Archive of SID

نشریه زمین شناسی ژئوتکنیک
سال ۱۰ (۱۳۹۳)، شماره۱: ۴۶-۳۵
WWW.appliedgeology.ir

تخمین مقاومت فشاری تک‌محوری و مدول الاستیسیته نمونه‌های کنگلومرا با استفاده از رگرسیون و شبکه عصبی مصنوعی

مجتبی حیدری*[۱]، بهروز رفیعی[۱]، مهران نوری[۱]، غلامرضا خانلری[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: ۹۲/۸/۲۸؛دریافت اصلاح شده: ۹۳/۲/۲۰؛پذیرش: ۹۳/۳/۶؛قابل دسترس در تارنما: ۹۴/۸/۳۰

چکیده

تعیین دقیق برخی از خواص مکانیکی سنگ‌ها، مانند مقاومت فشاری تک‌محوری (Uniaxial Compressive Strength, UCS) و مدول الاستیسیته (E)، به زمان و هزینه قابل توجهی برای جمع‌آوری و آماده‌سازی نمونه‌های مناسب و آزمون‌های آزمایشگاهی نیاز دارد. UCS و E از جمله مهمترین خواص سنگ‌ها می‌باشند که تعیین آنها برای مطالعات مهندسی سنگ در بسیاری از پروژه‌های معدنی و مهندسی عمران ضروری می‌باشد. بنابراین برای به حداقل رساندن زمان و هزینه می‌توان از روابط تجربی که به طور گسترده‌ای برای برآورد خواص پیچیده سنگ‌ها از داده‌های حاصل از روش‌های آسان بهره می‌گیرد، استفاده نمود. هدف از این مطالعه، بررسی روش‌های شبکه عصبی مصنوعی (Artificial Neural Network, ANN) و رگرسیون چندمتغیره خطی (Multiple linear regression, MLR) به‌منظور برآورد UCS و E می‌باشد. در این پژوهش متغیرهای مستقل شاخص مقاومت بار نقطه‌ای (Point Load Strength Index, Is (50))، سرعت موج (Pressure wave velocity, Vp)، تخلخل (n)، چگالی و درصد γ_d رطوبت (water content, Wn) به عنوان پارامترهای ورودی به منظور پیش‌بینی متغیرهای وابسته (UCS و E) در هر دو روش استفاده شدند. روش MLR، UCS و E را به ترتیب با ضرایب تعیین R^2=۰/۸۵ و R^2=۰/۷۳ پیش‌بینی نموده است. استفاده از شبکه عصبی پرسپترون چند لایه (Multilayer Perceptron , MLP)، ضرایب تعیین را تا سطح قابل قبولی (R^2=۰/۹۸ برای UCS و R^2=۰/۹۲ برای E) بهبود بخشید. در این مطالعه، علاوه بر ضریب تعیین (R^2)، شاخص‌های ریشه میانگین مربعات خطا (Root Mean Square Error, RMSE) و میانگین قدر مطلق خطا (Mean Absolute Error, MAE)، برای ارزیابی قابلیت پیش‌بینی، مدل‌های ANN و MLR پیشنهادی نیز محاسبه شدند. نتایج این مطالعه نشان داد که روش ANN، عملکرد بهتری در پیش‌بینی UCS و E نسبت به روش MLR دارد.

واژه‌های کلیدی: مقاومت فشاری تک‌محوری، مدول الاستیسیته، کنگلومرا، رگرسیون چندمتغیره خطی، شبکه عصبی

www.SID.ir

Archive of SID

۱- مقدمه

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 تک‌محوری 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 خردشده، پیش‌بینی مقاومت فشاری تک‌محوری 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)، (Yesiloglu et al. 2013)، (Ceryan 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)، (Maulenkamp & Grima1999) و (Yang & Zhang 1997). 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 برای مدل‌سازی سیستم‌های غیرخطی می‌باشند. هدف این پژوهش پیش‌بینی مقاومت فشاری تک‌محوری UCS و مدول الاستیسیته (E)، کنگلومراهای سازند منطقه تجرک 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.

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 تجرک 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، سیلتستون و مارن است. سازند قم در بخش بزرگی از شرق ایران مرکزی گسترش دارد و به طور پیش رونده‌ای 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 (آقانباتی 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 تحکیم‌یافته 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).

