، عملکرد بهتری در پیش بینی UCS و E نسبت به روش MLR دارد.

واژه های کلیدی: مقاومت فشاری تک محوری، مدول الاستیسیته، کنگلومرا، رگرسیون چندمتغیره خطی، شبکه عصبی

۱- مقدمه

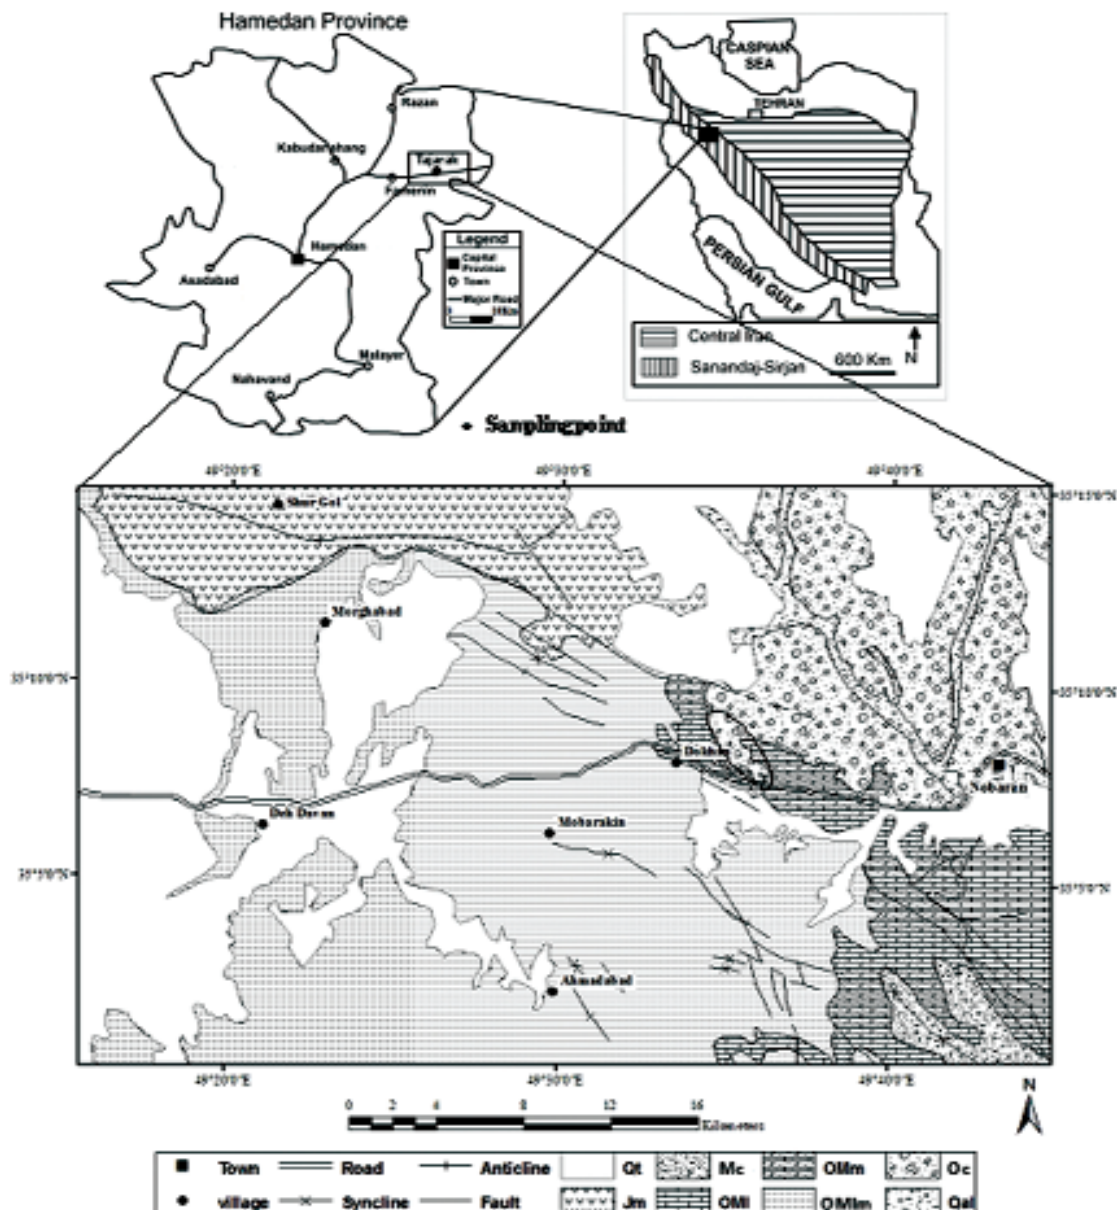
برای مدل‌سازی سیستم‌های غیرخطی می‌باشند. هدف این پژوهش پیش‌بینی مقاومت فشاری تک محوری UCS و مدول الاستیسیته (E)، کنگلومراهای سازند منطقه تبرک بر اساس پارامترهای شاخص مقاومت بار نقطه‌ای (IS_{50})، سرعت موج (Vp)، تخلخل (n)، چگالی γ_d و درصد رطوبت (Wn) می‌باشد. برای این منظور، از روش‌های رگرسیون چندمتغیره و شبکه عصبی مصنوعی استفاده شد. همچنین قابلیت پیش‌بینی مدل‌های پیش‌بینی کننده نیز با یکدیگر مقایسه شدند.

به منظور طبقه‌بندی سنگ‌ها و طراحی سازه‌ها در درون و یا بیرون توده‌های سنگی، مطالعه خواص مقاومتی و تغییر شکل‌پذیری سنگ‌ها دارای اهمیت حیاتی می‌باشد (Yilmaz & Yuksek 2009). مقاومت فشاری تک محوری و مدول الاستیسیته از جمله خواص بسیار مهم سنگ بکر در اجرای پروژه‌های مکانیک سنگ می‌باشند (Zorlu et al. 2008). تعیین مقاومت فشاری تک محوری و مدول الاستیسیته در آزمایشگاه به نمونه‌های مغزه با کیفیت مناسب نیاز دارد که انجام آن زمان‌بر و پرهزینه می‌باشد. نتایج حاصل به ابعاد نمونه، نحوه‌ی بارگذاری، خطاهای انسانی، عوامل خارجی و غیره بستگی دارد (کیانپور و همکاران ۱۳۹۰). با توجه به موارد گفته شده و همچنین عدم امکان تهیه نمونه مناسب از سنگ‌های ضعیف، متورق و خرد شده، پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته با استفاده از پارامترهای شاخص، ضروری به نظر می‌رسد. به شکل سنتی، روش‌های آماری مانند رگرسیون ساده و یا چندگانه، برای ایجاد مدل‌های پیش‌بینی کننده در مکانیک سنگ و زمین‌شناسی مهندسی به کار می‌روند. در سال‌های اخیر، روش‌های شبکه‌های عصبی و فازی در توسعه مدل‌های پیش‌بینی کننده برای برآورد پارامترهای مورد نیاز، استفاده شدند (Mishra & Basu 2013)، (Ceryan et al. 2013)، (Yesiloglu et al. 2013)، (Dehghan et al. 2010)، (Rabbani et al. 2010)، (Khanlari et al. 2012)، (Yilmaz & Yuksek 2009)، (Zorlu et al. 2008)، (Tiryaki 2008)، (Maity & Saha 2004)، (Singh et al. 2004)، (Singh et al. 2001)، (Yang & Zhang 1997) و (Maulenkamp & Grima 1999). شبکه‌های عصبی مصنوعی با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل کرده و نیازی به تعیین رابطه ریاضی بین ورودی‌ها و خروجی‌های مدل‌ها وجود ندارد. در مواردی که امکان نشان دادن مدل‌های پیچیده بین متغیرها در قالب‌های فیزیکی مشکل باشد، دارای توانایی زیادی می‌باشند. از سوی دیگر داده‌های ورودی نادرست یا ناقص در توابع ریاضی باعث ایجاد خطای زیادی در نتایج خروجی می‌شود، در صورتیکه شبکه‌های عصبی مصنوعی نتایج خروجی دقیقی را ارائه می‌کنند (منهاج ۱۳۷۷). از طرفی شبکه‌های عصبی مصنوعی ابزاری کارآمد

