

تخمین مدول الاستیسیته سنگ بکر با استفاده از شبکه عصبی مصنوعی و رگرسیون غیر خطی

معصومه اسماعیلی

دانشجوی کارشناسی ارشد ژئوتکنیک، گروه مهندسی عمران، دانشگاه اصفهان

مهرداد پسندی

استادیار گروه زمین شناسی، دانشگاه اصفهان

محمود هاشمی اصفهانیان

دانشیار گروه مهندسی عمران، دانشگاه اصفهان

تاریخ دریافت: ۹۳/۶/۱۸ تاریخ پذیرش: ۹۴/۸/۴

m.pasandi@sci.ui.ac.ir

چکیده

مدول الاستیسیته سنگ بکر یکی از ملزومات اساسی بسیاری از مطالعات ژئومکانیکی و به ویژه پروژه های حفاری سنگ می باشد. برای تعیین مستقیم مدول الاستیسیته، نمونه مغزه های باکیفیت بالا و هندسه مناسب مورد نیاز بوده و تهیه نمونه های مناسب از سنگ های شکسته و هوازده برای این منظور به آسانی امکان پذیر نیست. بنابراین مدل های پیش بینی مدول الاستیسیته بر اساس خصوصیات شاخص سنگ بکر ارائه گردیده اند. در این مطالعه با استفاده از شبکه عصبی چند لایه پرسپترون با الگوریتم پس انتشار و داده های حاصل از آزمایشات سنگ، مطلوبترین تخمین از مدول الاستیسیته برآورد گردیده و با نتایج حاصل از روش رگرسیون غیر خطی مقایسه شده است. بدین منظور، تعداد ۱۲۱ داده حاصل از آزمایشات سنگ سه پروژه بهشت آباد، رودبار لرستان و سبزکوه استفاده گردیده است. پارامترهای متعددی از جمله تخلخل، مقاومت فشاری تک محوره، سرعت موج فشاری، مقاومت کششی و چگالی در تخمین پارامتر مدول الاستیسیته مورد استفاده قرار گرفته اند. در بهینه یابی اجزای شبکه عصبی، مدل شبکه عصبی با دو لایه و چهار نورون در لایه مخفی، یک نورون در لایه خروجی و یک سری داده در لایه ورودی و تابع عملکرد tansig به عنوان ساختار بهینه شبکه عصبی برآورد شده است. نتایج حاصل از روش های تخمین مورد استفاده توسط معیارهای ضریب تعیین و جذر مجموع مربعات خطا مورد مقایسه واقع شده اند. این مقایسه نشانگر عملکرد مطلوب تر شبکه عصبی نسبت به رگرسیون غیر خطی می باشد. مقاومت فشاری تک محوری، سرعت موج فشاری و مقاومت کششی غیرمستقیم به ترتیب مهم ترین پارامترهای تاثیرگذار بر عملکرد مدل شبکه عصبی می باشند.

کلمات کلیدی: مدول الاستیسیته سنگ بکر، شبکه عصبی مصنوعی، رگرسیون غیر خطی

مقدمه

در صنایع معدن و زغال سنگ، اکثر خطرات ریزش و گسیختگی به دلیل کمبود دانش و یا برآورد غیر دقیق پارامترهای نمایانگر خصوصیات مکانیکی و فیزیکی سنگ ها رخ می دهد (Haghejrad et al., 2013). یکی از مهمترین این پارامترها مدول الاستیسیته بوده و به خوبی نشان دهنده رفتار مکانیکی سنگ به ویژه در حفاری ها می باشد (Okay aksoy et al., 2012, Palmstrom and Singh, 2001). همچنین آنالیزهای عددی اجزا محدود و المان مرزی جهت مطالعات توزیع تنش و جا به جایی اطراف حفاری های زیرزمینی بر اساس این پارامتر می باشند (Palmstrom and Singh, 2001). تخمین مدول الاستیسیته معمولاً توسط روش های آزمایشگاهی، آزمایشات برجا، روش های ژئوفیزیکی و روابط تجربی صورت می گیرد (Zhang and Einstein, 2004).