www.SID.ir

Archive of SID

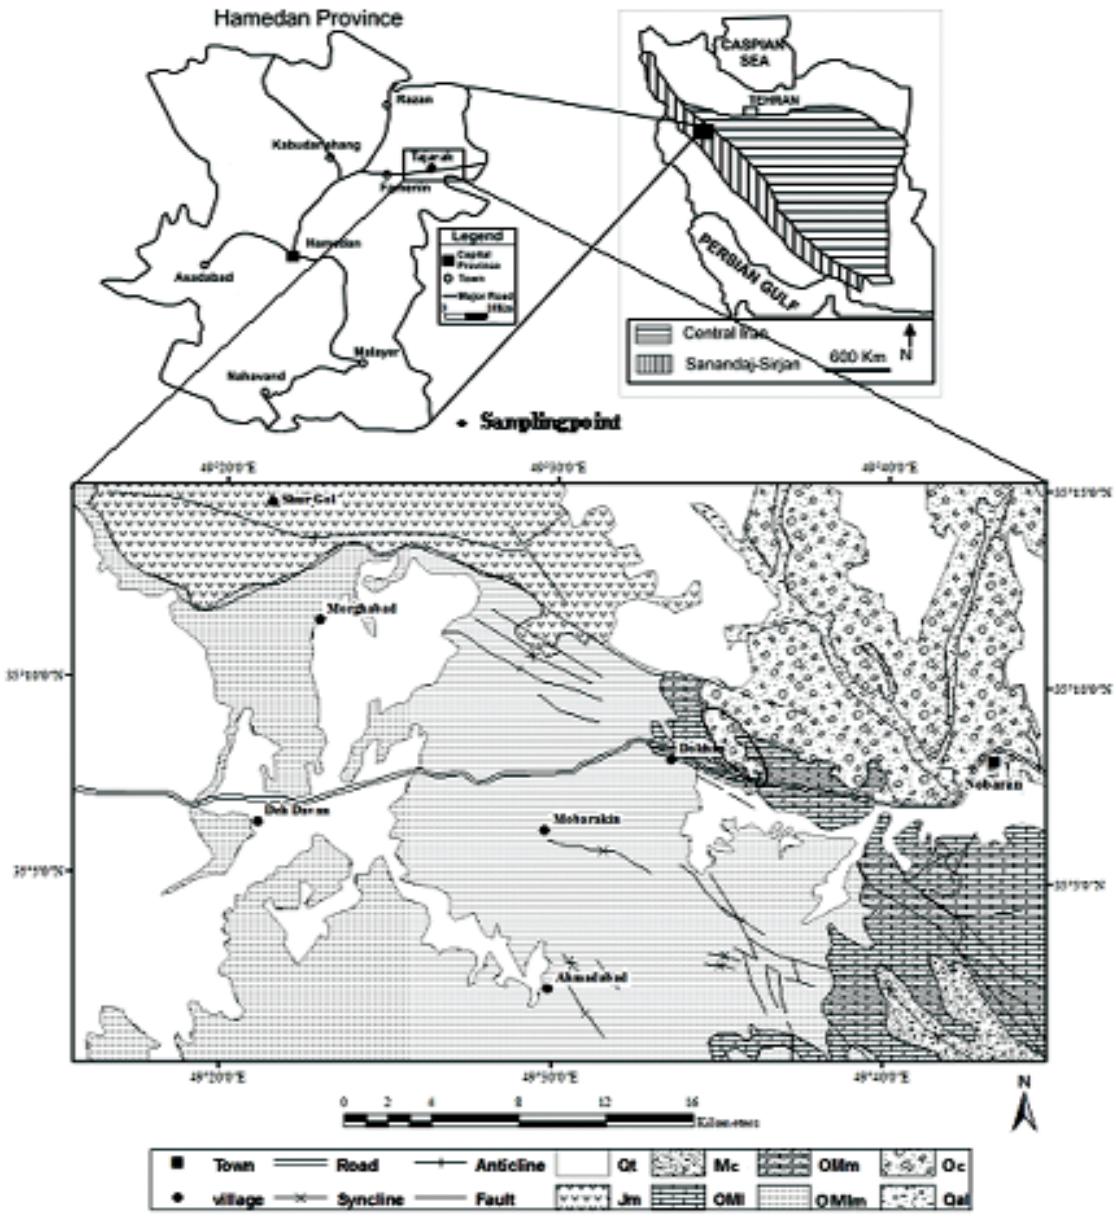

تصویر۱- موقعیت جغرافیایی و نقشه زمین شناسی منطقه تجرک (نقشه زمین شناسی ۱:۲۵۰۰۰۰ با اصلاحات)، (بلورچی و حاجیان ۱۳۵۸)

Oc: نهشته‌های کنگلومرایی، OMm: مارن، آهک ماسه‌ای و آهک مارنی، Mc: کنگلومرا و ماسه سنگ قرمز، Qt: آبرفت‌ها و تراس‌های آبرفتی، Qal: پادگانه‌های آبرفتی، OMlm: مارن، ماسه سنگ و آهک، OMl: رسوبات مارنی و آهک مارنی، Jm: سنگ‌های دگرگونی خفیف اسلیتی

۳- مواد و روش‌ها

برای تهیه مدل پیش بینی کننده قابل اعتماد، به تعداد کافی از داده‌های با کیفیت بالا نیاز می‌باشد. در نتیجه پایگاه داده با انجام یک سری آزمون‌های آزمایشگاهی بر روی ۸۰ مجموعه نمونه به‌دست آمده از کنگلومراهای منطقه تجرک تشکیل شد. هر مجموعه داده، شامل شاخص مقاومت بار نقطه‌ای (Is_{50})، سرعت موج (Vp)، تخلخل (n)، چگالی خشک γ_d، درصد رطوبت (Wn)، مقاومت فشاری تک‌محوری (UCS) و مدول الاستیسیته (E) می باشد.

تمامی این آزمایش‌ها مطابق با استانداردهای پیشنهادی ISRM (International Society for Rock Mechanics 1981) انجام شده‌اند. نتایج آزمایش‌ها در جدول (۱) نشان داده شده‌اند. در این تحقیق، از نسخه R2012a نرم‌افزار متلب (MATrix LABoratory MATLAB)، برای پیاده‌سازی شبکه‌های عصبی با ساختار پرسپترون چند لایه استفاده شد. این نرم‌افزار امکان طراحی، ساخت، یادگیری و ارزیابی شبکه‌های عصبی

www.SID.ir

Archive of SID

مصنوعی را در اختیار قرار می دهد که در برگیرنده شبکه های مختلف می باشد. نوع شبکه نیز با توجه به زمینه‌ای 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) هریک به میزان ۱۵٪ تقسیم شدند. داده های اطلاعاتی به صورت تصادفی به مجموعه های آموزش و ارزیابی تقسیم شدند.

۴- بحث

۴-۱- خصوصیات ژئومکانیکی

بر اساس جدول ۱، مقادیر اندازه‌گیری شده UCS از ۴۱/۱۵ تا ۷۲/۰۸ 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 نقطه‌ای و سرعت موج به ترتیب (MPa) ۴/۹۷ و ۴۳۵۳/۴۵ (M/S) می باشد. مقادیر متوسط تخلخل، چگالی خشک و درصد رطوبت نیز به ترتیب ۲/۹۷ درصد، (g/cm3) ۲/۵۷ و ۱/۱۴ درصد می باشند.

۴-۲- 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 می‌شود. در مبحث رگرسیون، هدف یافتن رابطه‌ای 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 شده‌اند. نتایج بهترین روابط بدست آمده بین E و UCS به عنوان پارامترهای وابسته و Is_{50}، Vp، n، γ_d و Wn به عنوان پارامترهای مستقل در جدول ۲ نشان داده شده‌اند. بر این اساس، مقاومت فشاری تک‌محوری 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=۰/۷۰) دارا می باشد.