۲- موقعیت جغرافیایی و زمین‌شناسی منطقه مورد

مطالعه

منطقه مورد مطالعه در ۴۰ کیلومتری جاده فامنین- ساوه و در مسیر بزرگراه همدان- ساوه واقع شده است (تصویر ۱). منطقه تبرک در زون ایران مرکزی قرار دارد. مهم‌ترین سازند این منطقه، سازند قم با سن اولیگومیوسن می‌باشد (آدابی ۱۳۶۶). از نظر لیتولوژیکی، این سازند در منطقه مورد مطالعه شامل کنگلومرا، ماسه سنگ، سیلستون و مارن است. سازند قم در بخش بزرگی از شرق ایران مرکزی گسترش دارد و به طور پیش‌رونده‌ای سازند سرخ پایینی و سنگ‌های قدیمی‌تر را می‌پوشاند. ارتفاعات جنوبی قم (دو چاه، دو برادر، نرداقی و ...) از جمله مناطقی هستند که در آن‌ها سازند قم گسترش قابل توجهی دارد. از منطقه قم به طرف غرب و شمال غرب، سازند قم در مناطق ساوه و همدان گسترش و ضخامت زیادی دارد، به طوری که در غرب ساوه، ضخامت این سازند به ۳۶۰۰ متر می‌رسد. همچنین در شمال همدان (آب گرم، رزن، نوبران) نهشته‌های ضخیم مارنی سازند قم، سبب شده تا نواحی مذکور به عنوان ژرف‌ترین بخش دریای قم شناخته شوند (آقاباتی ۱۳۸۵). مجموعه سنگ‌های رسوبی الیگومیوسن در منطقه مورد مطالعه شامل گستره‌ی وسیعی از واحدهای ماسه سنگی و کربناته می‌باشند (تصویر ۲) که سنگ‌های به طور کامل تحکیم یافته تا رسوب‌های سست و منفصل را در بر می‌گیرند. در برخی از برش‌های مطالعه شده، مرز زیرین سنگ‌های معادل سازند قم در منطقه مورد مطالعه را سازند سرخ زیرین با سن الیگومیوسن تشکیل می‌دهد. در برخی مکان‌ها نیز لایه‌های الیگومیوسن به صورت دگرشیب و یا گسله بر روی رسوبات قدیمی‌تر (کرتاسه و یا ژوراسیک) قرار گرفته‌اند (ساداتی و همکاران ۱۳۸۴).



تصویر ۱- موقعیت جغرافیایی و نقشه زمین شناسی منطقه تحرک (نقشه زمین شناسی ۱:۲۵۰۰۰۰ با اصلاحات)، (بلورچی و حاجیان ۱۳۵۸)
 Oc: نهشته های کنگلومرای، OMm: مارن، آهک ماسه ای و آهک مارنی، Mc: کنگلومرا و ماسه سنگ قرمز، Qt: آبرفت ها و تراس های آبرفتی، Qal:
 پادگانه های آبرفتی، OMIm: مارن، ماسه سنگ و آهک، OMI: رسوبات مارنی و آهک مارنی، Jm: سنگ های دگرگونی خفیف اسلیتی

تک محوری (UCS) و مدول الاستیسیته (E) می باشد.

تمامی این آزمایش ها مطابق با استانداردهای پیشنهادی ISRM (International Society for Rock Mechanics 1981) انجام شده اند. نتایج آزمایش ها در جدول (۱) نشان داده شده اند. در این تحقیق، از نسخه R2012a نرم افزار متلب (MATrix LABoratory MATLAB)، برای پیاده سازی شبکه های عصبی با ساختار پرسپترون چند لایه استفاده شد. این نرم افزار امکان طراحی، ساخت، یادگیری و ارزیابی شبکه های عصبی

۳- مواد و روش ها

برای تهیه مدل پیش بینی کننده قابل اعتماد، به تعداد کافی از داده های با کیفیت بالا نیاز می باشد. در نتیجه پایگاه داده با انجام یک سری آزمون های آزمایشگاهی بر روی ۸۰ مجموعه نمونه به دست آمده از کنگلومراهای منطقه تحرک تشکیل شد. هر مجموعه داده، شامل شاخص مقاومت بار نقطه ای (Is_{50})، سرعت موج (Vp)، تخلخل (n)، چگالی خشک γ_d ، درصد رطوبت (Wn)، مقاومت فشاری

مصنوعی را در اختیار قرار می دهد که در برگیرنده شبکه های مختلف می باشد. نوع شبکه نیز با توجه به زمینه ای که قرار است مدل شبکه مطابق با آن تهیه گردد، انتخاب می شود. شبکه های مورد استفاده در این تحقیق از نوع شبکه های پرسپترون چند لایه (MLP) با قانون یادگیری پس انتشار خطا (Back Propagation, BP) می باشند. برای طراحی مدل های شبکه عصبی مصنوعی (ANN) به منظور پیش بینی پارامترهای UCS و E، داده های به دست آمده (۸۰ سری داده) به سه مجموعه آموزش (train) ۷۰٪، آزمون (test) و اعتبار سنجی (Validation) هر یک به میزان ۱۵٪ تقسیم شدند. داده های اطلاعاتی به صورت تصادفی به مجموعه های آموزش و ارزیابی تقسیم شدند.

۴-۴-۱-۴

۱-۴-۱-۴ - خصوصیات ژئومکانیکی

بر اساس جدول ۱، مقادیر اندازه گیری شده UCS از ۴۷۱۵ تا ۷۲۰۸ مگاپاسکال متغیر است. مقادیر میانگین و انحراف معیار نیز به ترتیب ۵۴/۵۷ و ۹/۸ می باشند. در حالی که مقادیر اندازه گیری شده E از ۹ تا ۲۵ گیگاپاسکال تغییر می کند و مقادیر میانگین و انحراف معیار آن به ترتیب ۱۴/۶۹ و ۳/۹۵ می باشند. همچنین مقدار متوسط شاخص مقاومت بار نقطه ای و سرعت موج به ترتیب (MPa) ۴/۹۷ و (M/S) ۴۳۵۳/۴۵ می باشد. مقادیر متوسط تخلخل، چگالی خشک و درصد رطوبت نیز به

ترتیب ۲/۹۷ درصد، $2.97 \text{ (g/cm}^3)$ و ۷/۱۴ درصد می باشند.

۴-۲-۴ - رگرسیون ساده (Simple Regression, SR)

تحلیل آماری از جمله روش های رایج برای به دست آوردن مدل های پیش بینی کننده با استفاده از داده های موجود است که اغلب به دو صورت رگرسیون ساده و چند متغیره انجام می شود. در مبحث رگرسیون، هدف یافتن رابطه ای بین متغیرهای وابسته و متغیرهای مستقل می باشد. این رابطه ممکن است از نوع خطی یا غیر خطی باشد (دهقان و ستاری ۱۳۸۶). در این تحقیق برای به دست آوردن رگرسیون ساده، علاوه بر معادلات خطی $(y = ax + b)$ ، معادلات غیرخطی نیز بررسی شده اند. نتایج بهترین روابط بدست آمده بین UCS و E به عنوان پارامترهای وابسته و Is_{50} ، V_p ، n ، γ_d و W_n به عنوان پارامترهای مستقل در جدول ۲ نشان داده شده اند. بر این اساس، مقاومت فشاری تک محوری بهترین رابطه را با درصد تخلخل و با ضریب تعیین ۰/۸۱ داشته در حالی که مدول الاستیسیته بهترین رابطه را با درصد رطوبت ($R^2 = 0.70$) دارا می باشد.