از جمله این روش ها می توان به آزمایشات مختلفی همچون آزمایش کششی غیرمستقیم (تست برزلی) (Anagnos and Kennedy, 1972)، بار نقطه ای (Broch and Franklin, 1972)، مقاومت فشاری تک محوره (ذلولی و همکاران، ۱۳۹۳ و Kuhn, 2000) و روش دینامیکی

(Christaras et al., 1994) اشاره نمود. از آنجا که روش های آزمایشگاهی بر روی نمونه های کوچک انجام می شوند، نمی توانند تغییر شکل پذیری توده سنگ ها را پیش بینی کنند (Zhang and Einstein, 2004). آزمایشات برجا اطلاعات مستقیمی از تغییر شکل پذیری سنگ در اختیار می گذارند، اما به دلیل اینکه حتی در شرایط کاملاً یکنواخت و با کیفیت خوب توده سنگ ممکن است نتایج متفاوتی به دست آید، به تنهایی نمی توان به نتایج یک آزمایش برجا اعتماد کرد. بنابراین برای به دست آوردن نتایج قابل اعتمادتر چندین آزمایش مورد نیاز است که مستلزم صرف وقت و هزینه قابل توجهی می باشد (Hoek and Diederich, 2006; Shen et al., 2012).

هم چنین برای تعیین مستقیم مدول الاستیسیته، نمونه مغزه های با کیفیت بالا و هندسه مناسب مورد نیاز بوده و تهیه نمونه های مناسب از سنگ های شکسته و هوازده برای این روش امکان پذیر نیست (Sonmez et al., 2006; Heidari et al., 2010).

تحقیقات زیادی برای تخمین این پارامتر با استفاده از پارامترهای دینامیکی توسط محققین مختلف انجام گرفته و روابط تجربی زیادی در این مورد ارائه شده است (Zhang, 2005; Khandelwal and Sing;

در این مطالعه با استفاده از شبکه عصبی چند لایه با الگوریتم پس انتشار و روش رگرسیون، با ۱۴۶ داده حاصل از آزمایشات سنگ سه پروژه بهشت آباد، رودبار لرستان و سبزکوه، مطلوب ترین تخمین از مدول الاستیسیته برآورد شده است. در این تخمین پارامترهای مستقل متعددی برای سنگ بکر از جمله تخلخل، مقاومت فشاری تک محوره، سرعت موج فشاری، مقاومت کششی و چگالی در نظر گرفته شده است. در نهایت مدل شبکه عصبی با پارامترهای مناسب ساخته شده و نتایج به توسط معیارهای کارایی ضریب تعیین (R^2) و جذر مجموع مربعات خطا (RMSE) مورد مقایسه واقع شده-اند. مدل شبکه عصبی به دست آمده برای اعتبارسنجی بر روی ۲۸ نمونه مشابه دیگر نیز مورد استفاده قرار گرفته است.

زمین شناسی پروژه‌های عمرانی مورد بررسی

در این مطالعه از ۱۴۶ داده حاصل از آزمایشات سنگ در سه پروژه بهشت آباد، رودبار لرستان و سبزکوه (شکل ۱) استفاده گردیده و در ذیل مختصری در خصوص زمین شناسی مکان اجرای این پروژه‌ها توضیح داده می شود.

سبزکوه

از نظر تقسیم‌بندی کشوری، تونل انتقال آب سبزکوه با راستای تقریباً شمالی-جنوبی در استان چهار محال بختیاری و در جنوب شهرستان شهرکرد واقع شده است (شکل ۱). در مراحل اولیه مطالعات، جهت بررسی شرایط عمقی و زیرسطحی توده‌های سنگی ساختگاه تونل، تعدادی گمانه در مسیر تونل توسط شرکت مهتاب قدس حفاری گردیده که از این میان، سه گمانه به دلیل دارا بودن اطلاعات به اندازه کافی، مورد استفاده قرار گرفتند.

با توجه به تقسیم بندی‌های زمین ساختی ایران، منطقه مورد مطالعه در حاشیه شمالی رشته کوه‌های زاگرس و در بخش‌های میانی آن، در پهنه زاگرس بلند واقع شده است. سنگ شناسی منطقه شامل سنگ‌های رسوبی می‌باشد که به صورت چین خوردگی ها، گسل ها، زون‌های برشی و سطوح درز و شکاف دار و هوازده رخنمون یافته‌اند. تاقدیس کلار و دو گسل تراستی سولقان و آوردگان به همراه گسل امتداد لغز چهارطاق از ساختارهای زمین شناسی اصلی در مسیر تونل سبزکوه می باشند.