۴-۳- رگرسیون چندمتغیره خطی (MLR)

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

جدول ۱- نتایج بدست آمده از آزمون‌های آزمایشگاهی

آمار	UCS (MPa)	E (GPa)	Is_{50} (MPa)	Vp (m/s)	n (%)	γ_d (g/cm ^{3})	Wn (%)
حداقل	۴۱/۱۵	۹	۳/۵۳	۳۷۶۱/۵۳	۱/۹۵	۲/۵۱	۰/۷۷
حداکثر	۷۲/۰۸	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 مدل‌های پیش بینی کننده مقاومت فشاری تک‌محوری و مدول الاستیسیته

متغیر مستقل	مدل‌های پیش بینی کننده UCS	R^2	مدل‌های 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
Vp	$UCS = 8E\text{-}05 (Vp)^{1.5961}$	۰/۶۵	$E = 1E\text{-}06 (Vp)^{1.9489}$	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	$E = 5E\text{-}06e^{5.7943\gamma_d}$	۰/۵۴
Wn	$UCS = 58.007 (Wn)^{-0.638}$	۰/۷۸	$E = 15.796 (Wn)^{-0.946}$	۰/۷۰

www.SID.ir

Archive of SID

می‌کنند. استفاده از این مدل‌ها در معادن و طرح‌های کاربردی مهندسی عمران مناسب نمی‌باشد، زیرا ضریب تعیین (R^2) مدل های 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 چند متغیره، یک روش مدل سازی قدرتمند می‌باشد. این روش در مواردی که روابط پیچیده درگیر هستند، می‌تواند بسیار مفید واقع شود. علاوه بر این، تجزیه وتحلیل 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.

رابطه(1)
$$Y = b_0 + b_1X + ... + b_kX_k$$

در این رابطه Y متغیر وابسته، X_1 ... X_k پارامترهای مستقل، b_0 مقدار ثابت و $b_1...b_k$ 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 تک‌محوری (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 چند متغیره خطی برای پیش‌بینی مقاومت فشاری تک محوری و مدول الاستیسیته در جدول ۳ خلاصه شده است.

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

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 = ۰/۸۵ برای مدل UCS و R^2 = ۰/۷۳ را برای مدل E نشان می‌دهد.

مقدار زیاد ضریب رگرسیون ضرورتا 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 هریک از مدل‌ها انجام شد. اگر مقدار t محاسبه شده بیشتر از مقدار آستانه

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	۸۱/۲۰	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	/۰۸۲	۱/۷۵۹	۰/۰۸۳
Wn	۰/۶۹۲-	۵	-۰/۱۳۸	۰/۸۹۰	-۱۰۷۲۸/۷۲	۳/۰۶۰	۲/۴۱۳-	۰/۰۱۸

www.SID.ir

Archive of SID

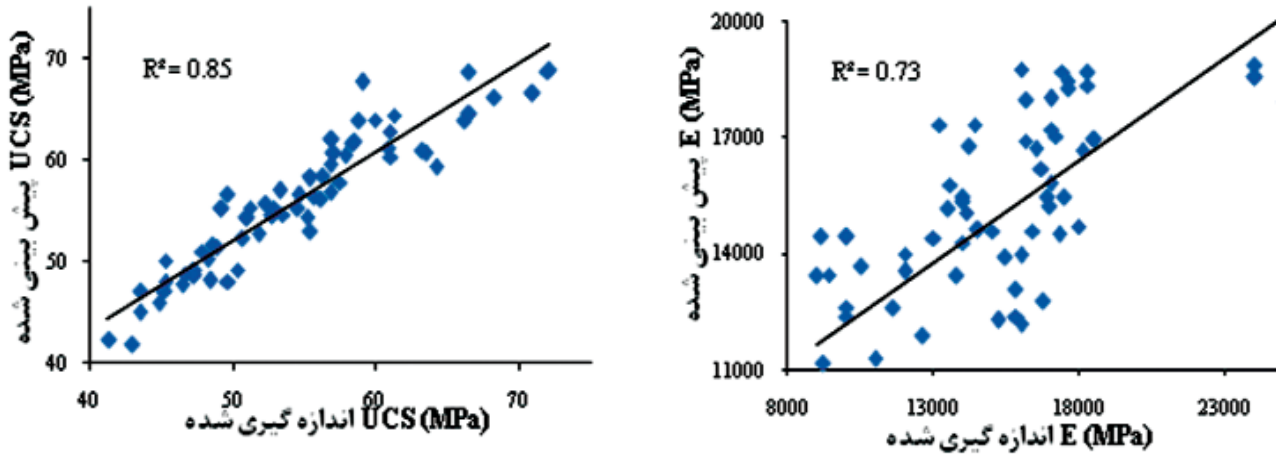

تصویر ۲- نمودارهای همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده UCS و E برای مدل‌های رگرسیون چندمتغیره

باشد، معناداری آن با درجه اطمینان بیشتر از ۹۵٪ می‌باشد که در این حالت متغیر به صورت قابل ملاحظه‌ای در پیش‌بینی، موثر است. بررسی‌های انجام گرفته نشان داده است که برای مدل UCS، مقدار درجه اهمیت در مورد Is_{50}، Vp و n کمتر از ۰/۰۵ می‌باشد. این امر نشان دهنده وجود ارتباط قوی با عملکرد بالای ۹۵٪ بین پارامترهای مذکور و UCS می‌باشد. این در حالی است که پارامترهای γ_d و Wn دارای درجه اهمیتی کمتر در مقایسه با Is_{50}، Vp و n می‌باشند. در ارتباط با مدل E نیز، Is_{50} و Wn دارای درجه اهمیت کمتر از ۰/۰۵ می‌باشند که در مقایسه با Vp، n و γ_d دارای ارتباط قوی‌تری با پارامتر E می‌باشند. در این مطالعه، همچنین شاخص‌های ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE)، با استفاده از روابط ۴ و ۵ برای کنترل قابلیت پیش‌بینی مدل‌های پیشنهادی محاسبه شده‌اند، که نتایج آن در جدول ۴ ارائه شده است.