۴-۳-۴ - رگرسیون چندمتغیره فطی (MLR)

بسیاری از مدل های ساده (تک متغیره) از پارامترهای Is_{50} ، V_p ، γ_d و یا از دیگر خصوصیات سنگ ها برای برآورد UCS و E استفاده

جدول ۱- نتایج بدست آمده از آزمون های آزمایشگاهی

آمار	UCS (MPa)	E (GPa)	Is_{50} (MPa)	V_p (m/s)	n (%)	γ_d (g/cm ³)	W_n (%)
حداقل	۴۷۱۵	۹	۳۵۳	۳۷۶۱/۵۳	۱/۹۵	۲/۵۱	۰/۷۷
حداکثر	۷۲۰۸	۲۵	۶/۱۱	۴۸۸۳/۱۰	۴/۷۴	۲/۶۱	۱/۷۶
میانگین	۵۴/۵۷	۱۴/۶۹	۴/۹۷	۴۳۵۳/۴۵	۲/۹۷	۲/۵۷	۱/۱۴
انحراف معیار	۹/۸	۳/۹۵	۰/۷۸	۳۰۴	۱/۱۸	۰/۰۳	۰/۴۶

جدول ۲- بهترین مدل های پیش بینی کننده مقاومت فشاری تک محوری و مدول الاستیسیته

متغیر مستقل	مدل های پیش بینی کننده UCS	R^2	مدل های پیش بینی کننده E	R^2
Is_{50}	$UCS = 8.7561 (Is_{50}) + 10.755$	۰/۵۲	$E = 3.5503 (Is_{50}) - 3.0805$	۰/۴۸
V_p	$UCS = 8E-05 (V_p)^{1.5961}$	۰/۶۵	$E = 1E-06 (V_p)^{1.9489}$	۰/۵۹
N	$UCS = -33.41 \ln(n) + 90.02$	۰/۸۱	$E = -12.22 \ln(n) + 27.649$	۰/۶۷
γ_d	$UCS = 0.0049e^{3.6231 \gamma_d}$	۰/۶۷	$E = 5E-06e^{5.7943 \gamma_d}$	۰/۵۴
W_n	$UCS = 58.007 (W_n)^{-0.638}$	۰/۷۸	$E = 15.796 (W_n)^{-0.946}$	۰/۷۰

در این تحقیق، جهت انجام رگرسیون چندمتغیره از نرم‌افزار (Statistical Package for Social Science, SPSS 21) استفاده شده است. بهترین معادلات پیشنهاد شده بر اساس روش رگرسیون چندمتغیره خطی، برای پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته در روابط ۲ و ۳ ارائه شده است.

رابطه (۲)

$$UCS = 2.750 Is_{50} + 0.007 Vp - 7.136 n + 18.546 \gamma_d - 0.692 W_n + 81.20$$

رابطه (۳)

$$E = 2084.57 Is_{50} + 0.713 Vp - 1589.66 n + 32522.75 \gamma_d - 10728.72 W_n - 68646$$

اعتبار مدل‌های ارائه شده توسط ضریب تعیین (R^2)، آزمون (t-test, t) و درجه اهمیت (sig. Level) مورد بررسی قرار گرفته است. ضریب تعیین (R^2) بین مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده یک نشانگر خوب، برای بررسی عملکرد مدل پیش‌بینی کننده می‌باشد. تصویر ۲ ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده بوسیله مدل‌های پیش‌بینی کننده را با ضریب تعیین $R^2 = 0.73$ برای مدل UCS و $R^2 = 0.85$ برای مدل E نشان می‌دهد.

مقدار زیاد ضریب رگرسیون ضرورتاً به معنای برتری مدل در پیش‌بینی نمی‌باشد. بر این اساس، بایستی با استفاده از روش‌هایی مانند آزمون t، همبستگی بین مدل و نتایج تجربی مورد ارزیابی قرار گیرند (Atici 2011). آزمون t با درجه اطمینان ۹۵٪ برای هر یک از مدل‌ها انجام شد. اگر مقدار t محاسبه شده بیشتر از مقدار آستانه


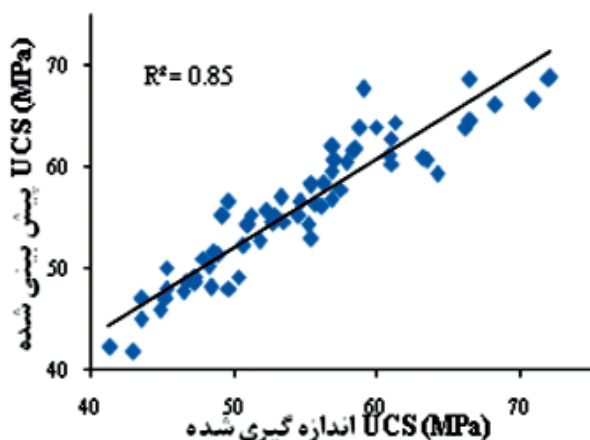
می‌کنند. استفاده از این مدل‌ها در معادن و طرح‌های کاربردی مهندسی عمران مناسب نمی‌باشد، زیرا ضریب تعیین (R^2) مدل‌های تک‌متغیره نمی‌تواند تغییرات ناشی از متغیرهای مستقل را توضیح دهد. به عبارت دیگر، این مدل‌ها کمتر قابل اعتماد می‌باشند. لذا استفاده از یک مدل رگرسیون چندمتغیره، ارزیابی دقیق‌تری را از خواص مکانیکی سنگ ارائه خواهد کرد (Dehghan et al. 2010). تجزیه و تحلیل رگرسیونی چندمتغیره، یک روش مدل‌سازی قدرتمند می‌باشد. این روش در مواردی که روابط پیچیده درگیر هستند، می‌تواند بسیار مفید واقع شود. علاوه بر این، تجزیه و تحلیل رگرسیون چندمتغیره، زمانی که بیش از یک متغیر در خواص سنگ موثر است، می‌تواند روش صحیحی باشد (Karakus et al. 2005). در به کارگیری مدل آماری مذکور در این تحقیق، رابطه بین متغیرهای مستقل و وابسته به صورت رابطه (۱) در نظر گرفته شدند.

$$Y = b_0 + b_1 X_1 + \dots + b_k X_k \quad \text{رابطه (۱)}$$

در این رابطه Y متغیر وابسته، $X_1 \dots X_k$ پارامترهای مستقل، b_0 مقدار ثابت و $b_1 \dots b_k$ ضرایب پارامترها می‌باشند. هدف از تحلیل رگرسیون، مشخص کردن پارامترهای معادله رگرسیون و مقایسه مدل با مقدار متغیر وابسته Y می‌باشد. در این مطالعه، برای ارزیابی ارتباط مقاومت فشاری تک محوری (UCS) و مدول الاستیسیته (E) با پنج مشخصه انتخاب شده سنگ (شاخص مقاومت بار نقطه‌ای، سرعت موج، تخلخل، چگالی خشک و درصد رطوبت)، دو مورد تجزیه و تحلیل MLR انجام شد. نتایج آماری مدل‌های حاصل از روش رگرسیون چندمتغیره خطی برای پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته در جدول ۳ خلاصه شده است.