در ۶ کیلومتر اولیه تونل تغییرات سنگ شناسی به صورت منظم بوده و به ترتیب شامل مارن و مارن آهکی سازند گورپی، آهک های سروک-ایلام، آهک و آهک مارنی کژدمی، دولومیت و آهک دولومیتی سازندهای داریان-فهلپان، سورمه و نی ریز می باشد. شیب لایه بندی در این بخش از تونل حدود ۶۰-۵۰ درجه به سمت ورودی تونل می باشد. اما ۴/۵ کیلومتر بخش خروجی تونل دربرگیرنده آهک‌های توده‌ای سازند خانه‌کت و شیل‌ها و مارن‌های کامبرین می‌باشد که به دلیل عملکرد گسل‌های تراستی آوردگان و سولقان به شدت به هم ریخته و خرد شده است. بخش عمده خروجی تونل را زون‌های برشی با قطعات آهکی و دولومیتی تشکیل داده‌اند.

گمانه‌های مورد بررسی در محدوده پرتال ورودی در محدوده سبزکوه حفر گردیده‌اند. غالب چینه شناسی پرتال ورودی تونل شامل سازند گورپی با سن کرتاسه می‌باشد. عمده سنگ‌های موجود در این پروژه شامل: آبرفت-مارن سنگ، آهک ماسه‌ای، آبرفت-سنگ آهک و مارن، آبرفت-سنگ آهک، سنگ آهک و مارن می‌باشند. در این تحقیق تنها از نمونه‌های آهکی پروژه استفاده

(2009). در متون مکانیک سنگ نیز یکسری روابط تجربی بین مدول الاستیک سنگ سالم و دیگر پارامترهای سنگ نظیر مقاومت فشاری تک محوره، وزن واحد حجم، عدد برگشت اشمیت، شاخص بار نقطه‌ای و ترکیب سنگ نگاره‌ها موجود می‌باشد. از جمله به تحقیقی که در زمینه رابطه مدول الاستیسیته سنگ بکر و مقاومت فشاری تک محوره انجام گرفته و در همین راستا نموداری نیز جهت تخمین مدول الاستیسیته با استفاده از مقادیر مقاومت فشاری تک محوره برای سنگ‌های مختلف ارائه شده است، می‌توان اشاره نمود (Deere and Miller; 1966). برخی محققان نیز در سال‌های اخیر از پارامترهای چندگانه نظیر مقاومت فشاری تک محوره و چگالی در روابط تجربی تخمین مدول الاستیسیته بهره برده‌اند (Sonmez et al., 2006; Ocak, 2008).

محدودیت این روابط این است که برای سنگ‌های خاصی به دست آمده‌اند و به عبارت دیگر به صورت فراگیر قابل استفاده نیستند. بنابراین توصیف مکانی خوب از توده سنگ و استفاده از یک روش هوشمند مناسب نتایج بهتری نسبت به اندازه‌گیری‌های مکانی پرهزینه به دست می‌دهد. امروزه در رشته‌های مهندسی، استفاده از شبکه عصبی مصنوعی با توجه به عدم فرمول بندی و پویا بودن، راهبرد مناسبی برای تخمین و مدل سازی به شمار می‌رود (Hubick, 1992). تحقیقات زیادی در خصوص حل مسائل ژئوتکنیک با بهره گیری از شبکه عصبی مصنوعی صورت گرفته است (پسندی و همکاران، ۱۳۹۲) و مطالعاتی به طور خاص جهت تخمین مدول الاستیسیته با بهره‌گیری از شبکه عصبی صورت گرفته است. برخی از محققان از عدد بازگشت چکش اشمیت برای تخمین مدول الاستیسیته استفاده کرده‌اند (Sachpazis, 1990; Yagiz, 2009). و برخی دیگر استفاده از مقاومت فشاری تک محوره را برای تخمین مدول الاستیسیته پیشنهاد نموده‌اند (Rohde and Feng, 1990; Tuğrul and Zarif, 1999; Palchik, 1999; Lashkaripour and Nakhaei, 2001; Ocak, 2009). این روش هیچ محدودیتی در تعداد پارامترهای ورودی برای پیش بینی مدول الاستیسیته ندارد. (Sonmez et al., 2006) شبکه‌ای طراحی نمودند و بر اساس آن یک جدول تخمین مدول الاستیسیته سنگ بکر با استفاده از چگالی و مقاومت فشاری تک محوره پیشنهاد کردند. از سرعت موج فشاری، شاخص بار نقطه، تخلخل و عدد چکش اشمیت نیز برای پیش بینی مدول الاستیسیته سنگ تراورتن استفاده گردیده است (Dehghan et al., 2010). همچنین در مطالعات اخیر محققان از چگالی و مقاومت فشاری تک محوره جهت تخمین این پارامتر استفاده نموده‌اند (Ocak and Evren, 2012). در این مطالعه با استفاده از شبکه عصبی چند لایه با الگوریتم پس انتشار و داده‌های حاصل از آزمایشات سنگ سه پروژه عمرانی بهشت آباد، رودبار لرستان و سبزکوه، مطلوب‌ترین تخمین از مدول الاستیسیته برآورد گردیده و نتایج با تخمین از طریق روش رگرسیون غیرخطی مقایسه شده است.