رابطه (۴)

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} (x_1 - yi)^2}{n}}$$

رابطه (۵)

$$MAE = \frac{\sum_{i=1}^{n} |x_i - y_i|}{n}$$

جدول ۴- شاخص‌های کنترل عملکرد (R^2، MAE و RMSE)، مدل‌های رگرسیون چندمتغیره (MLR)

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

۴-۴- شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی، شامل اجزای ساده‌ای 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 تقریبا جدید است که مهمترین ویژگی آن، توانایی یادگیری از داده‌های در حال پردازش است. این روش برای حل مسائلی که برای روش‌های آماری مرسوم مناسب نمی‌باشند، می‌تواند مورد استفاده قرار گیرد (Aqil et al. 2007). این روش یک ابزار محاسباتی در حل مسائل مبهم و پیچیده می‌باشد که با استفاده از روش‌های ریاضی مانند معادلات دیفرانسیلی یا رگرسیون‌های خطی، قابل حل نمی‌باشند (آغاجریان و همکاران ۱۳۹۱). یک شبکه عصبی مصنوعی می‌تواند بوسیله سه جزء اساسی تابع انتقال، معماری شبکه و قانون یادگیری تعریف شود. تعریف این اجزا برای حل مسائل آماری ضروری می‌باشد (Yilmaz & Yuksek 2009). ساده‌ترین و معمولی‌ترین نوع شبکه عصبی مصنوعی که در بسیاری از علوم مهندسی و در این پژوهش استفاده گردید، شبکه‌های عصبی MLP همراه با ناظر می‌باشد. در این نوع شبکه‌ها، مسیرهای عملکرد شبکه، همیشه رو به جلو بوده و اجازه انتقال سیگنال تنها در یک مسیر از ورودی تا خروجی داده می‌شود (Khanlari et al. 2012). این شبکه‌ها شامل سه لایه از نرون‌ها می‌باشند. لایه ورودی برای ارائه داده‌ها به شبکه استفاده می‌شود، این لایه داده‌ها را از منابع مختلف دریافت می‌کند، از این رو تعداد نرون‌ها در لایه‌های ورودی به تعداد منابع در ورودی بستگی دارد. در این مطالعه، برای برآورد UCS و E به عنوان متغیرهای وابسته، متغیرهای مستقل $Is_{(50)}$، Vp، n، γ_d و

www.SID.ir

Archive of SID

Wn، 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 تک‌محوری 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 UCE 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 دارای کمترین مقدار می‌باشند. بنابراین در شبکه های 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 می‌باشد، بهترین معماری برای پیش‌بینی UCS و معماری ۱-۱۰-۵ 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 اندازه گیری به عمل آمده، نسبتا قوی می‌باشد (تصاویر ۴ الف و ۵ الف).

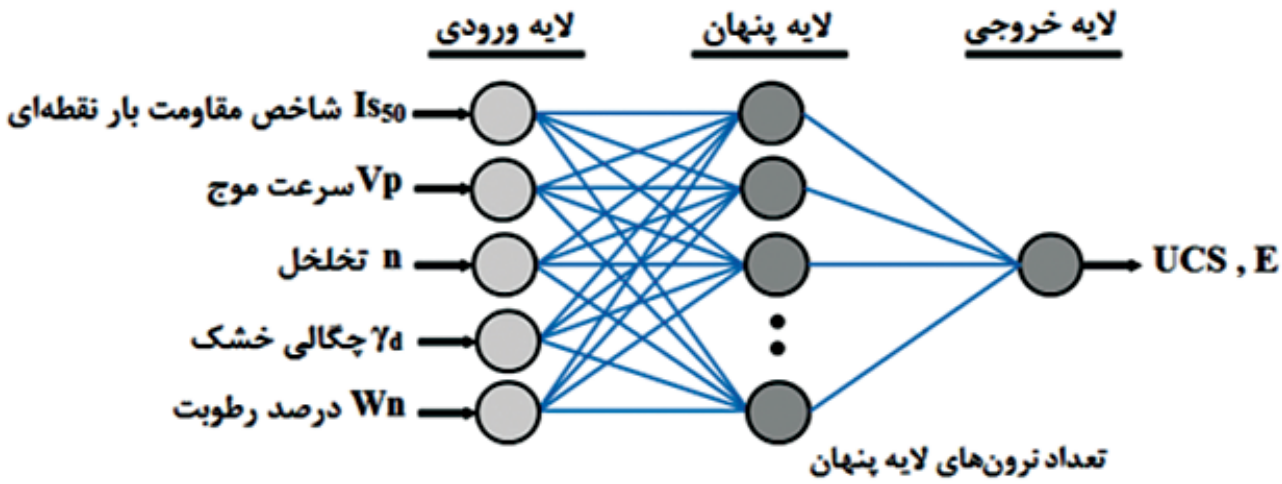

تصویر ۳- معماری شبکه عصبی پرسپترون چندلایه پیش‌خور (MLP) ساخته شده برای پیش‌بینی UCS و E