جدول ۳- خلاصه آماری مدل‌های حاصل از روش رگرسیون چندمتغیره برای پیش‌بینی UCS و E

متغیر وابسته	UCS				E			
	Coefficient	St. error	t-value	Sig. level	Coefficient	St. error	t-value	Sig. level
Constant	۸۱۲۰	۵/۵۹۲	۱/۵۴۴	۰/۱۲۷	۶۸۶۴۶-	۴/۷۴۷	-۱/۴۷۰	۰/۱۴۶
Is 50	۲/۷۵۰	۰/۷۲۹	۳/۷۷۲	۰/۰۰۰	۲۰۸۴/۵۷	۶/۳۰۰	۳/۲۲۰	۰/۰۰۲
Vp	۰/۰۰۷	۰/۰۰۲	۳/۲۳۷	۰/۰۰۲	۰/۷۱۳	۱/۸۲۶	-۰/۳۹۱	۰/۶۹۷
n	۷/۱۳۶-	۲/۱۳۲	-۳/۳۴۷	۰/۰۰۱	۱۵۸۹/۶۶-	۰/۷۰۶	۰/۸۴۰	۰/۴۰۴
γ_d	۱۸/۵۴۶	۲/۸۲۸	-۰/۸۹۰	۰/۳۷۶	۳۲۵۲۲/۷۵	۱/۰۸۲	۱/۷۵۹	۰/۰۸۳
Wn	۰/۶۹۲-	۵	-۰/۱۳۸	۰/۸۹۰	-۱۰۷۲۸/۷۲	۳/۰۶۰	۲/۴۱۳-	۰/۰۱۸



تصویر ۲- نمودارهای همبستگی بین مقادیر اندازه گیری شده و پیش بینی شده UCS و E برای مدل های رگرسیون چند متغیره

جدول ۴- شاخص های کنترل عملکرد (R^2 ، MAE و RMSE)، مدل های رگرسیون چند متغیره (MLR)

پارامترهای پیش بینی شده	RMSE	MAE	R^2
UCS	۵/۱۵	۴/۲۲	۰/۸۸
E	۷/۳۶	۴/۸۷	۰/۸۶

مسائلی که برای روش های آماری مرسوم مناسب نمی باشند، می تواند مورد استفاده قرار گیرد (Aqil et al. 2007). این روش یک ابزار محاسباتی در حل مسائل مبهم و پیچیده می باشد که با استفاده از روش های ریاضی مانند معادلات دیفرانسیلی یا رگرسیون های خطی، قابل حل نمی باشند (آعاجریان و همکاران ۱۳۹۱). یک شبکه عصبی مصنوعی می تواند بوسیله سه جزء اساسی تابع انتقال، معماری شبکه و قانون یادگیری تعریف شود. تعریف این اجزا برای حل مسائل آماری ضروری می باشد (Yilmaz & Yuksek 2009). ساده ترین و معمولی ترین نوع شبکه عصبی مصنوعی که در بسیاری از علوم مهندسی و در این پژوهش استفاده گردید، شبکه های عصبی MLP همراه با ناظر می باشد. در این نوع شبکه ها، مسیرهای عملکرد شبکه، همیشه رو به جلو بوده و اجازه انتقال سیگنال تنها در یک مسیر از ورودی تا خروجی داده می شود (Khanlari et al. 2012). این شبکه ها شامل سه لایه از نرون ها می باشند. لایه ورودی برای ارائه داده ها به شبکه استفاده می شود، این لایه داده ها را از منابع مختلف دریافت می کند، از این رو تعداد نرون ها در لایه های ورودی به تعداد منابع در ورودی بستگی دارد. در این مطالعه، برای برآورد UCS و E به عنوان متغیرهای وابسته، متغیرهای مستقل n ، V_p ، Is_{50} و γ_d

باشد، معناداری آن با درجه اطمینان بیشتر از ۹۵٪ می باشد که در این حالت متغیر به صورت قابل ملاحظه ای در پیش بینی، موثر است. بررسی های انجام گرفته نشان داده است که برای مدل UCS، مقدار درجه اهمیت در مورد Is_{50} ، V_p و n کمتر از ۰/۰۵ می باشد. این امر نشان دهنده وجود ارتباط قوی با عملکرد بالای ۹۵٪ بین پارامترهای مذکور و UCS می باشد. این در حالی است که پارامترهای W_n و γ_d دارای درجه اهمیتی کمتر در مقایسه با Is_{50} ، V_p و n می باشند. در ارتباط با مدل E نیز، Is_{50} و W_n دارای درجه اهمیت کمتر از ۰/۰۵ می باشند که در مقایسه با V_p ، n و γ_d دارای ارتباط قوی تری با پارامتر E می باشند. در این مطالعه، همچنین شاخص های ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE)، با استفاده از روابط ۴ و ۵ برای کنترل قابلیت پیش بینی مدل های پیشنهادی محاسبه شده اند، که نتایج آن در جدول ۴ ارائه شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad \text{رابطه (۴)}$$