روش کار

هدف این تحقیق ارائه مدلی جهت تخمین مدول الاستیسیته سنگ بکر می‌باشد. روش‌های مورد استفاده برای تخمین E معمولاً شامل روش‌های آزمایشگاهی، آزمایشات برجا، روش‌های ژئوفیزیکی و روابط تجربی می‌باشند که هر یک از این روش‌ها مزایا و معایبی دارند.

شده است (شرکت مهتاب قدس، ۱۳۸۳).

سد رودبار لرستان

ناحیه‌ی مورد بررسی در پهنه زاگرس شمالی یا زاگرس بلند واقع شده است (شکل ۱). در بخشی از زاگرس شمالی که گستره مورد بررسی در آن واقع شده مهم‌ترین واحدهایی که رخنمون دارند شامل سازندهای آهکی-دولومیتی نظیر دالان و سروک، سازندهای واجد سنگ شناسی شکل پذیر نظیر شیل و مارن متشکل از سازندهای هرمز و میلا و سازندهای حد واسط (واجد سنگ شناسی آهک مارنی و مارن) نظیر سازند گرو می‌باشند. با توجه به رخنمون سنگ‌ها در محدوده مجاور رودخانه الکن و نیز اطلاعات مطالعات سد رودبار لرستان، بخش اصلی ستون سنگ شناسی در محدوده مزبور شامل دولومیت‌های تیره رنگ همراه با تداخل‌هایی از پرش و شیب‌های میکادار، شیل و مارن‌های ارغوانی و صورتی رنگ و نیز ماسه سنگ‌های صورتی و دولومیت‌های تیره رنگ استروماتولیتی است. عمده سنگ‌های موجود در محدوده این پروژه شامل: سنگ آهک خاکستری تیره با رگچه‌های کلسیتی و درزه، دولومیت خاکستری با رگچه‌های کلسیتی، سنگ آهک خاکستری با درزه‌های کلسیتی و درزه‌های حاوی قیر، سنگ آهک کرم مایل به خاکستری متخلخل می‌باشند (شرکت توسعه منابع آب و نیروی ایران، ۱۳۸۵).

بهشت آباد

موقعیت جغرافیایی سد، محل تلاقی رودخانه‌های بهشت آباد و کوه‌رنگ نزدیک روستای بهشت آباد واقع در شهرستان اردل (استان چهارمحال و بختیاری) است (شکل ۱). موقعیت انتقال آب در گستره‌ی جغرافیایی از گردنه رخ تا ارتفاعات بیدکان می‌باشد.