www.SID.ir

Archive of SID

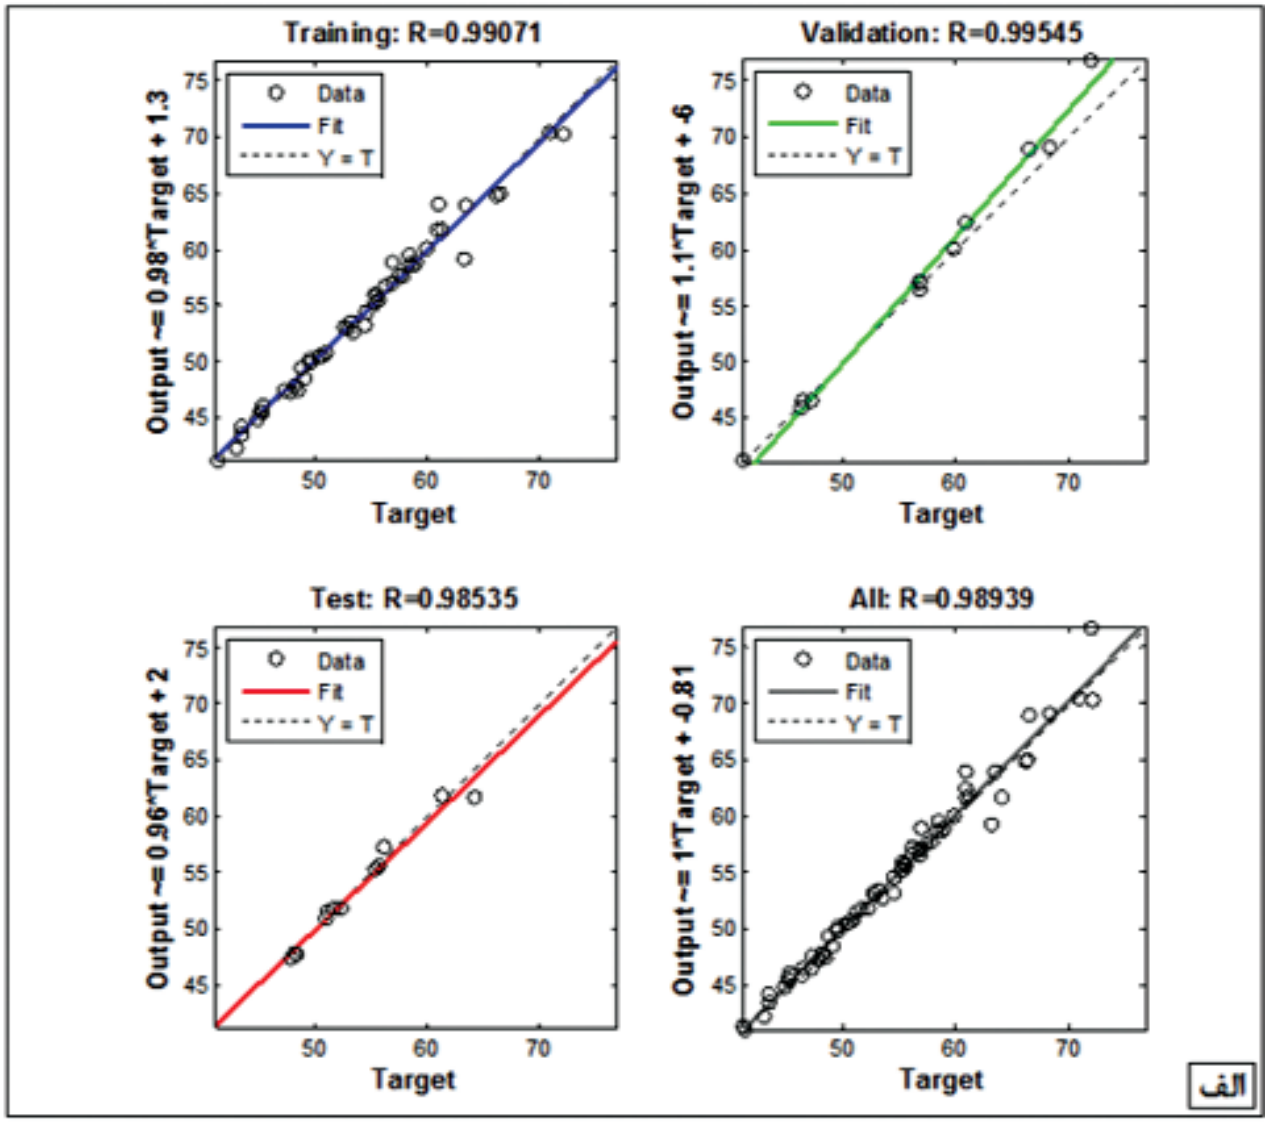

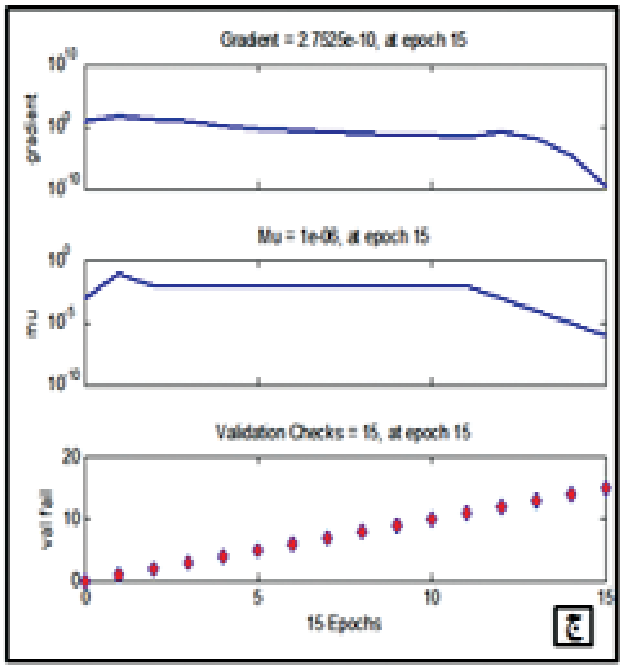

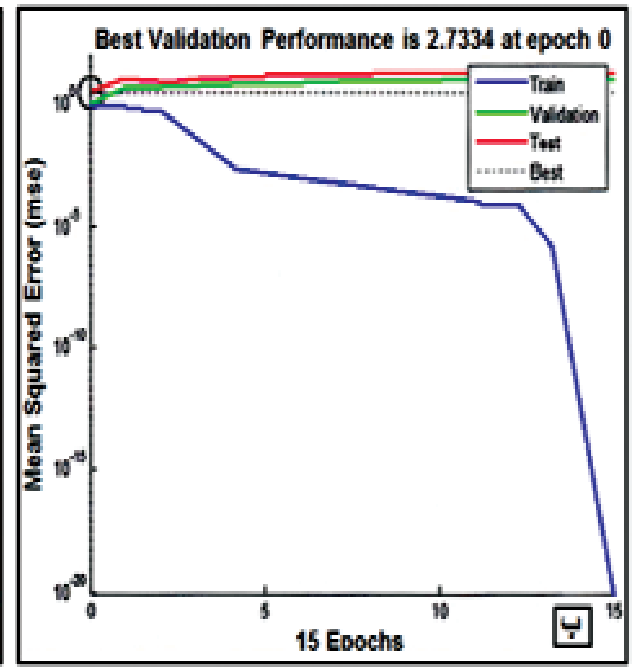

تصویر ۴- نتایج مدل UCS در ۱۵ دوره تکرار، الف) ضرایب رگرسیون شبکه، ب) خطای مجموع مربعات شبکه، ج) مراحل آموزش شبکه