$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad \text{رابطه (۵)}$$

۱۴-۱۴- شبکه عصبی مصنوعی

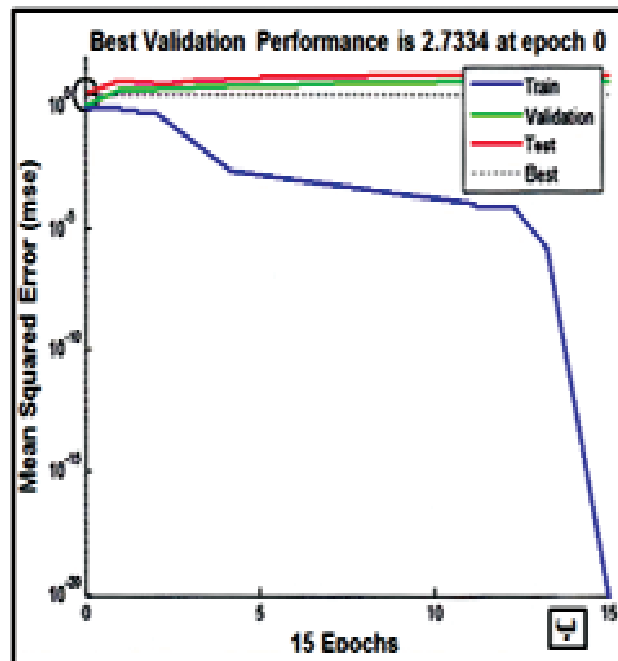
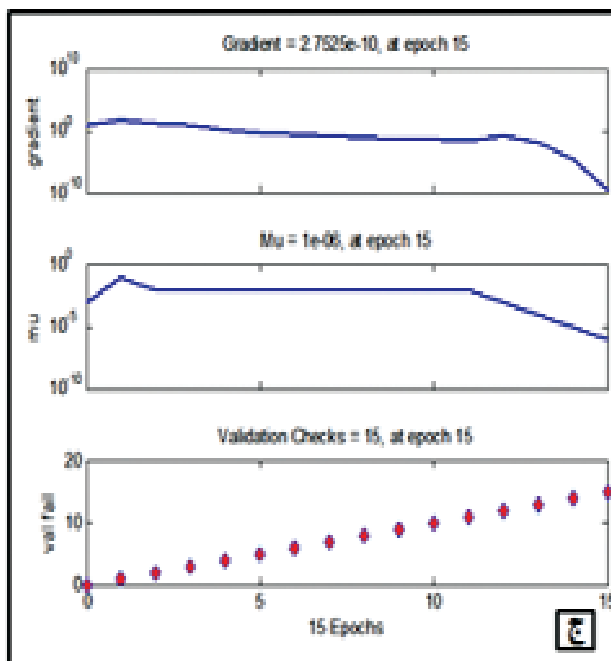
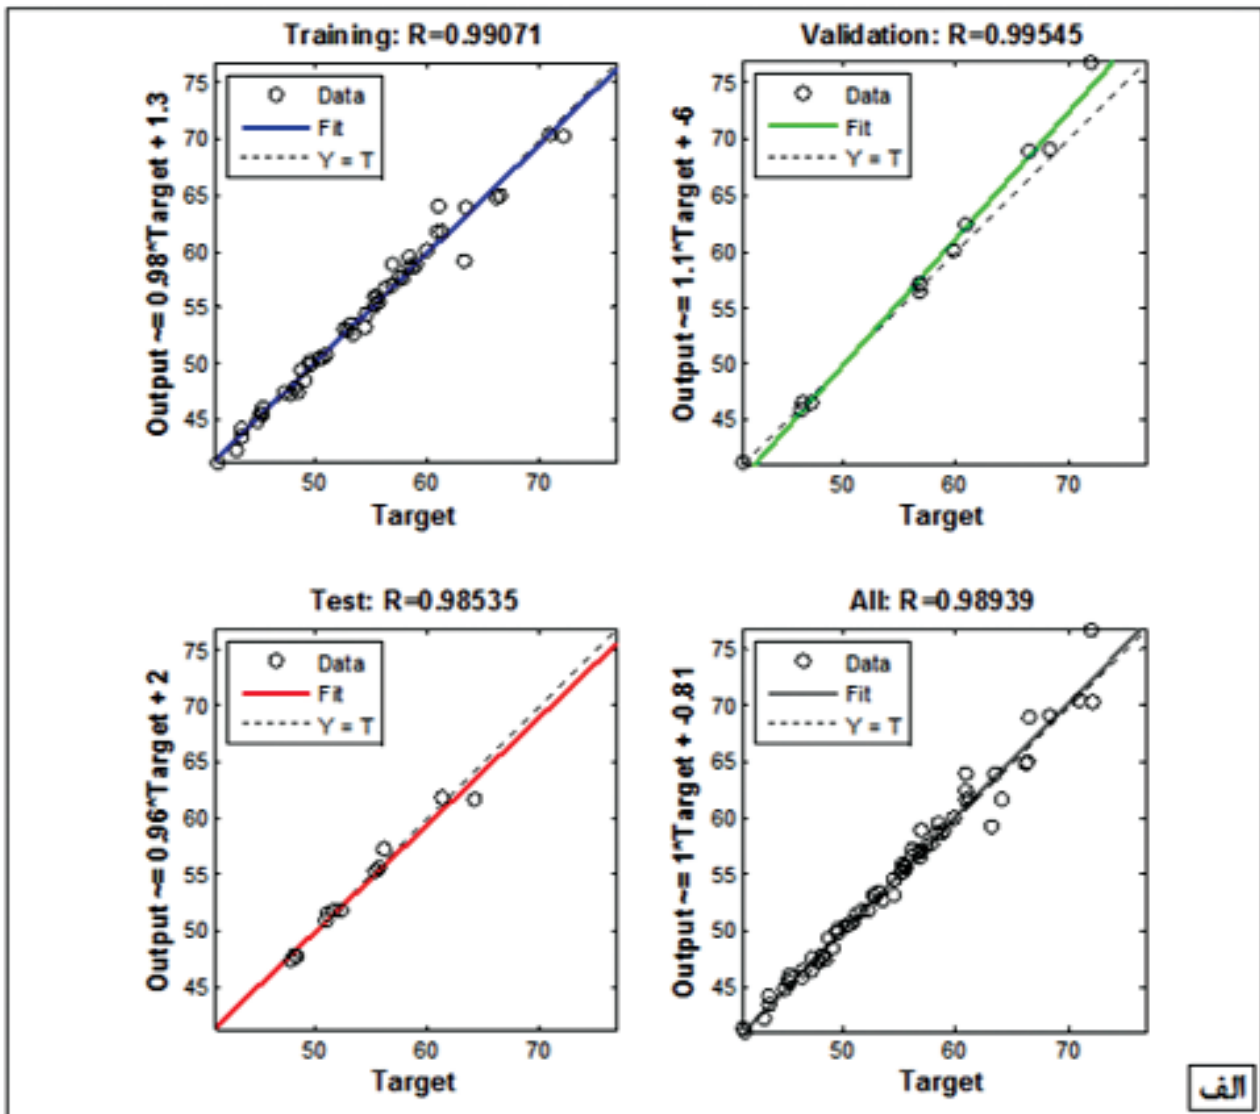
یک شبکه عصبی مصنوعی، شامل اجزای ساده ای به نام نرون است که از سیستم عصبی زیستی الهام گرفته شده است (Malinova & Guo 2004). از طرفی دیگر، شبکه عصبی یک روش آماری غیرخطی تقریباً جدید است که مهمترین ویژگی آن، توانایی یادگیری از داده های در حال پردازش است. این روش برای حل

می‌باشد، بهترین معماری برای پیش‌بینی UCS و معماری ۱-۱-۵ بهترین معماری برای پیش‌بینی E می‌باشند. توابع بسیاری وجود دارد که در انتقال اعداد از لایه قبل به لایه بعد ممکن است مورد استفاده قرار گیرند. از جمله می‌توان توابع سیگموئیدی (Sigmoid)، گوسی (Gaussian)، تانژانت هایپربولیک (Hyperbolic Tangent) و سکانت هایپربولیک (Hyperbolic Secant) را نام برد. تابع سیگموئیدی بیشترین کاربرد را در مسائل مهندسی دارد. یکی از دلایل عمده استفاده از این تابع، سادگی مشتق آن است که استفاده از روش پس‌انتشار خطا را ساده می‌کند. در این مطالعه پس از انتخاب معماری شبکه عصبی، توابع انتقال نرون‌های لایه پنهان و خروجی تعیین شدند. بدین منظور برای شبکه‌های عصبی با ساختارهای یاد شده، حالت‌های مختلفی برای توابع انتقال نرون‌های لایه پنهان و خروجی در نظر گرفته شد. در ادامه مشاهده شد که استفاده از تابع تانژانت سیگموئید (Tan-Sigmoid Transfer Function, TANSIG) در مدل شبکه UCS و تابع لوگ سیگموئید (Log_Sigmoid Transfer Function, LOGSIG) در مدل شبکه E، برای لایه پنهان و تابع خطی (Linear Transfer Function, PURELIN) برای لایه خروجی، در هر دو مدل به کمترین خطا منتهی می‌گردد. این توابع مقادیر وزن‌ها و بایاس را بر اساس الگوریتم پس‌انتشار خطا اصلاح می‌کنند. جزئیات بهترین مدل‌های شبکه عصبی مصنوعی به منظور پیش‌بینی UCS و E در جدول ۵ ارائه شده است. در ارتباط با هر دو مدل، همبستگی بین مقادیر تخمین زده شده و اندازه‌گیری به عمل آمده، نسبتاً قوی می‌باشد (تصاویر ۴ الف و ۵ الف).

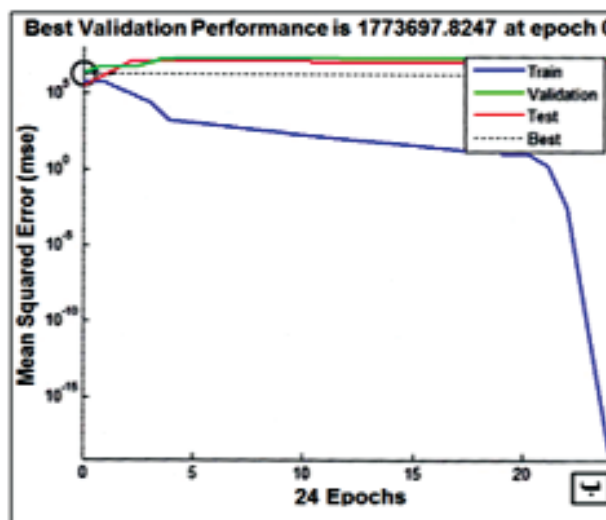
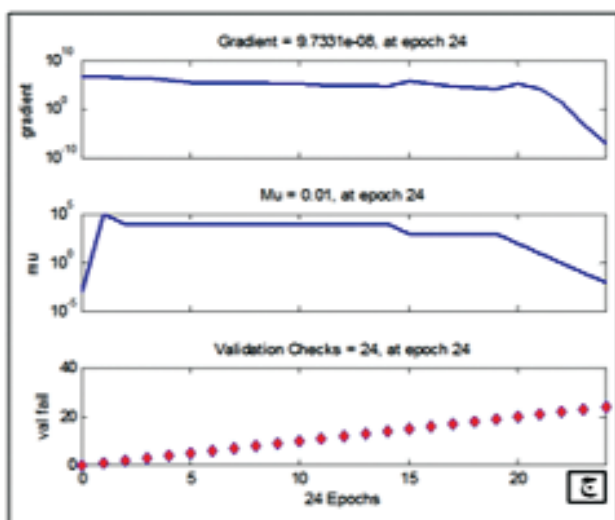
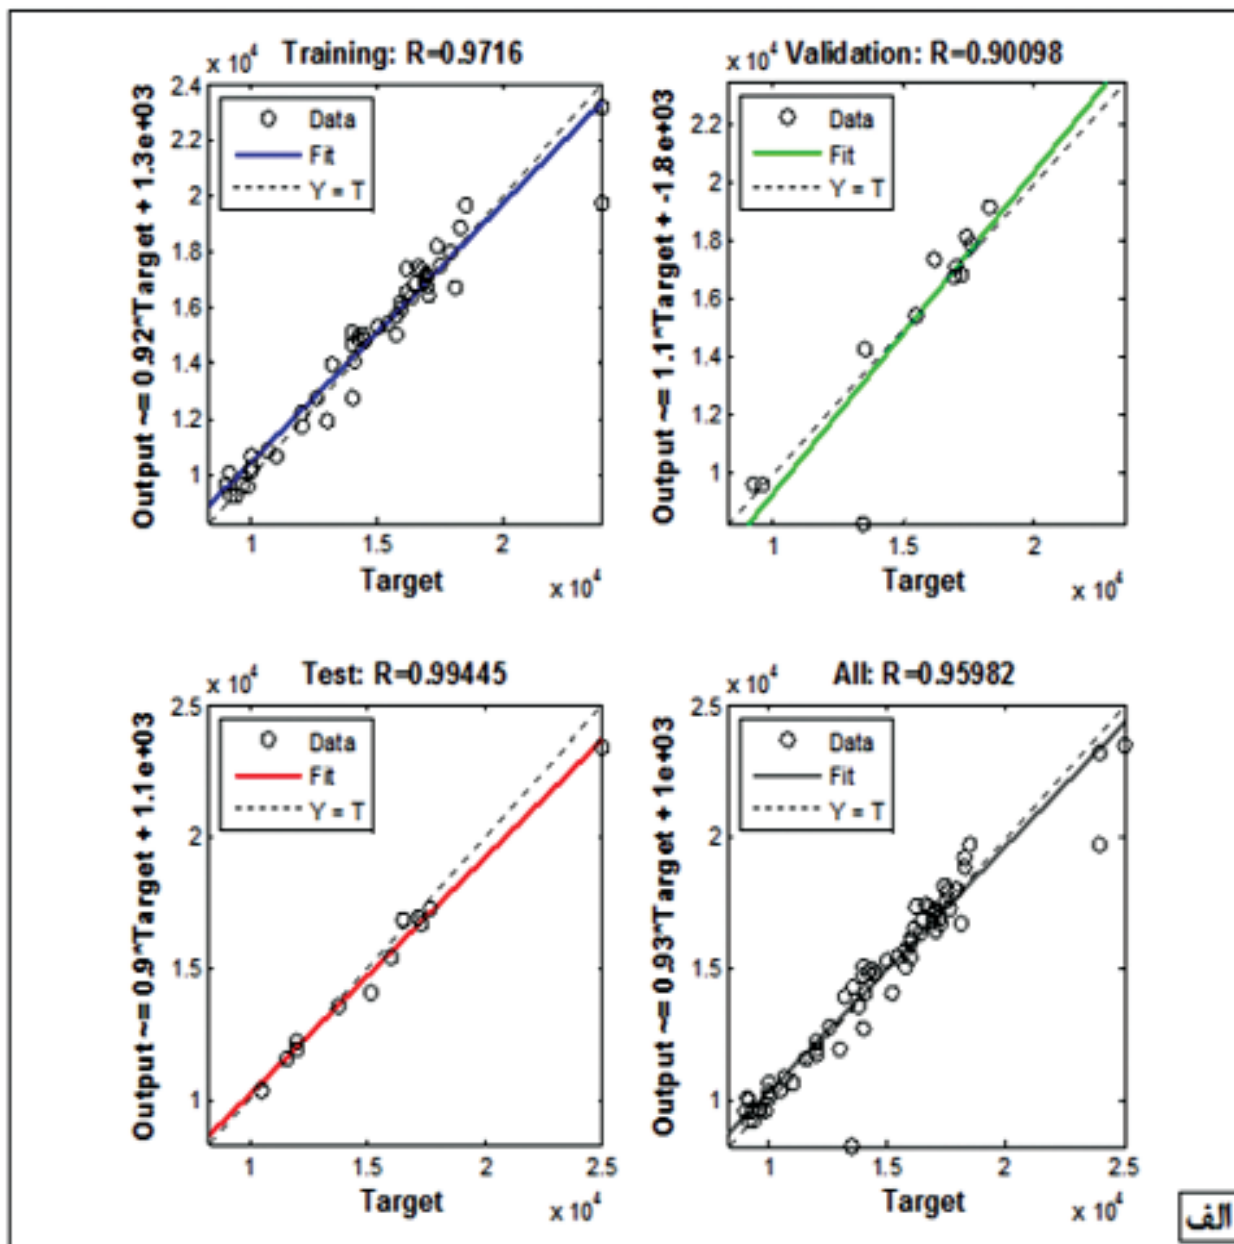
به عنوان ورودی شبکه به کار گرفته شده‌اند. معماری شبکه عصبی پرسپترون چند لایه پیش‌خور (MLP) مورد استفاده در این مطالعه به منظور پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته، به صورت شماتیک در تصویر ۳ نشان داده شده است. در الگوریتم‌های شبکه‌های عصبی مصنوعی، ساخت و ساز معماری شبکه، به یک تعداد بهینه‌ای از لایه‌های پنهان بین لایه‌های ورودی و خروجی و به تعداد بهینه‌ای از نرون‌ها در هر لایه نیاز دارد، بنحویکه این امر یکی از مهمترین و دشوارترین بخش‌های طراحی شبکه است، زیرا هیچ تئوری واحد و یکپارچه‌ای برای معماری بهینه وجود ندارد (Shahin et al. 2001; Gullu & Ercelebi 2007; 2008). تعداد لایه‌های مخفی و نرون‌های آن اغلب با روش آزمون و خطا تعیین می‌شوند (Kanungo et al. 2006). در این مطالعه، با توجه به متغیرهای ورودی و خروجی و پیچیدگی مساله، تعداد سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) برای هر دو مدل پیش‌بینی کننده UCS و E انتخاب شدند. تعداد نرون‌ها برای لایه ورودی برای هر دو مدل UCS و E برابر با تعداد متغیرهای ورودی یعنی ۵ نرون در نظر گرفته شده است. به منظور تعیین تعداد مناسب نرون لایه پنهانی، شبکه‌های مختلف با تعداد متفاوت نرون در لایه پنهانی طراحی گردیده و مشاهده شد که به ازای تعداد ۱۵ نرون برای مدل UCS و ۱۰ نرون برای مدل E در لایه پنهانی، R^2 دارای بیشترین مقدار و RMSE و MAE کمترین مقدار می‌باشند. بنابراین در شبکه‌های طراحی شده، معماری ۱-۱۵-۵ که به ترتیب دارای ۵ نرون در لایه ورودی، ۱۵ نرون در لایه پنهان و ۱ نرون در لایه خروجی