www.SID.ir

Archive of SID

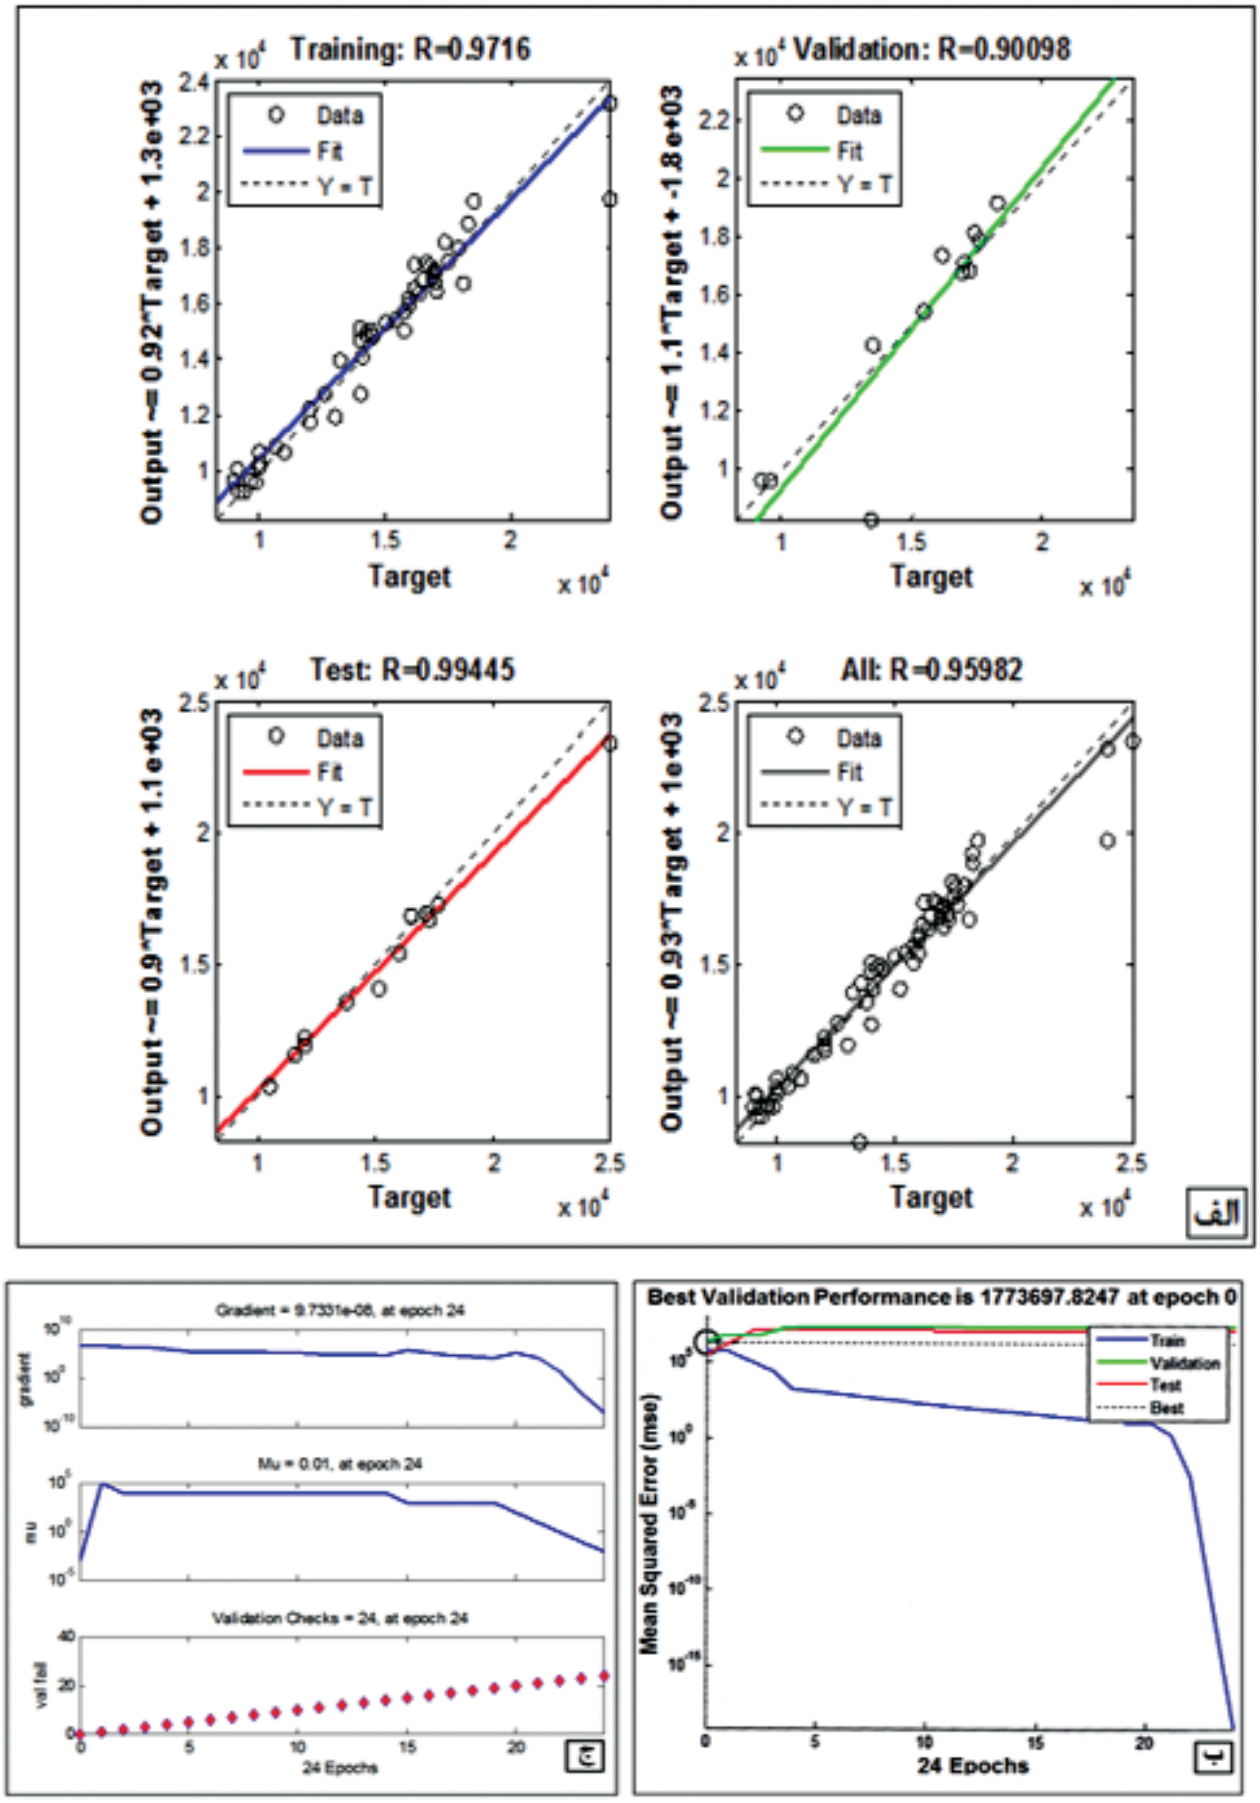

تصویر ۵- نتایج مدل E در ۲۴ دوره تکرار، الف) ضرایب رگرسیون شبکه، ب) خطای مجموع مربعات شبکه، ج) مراحل آموزش شبکه

www.SID.ir

Archive of SID

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

متغیر وابسته	مدل عصبی	تابع انتقال	قانون یادگیری	معماری شبکه	آموزش شبکه R^2	اعتبار شبکه R^2	آزمون شبکه R^2	مدل شبکه R^2	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	۱-۱۰-۵	۰/۹۴	۰/۸۱	۰/۹۸	۰/۹۰	۴/۴۷	۳/۱۲

LM: قانون یادگیری لورنبرگ- مارکوارت

بر اساس تصاویر ۴ ب و ج و ۵ ب و ج، شبکه برای برآورد مقاومت فشاری تک‌محوری در ۱۵ دوره و برای برآورد مدول الاستیسیته در ۲۴ دوره تکرار، به جواب مطلوب حاصل از آموزش شبکه رسیده است. همبستگی میان مقادیر اندازه‌گیری شده و پیش‌بینی شده نشان می‌دهد که مدل‌های شبکه عصبی مصنوعی طراحی شده برای پیش‌بینی مقاومت فشاری تک‌محوری (UCS) و مدول الاستیسیته (E) بسیار قابل قبول می‌باشند (تصویر ۶). به طوری که ضریب تعیین (R2) جهت ارزیابی عملکرد مدل‌ها، برای مدل UCS برابر ۰/۹۸ و برای مدل E برابر ۰/۹۲ می‌باشد، که این امر به خوبی عملکرد شبکه را تایید می‌نماید.