تصویر ۳- معماری شبکه عصبی پرسپترون چند لایه پیش‌خور (MLP) ساخته شده برای پیش‌بینی UCS و E



تصویر ۴- نتایج مدل UCS در ۱۵ دوره تکرار، الف) ضرایب رگرسیون شبکه، ب) خطای مجموع مربعات شبکه، ج) مراحل آموزش شبکه



تصویر ۵- نتایج مدل E در ۲۴ دوره تکرار، الف) ضرایب رگرسیون شبکه، ب) خطای مجموع مربعات شبکه، ج) مراحل آموزش شبکه

جدول ۵- مشخصات مدل های شبکه عصبی تهیه شده به منظور پیش بینی UCS و E

متغیر وابسته	مدل عصبی	تابع انتقال	قانون یادگیری	معماری شبکه	آموزش شبکه	اعتبار شبکه	آزمون شبکه	مدل شبکه	RMSE	MAE
UCS	MLP	TANSIG	LM	۱-۱۵-۱	۰/۹۸	۰/۹۸	۰/۹۷	۰/۹۷	۳/۲	۱/۸۹
E	MLP	LOGSIG	LM	۵-۱۰-۱	۰/۹۴	۰/۸۱	۰/۹۸	۰/۹۰	۴/۴۷	۳/۱۲

LM: قانون یادگیری لورنبرگ-مارکواریت

۴-۵- مقایسه عملکرد مدل های ANN با مدل های MLR

برای پیش بینی UCS و E

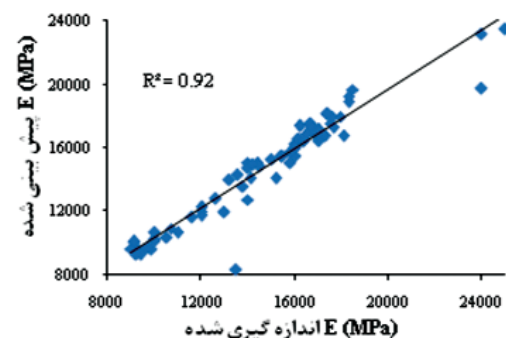

در این مطالعه، عملکرد مدل های طراحی شده بوسیله روش های شبکه عصبی مصنوعی (ANN) و رگرسیون چندمتغیره خطی (MLR)، با استفاده از شاخص های آماری ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) با یکدیگر مورد مقایسه قرار گرفتند که نتایج آن در جدول ۷ و تصویر ۷ ارائه شده است. بر این اساس، شاخص R^2 حاصل از مدل های ANN، با مقادیر ۰/۹۷ برای UCS و ۰/۹۰ برای E، بزرگتر از ضرایب همبستگی بدست آمده از روش MLR، با مقادیر ۰/۸۸ برای UCS و ۰/۸۶ برای E می باشد. از طرفی، شاخص MAE، حاصل از روش شبکه عصبی با مقادیر ۱/۸۹ برای UCS و ۳/۱۲ برای E، کوچکتر از مقادیر به دست آمده این پارامتر، از روش رگرسیون چند متغیره، با مقادیر ۴/۲۲ برای UCS و ۴/۸۷ برای E می باشد. همچنین، شاخص RMSE، حاصل از روش شبکه عصبی با مقادیر ۳/۲۲ برای UCS و ۴/۴۷ برای E، کوچکتر از مقادیر به دست آمده این پارامتر از روش رگرسیون چندمتغیره، با مقادیر ۵/۱۵ برای UCS و ۷/۳۶ برای E می باشد. نتایج به دست آمده حاکی از آن است که

بر اساس تصاویر ۴ ب و ج و ۵ ب و ج، شبکه برای برآورد مقاومت فشاری تک محوری در ۱۵ دوره و برای برآورد مدول الاستیسیته در ۲۴ دوره تکرار، به جواب مطلوب حاصل از آموزش شبکه رسیده است. همبستگی میان مقادیر اندازه گیری شده و پیش بینی شده نشان می دهد که مدل های شبکه عصبی مصنوعی طراحی شده برای پیش بینی مقاومت فشاری تک محوری (UCS) و مدول الاستیسیته (E) بسیار قابل قبول می باشند (تصویر ۶). به طوری که ضریب تعیین (R^2) جهت ارزیابی عملکرد مدل ها، برای مدل UCS برابر ۰/۹۸ و برای مدل E برابر ۰/۹۲ می باشد، که این امر به خوبی عملکرد شبکه را تایید می نماید.

عملکرد شبکه با مقایسه مقادیر اندازه گیری شده و مقادیر پیش بینی شده حاصل از شبکه، با استفاده از شاخص های آماری R^2 ، RMSE و MAE مورد ارزیابی قرار گرفت. به طور کلی، در صورتی که مقادیر R^2 ، RMSE و MAE به ترتیب به مقادیر ۱، ۰ و ۰ نزدیکتر باشند، پیش بینی شبکه مطلوب تر ارزیابی می گردد. مقادیر R^2 ، RMSE و MAE برای هر دو شبکه در جدول ۶ ارائه شده اند.

جدول ۶- شاخص های کنترل عملکرد (R^2 ، MAE و RMSE)، مدل های شبکه عصبی

پارامترهای پیش بینی شده	RMSE	MAE	R^2
UCS	۳/۲	۱/۸۹	۰/۹۷
E	۴/۴۷	۳/۱۲	۰/۹۰



تصویر ۶- نمودارهای همبستگی بین مقادیر اندازه گیری شده و پیش بینی شده UCS و E مدل های شبکه عصبی مصنوعی

۵- نتیجه گیری

بر اساس نتایج این پژوهش، با استفاده از تحلیل رگرسیون ساده، درصد تخلخل و رطوبت بهترین ارتباط را با UCS و E نشان می‌دهند. با این وجود در مقایسه با رگرسیون چندمتغیره، ضرایب تعیین به دست آمده به مراتب پایین تر می‌باشد.

مدل‌های ارائه شده در روش رگرسیون چندمتغیره نشان می‌دهد که این روش، عملکرد نسبتاً قابل قبولی برای پیش‌بینی UCS و E به ترتیب با ضرایب تعیین $R^2 = 0/86$ و $R^2 = 0/88$ دارد.

بهترین مدل پیشنهادی برای پیش‌بینی UCS، مدل با شبکه پرسپترون چند لایه، تابع فعال سازی تانژانت سیگموئید برای لایه پنهان، تابع خطی برای لایه خروجی، قانون آموزش پس انتشار خطا (الگوریتم پس انتشار مارکوارت-لورنبرگ (LM)) با معماری ۱-۱۵-۵ می‌باشد.

این مدل، مقادیر UCS را با $R^2 = 0/97$ ، $RMSE = 3/2$ و MAE = 1/89 را پیش‌بینی می‌نماید.


بهترین مدل پیشنهادی برای پیش‌بینی E، مدل با شبکه پرسپترون چند لایه، تابع فعال سازی لوگ سیگموئید برای لایه پنهان، تابع خطی برای لایه خروجی، قانون آموزش پس انتشار خطا (الگوریتم پس انتشار مارکوارت-لورنبرگ (LM)) با معماری ۱-۱۰-۵ می‌باشد. این مدل E را با $R^2 = 0/90$ ، $RMSE = 4/47$ و MAE = 3/12 پیش‌بینی می‌نماید.