عملکرد شبکه با مقایسه مقادیر اندازه گیری شده و مقادیر پیش‌بینی شده حاصل از شبکه، با استفاده از شاخص‌های آماری R2، RMSE و MAE مورد ارزیابی قرار گرفت. به طور کلی، در صورتی که مقادیر R2، RMSE و MAE به ترتیب به مقادیر ۱، ۰ و ۰ نزدیکتر باشند، پیش‌بینی شبکه مطلوب‌تر ارزیابی می‌گردد. مقادیر R2، RMSE و MAE برای هر دو شبکه در جدول ۶ ارائه شده‌اند.

جدول ۶- شاخص‌های 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

۴-۵- مقایسه عملکرد مدل‌های ANN با مدل‌های MLR برای پیش‌بینی UCS و E

در این مطالعه، عملکرد مدل‌های طراحی شده بوسیله روش‌های شبکه عصبی مصنوعی (ANN) و رگرسیون چندمتغیره خطی (MLR)، با استفاده از شاخص‌های 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 مدل‌های 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 می‌باشد. 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 می‌باشد. 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 می‌باشد. نتایج به دست آمده حاکی از آن است که

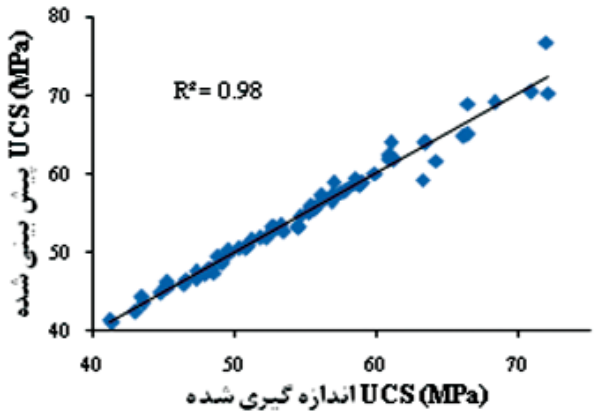

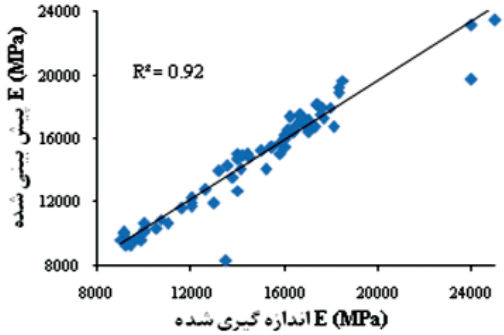

تصویر ۶- نمودارهای همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده UCS و E مدل‌های شبکه عصبی مصنوعی

www.SID.ir

Archive of SID

قابلیت روش شبکه عصبی مصنوعی (ANN)، در پیش بینی 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 چند متغیره

مدل های شبکه	R^2		RMSE		MAE	
	MLR	ANN	MLR	ANN	MLR	ANN
UCS	۰/۸۸	۰/۹۷	۵/۱۵	۳/۲۲	۴/۲۲	۱/۸۹
E	۰/۸۶	۰/۹۰	۷/۳۶	۴/۴۷	۴/۸۷	۳/۱۲

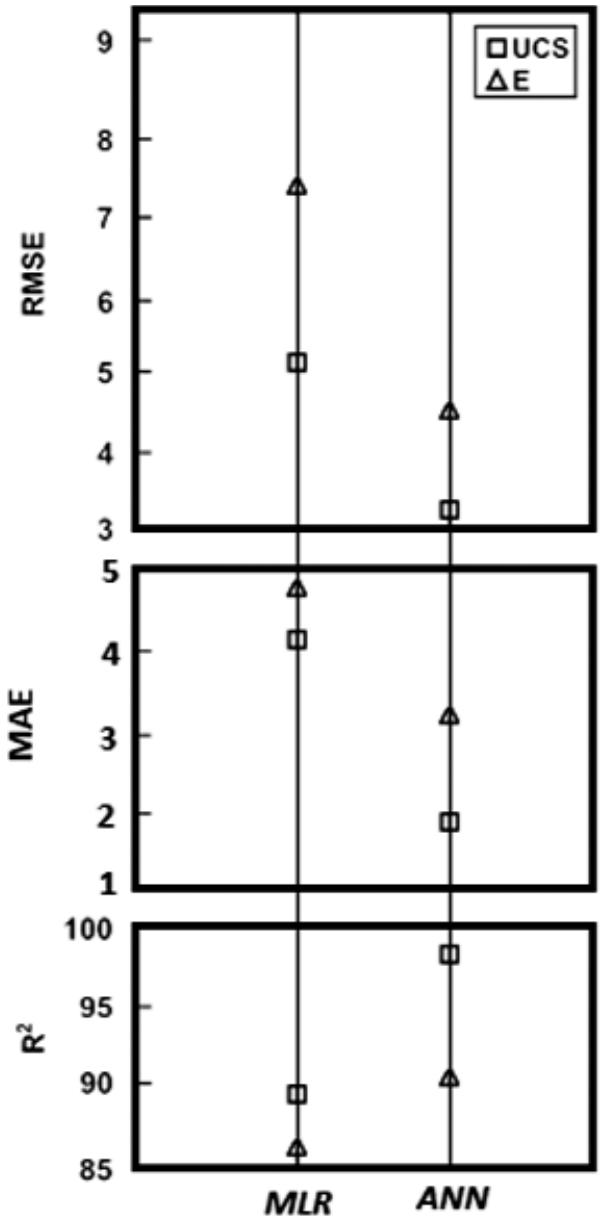

تصویر ۷- مقایسه مقادیر R2، MAE و RMSE برای مدل‌های MLR و ANN

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 پایین‌تر می‌باشد.

مدل‌های ارائه شده در روش رگرسیون چندمتغیره نشان می‌دهد که این روش، عملکرد نسبتا قابل قبولی برای پیش‌بینی UCS و E به ترتیب با ضرایب تعیین R^2= ۰/۸۸ و R^2 = ۰/۸۶ دارد.

بهترین مدل پیشنهادی برای پیش بینی UCS، مدل با شبکه پرسپترون چند لایه، تابع فعال سازی تانژانت سیگموئید برای لایه پنهان، تابع خطی برای لایه خروجی، قانون آموزش پس‌انتشار خطا (الگوریتم پس‌انتشار مارکوارت- لورنبرگ (LM)) با معماری ۱-۱۵-۵ می‌باشد. این مدل، مقادیر UCS را با R^2=۰/۹۷، RMSE=۳/۲ و MAE =۱/۸۹ را پیش بینی 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 پس‌انتشار خطا (الگوریتم پس‌انتشار مارکوارت-لورنبرگ (LM)) با معماری ۱-۱۰-۵ می‌باشد. این مدل E را با R^2= ۰/۹۰، RMSE=۴/۴۷ و MAE= ۳/۱۲ 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 کارآیی بالاتر مدل‌های شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیون چندمتغیره در پیش‌بینی UCS و E می‌باشد.

مراجع

آدابی، م.ح.، ۱۳۶۶. سنگ‌های رسوبی شیمیایی- بیوشیمیایی. انتشارات آستان قدس رضوی، ۳۴۴ص.

آغاجریان،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 زمین شناسی کاربردی دانشگاه آزاد، سال ۸ (۳): ۲۰۲-۱۹۳.

آقانباتی، س.ع.، ۱۳۸۵. زمین‌شناسی ایران. سازمان زمین‌شناسی و اکتشافات معدنی کشور. چاپ دوم، ۵۸۶ص.

www.SID.ir

Archive of SID

بلورچی، م.،ح.، حاجیان، ج.، ۱۳۵۸. نقشه زمین شناسی کبودرآهنگ، مقیاس ۱:۲۵۰۰۰۰. سازمان زمین شناسی و اکتشافات معدنی کشور.

دهقان، س.، ستاری، ق.، ۱۳۸۶. تخمین مقاومت تراکمی تک‌محوری سنگ تراورتن محلات با استفاده از تخلخل 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، شماره۱، ص ۱۴-۲۲.

کیانپور، م.، ارومیه‌ای، ع.، نیکودل، م.ر.، ۱۳۹۰ . بررسی روش‌های غیر مستقیم تخمین مقاومت تراکمی تک‌محوری 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 neurofuxxy 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 relationdhips: 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 weigting 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 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 Hardeness. *International Journal of Rock Mechanic 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.*

www.SID.ir