بطور کلی مقادیر R^2 مدل‌های شبکه عصبی بزرگ‌تر از مقادیر R^2 مدل‌های رگرسیون چندمتغیره می‌باشند، همچنین مقادیر RMSE و MAE مدل‌های شبکه عصبی کوچکتر از مقادیر این شاخص‌ها برای مدل‌های رگرسیون چندمتغیره می‌باشند. این امر نشان دهنده کارایی بالاتر مدل‌های شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیون چندمتغیره در پیش‌بینی UCS و E می‌باشد.

قابلیت روش شبکه عصبی مصنوعی (ANN)، در پیش‌بینی مقاومت فشاری تک محوری (UCS) و مدول الاستیسیته (E) به مراتب بالاتر و قابل اعتمادتر از روش رگرسیون چندمتغیره خطی (MLR) است.

جدول ۷- مقادیر شاخص‌های کنترل عملکرد مدل‌های شبکه عصبی و رگرسیون چندمتغیره

مدل‌های شبکه	R^2		RMSE		MAE	
	MLR	ANN	MLR	ANN	MLR	ANN
UCS	0/88	0/97	5/15	3/22	4/22	1/89
E	0/86	0/90	7/36	4/47	4/87	3/12



تصویر ۷- مقایسه مقادیر R^2 ، MAE و RMSE برای مدل‌های MLR و ANN

مراجع

- آدابی، م.ح، ۱۳۶۶. سنگ‌های رسوبی شیمیایی- بیوشیمیایی. انتشارات آستان قدس رضوی، ۳۴۴ص.
- آغاچریان، م.، کمالی، م.ر.، کدخدایی، ع.، فتح‌اللهی، ص.، ۱۳۹۱. تخمین تراوایی و تخلخل مؤثر و تعیین واحدهای جریان هیدرولیکی با استفاده از شبکه‌ی عصبی مصنوعی در میدان نفتی مارون. فصلنامه زمین‌شناسی کاربردی دانشگاه آزاد، سال ۸ (۳)، ۲۰۲-۱۹۳.
- آقاباتی، س.ع، ۱۳۸۵. زمین‌شناسی ایران. سازمان زمین‌شناسی و اکتشافات معدنی کشور. چاپ دوم، ۵۸۶ص.

42.323.

Khanlari, G.R., Heidari, M., Momeni, A.A., Abdilor, Y., 2012. Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *Engineering Geology, Vol. 131-132: 11-18.*

Maity, D., A. Saha, 2004. Damage assessment in structure from changes in static parameters using neural networks. *Sadhana, Vol. 29(3): 315-327.*

Malinova, T., Guo, Z.X., 2004. Artificial neural network modeling of hydrogen storage properties of Mg-based Alloys. *Materials Science and Engineering A, Vol. 365: 219-227.*

Maulenkamp, F., M.A. Grima, 1999. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip Hardness. *International Journal of Rock Mechanics and Mining Sciences, Vol. 36: 29-39.*

Mishra, D.A., Basu, A., 2013. Estimation of uniaxial compressive strength of rock materials by indextests using regression analysis and fuzzy inference system. *Engineering Geology, Vol. 160: 54-68.*

Rabbani, E., Sharif, F., Koolivand Salooki, M., Moradzadeh, A., 2010. Application of neural network technique for prediction of uniaxial compressive strength using reservoir formation properties. *International Journal of Rock Mechanics & Mining Sciences, Vol. 56: 100-111.*

Shahin, M.A., Jaksa, M.B., Maier H.R., 2001. Artificial neural network applications in geotechnical engineering. *Australian Geomechanics, Vol. 36 (1): 49-62.*

Singh, V.K., D Singh, T.N. Singh, 2001. Prediction of strength properties of some schistose rock. *International Journal of Rock Mechanics and Mining Sciences Vol. 38 (2). 269-284.*

Singh, T.N., R. Kanchan, K. Saigal, A.K. Verma, 2004. Prediction of P-wave velocity and anisotropic properties of rock using Artificial Neural Networks technique. *J Sci Ind Res, Vol. 63 (1): 32-38.*

Tiryaki, B., 2008. Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees. *Engineering Geology, Vol. 99: 51-60.*

Yang, Y., Q. Zhang, 1997. Analysis for the result of point load testing with artificial neural network. In: Proceedings of Computer Methods and Advances in Geomechanics. *China, pp. 607-612.*

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 & Mining Sciences, Vol. 62: 113-122.*

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 & Mining Sciences, Vol. 46: 803-810.*

Zorlu, K., Gokceoglu, C., Ocakoglu, F., Nefeslioglu, H.A., Acikalin, S. 2008. Prediction of uniaxial compressive strength of sandstones using petrography-based model. *Engineering Geology, Vol. 96: 141-158.*

بلورچی، م.ح، حاجیان، ج، ۱۳۵۸. نقشه زمین شناسی کبودآهنگ، مقیاس ۱:۲۵۰۰۰. سازمان زمین شناسی و اکتشافات معدنی کشور.

دهقان، س. ستاری، ق، ۱۳۸۶. تخمین مقاومت تراکمی تک محوری سنگ تراورتن محلات با استفاده از تلیخل و شاخص بار نقطه‌ای. فصلنامه زمین شناسی کاربردی دانشگاه آزاد، سال ۳ (۴): ۹۰-۷۷.

ساداتی، س. م.، خدابخش، س.، محسنی، ح.، ۱۳۸۴. واحدهای سنگی الیگومیوسن در شمال رزن سنندج- سیرجان: مطالعه موردی در شرق و شمال شرق همدان. مجله علوم دانشگاه بوعلی، جلد ۲، شماره ۱، ص ۱۴-۲۲.

کیانپور، م.، ارومیه‌ای، ع.، نیکودل، م. ر.، ۱۳۹۰. بررسی روش‌های غیر مستقیم تخمین مقاومت تراکمی تک محوری شیل‌های سازند شمشک. فصلنامه زمین شناسی کاربردی دانشگاه آزاد، سال ۷ (۱): ۹۰-۷۷.

منهاج، م. ب.، ۱۳۷۷. مبانی شبکه‌های و عصبی هوش محاسباتی. انتشارات دانشگاه صنعتی امیر کبیر، جلد اول. ۵۰۲ صفحه.

Agil, M., Kita, I., Yano, A., Nishiyama, S., 2007. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *Journal of Hydrology, Vol. 337: 22-34.*

Atici, U., 2011. Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network. *Expert Systems with Applications, Vol. 38: 9609-9618.*

Ceryan, N., Okkan, U., Kesimal, A., 2013. Prediction of unconfined compressive strength of carbonate rocks using artificial neural networks. *Environ Earth Sci, Vol. 68: 807-819.*

Dehghan, S., Sattari, Gh., S. Chehrehchelghani, M.A. Aliabadi, 2010. Prediction of uniaxial compressive strength and modulus of elasticity for Travertine Samples using regression and artificial neural network. *Mining Science and Technology, Vol. 20: 0041-0046.*

Gullu, H., Ercelebi, E., 2007. A neural network approach for attenuation relationships: an application using strong ground motion data from Turkey. *Engineering Geology, Vol. 93: 65-81.*

Gullu, H., Ercelebi, E., 2008. Reply to discussion by H. Sonmez and C. Gokceoglu an .A neural network approach for attenuation relationships: An application using strong ground motion data from Turkey "by H. Gullu, and E. Ercelebi", *Eng. Geol 93, 65-81. Engineering Geology, Vol. 97: 94-96.*

ISRM, 1981. The Complete ISRM Suggested Methods for Rock Characterization, Testing and Monitoring. *edited by Brown, Pergamon Press.*

Kanungo, D.P., Arora, M.K., Sarkar, S., Gupta, R.P., 2006. A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas. *Engineering Geology, Vol. 85: 347-366*

Karakus, M., M. Kumral, O. Kilic, 2005. Predicting elastic properties of intact rocks from index tests using multiple regression modeling. *Int J Rock Mech Min Sci*