بر اساس برخی از تقسیم‌بندی‌های انجام شده در مورد زمین شناسی ایران، محدوده مورد مطالعه در منطقه کوهزایی زاگرس و پهنه زاگرس مرتفع قرار گرفته است. عمده سنگ‌های موجود در نمونه‌های پروژه بهشت آباد شامل سنگ آهک کرم رنگ روشن با درزه‌های هوازده و گاه‌آ دارای رگه‌های کلسیتی، سنگ آهک دولومیتی متخلخل خاکستری روشن، دولومیت خاکستری با رگچه‌های کلسیتی، دولومیت کرم خاکستری روشن با درزه‌های هوازده، دولومیت آهکی کرم مایل به زرد، سنگ آهک خاکستری روشن، سنگ آهک کرم تیره با درزه و فسیل، کنگلومرای کرم مایل به خاکستری با دانه‌های متوسط می‌باشند (شرکت آب منطقه‌ای اصفهان، ۱۳۸۳).

تئوری

اثر پارامترهای مستقل بر مدول الاستیسیته سنگ بکر

تعدادی از پارامترهای فیزیکی بطور مستقیم یا غیرمستقیم در ارتباط با مدول الاستیسیته می‌باشند و از این پارامترها در تخمین غیرمستقیم مدول الاستیسیته می‌توان استفاده نمود. در ذیل این پارامترها معرفی شده و ارتباط آن‌ها با مدول الاستیسیته جهت توجیه کاربرد آن‌ها در تخمین این پارامتر، تشریح می‌گردد:

مقاومت فشاری تک محوره (UCS)

از آنجایی که مقاومت فشاری تک محوره و مدول الاستیسیته رابطه مستقیمی با یکدیگر دارند، می‌توان این نتیجه را گرفت که هر پارامتری که بر روی مقاومت تک محوره تأثیر می‌گذارد بر روی مدول الاستیسیته نیز اثرگذار می‌باشد. از این منظر عواملی که شاخص دوام را تحت تأثیر قرار می‌دهند، بر

روی مدول الاستیسیته نیز همان اثر را خواهند داشت (Rohde and Feng, 1990; Diamantis et al., 2009).

نتیجه یک سری مطالعات میکروسکوپی نشان می‌دهد که بافت سنگ، نحوه تماس بین ذرات و درجه قفل شدگی ذرات در یکدیگر کنترل کننده‌ی خواص ژئومکانیک بوده و بر ویژگی مقاومت نیز اثرگذار است. تحقیقات با استفاده از آزمایش سختی و همچنین آزمایش تعیین شاخص دوام (Id) نشان می‌دهند که اغلب عواملی که دوام سنگ را تحت تأثیر قرار می‌دهند بر مقاومت فشاری تک محوره نیز اثرگذار هستند. البته برخی مشخصه‌ها مانند شکل و اندازه دانه‌ها اثر کاملاً متفاوتی بر مقاومت و دوام سنگ‌ها دارند. علاوه بر این، نتایج آزمایش UCS تحت تأثیر سرعت بارگذاری و دقت آماده سازی نمونه قرار می‌گیرند، در صورتی که این عوامل بر شاخص دوام سنگ تأثیری ندارند. با این وجود نقش عواملی که به طور مشترک باعث افزایش و کاهش Id و UCS می‌شوند، بسیار بیشتر است (Jensen et al., 2010).

سرعت موج فشاری (Vp)

هر چه تراکم سنگ بیش‌تر و سنگ ریزدانه‌تر باشد، به دلیل افزایش تنش وارده نسبت به تغییر مکان، سرعت امواج در آن بیش‌تر است. درجه تراکم سنگ آهک توسط وزن واحد حجم آن تعیین می‌گردد (Jensen et al., 2010). بنابراین می‌توان این نتیجه را گرفت که هرچه سرعت موج فشاری در سنگ بیش‌تر باشد، مدول الاستیسیته افزایش خواهد یافت.

با افزایش میزان مقاومت تراکمی تک محوری سنگ‌ها، سرعت عبور امواج افزایش می‌یابد که می‌تواند به علت بسته بودن فضاها و میکرو ترک های داخلی سنگ بکر با مقاومت بالاتر نسبت به سنگ بکر با مقاومت پایین‌تر و همچنین بالاتر بودن چگالی سنگ در حالت با مقاومت فشاری بالاتر نسبت به مقاومت فشاری پایین‌تر باشد. از تئوری الاستیسیته نیز می‌توان رابطه‌ی سرعت موج فشاری و مدول الاستیسیته را به صورت زیر بیان نمود:

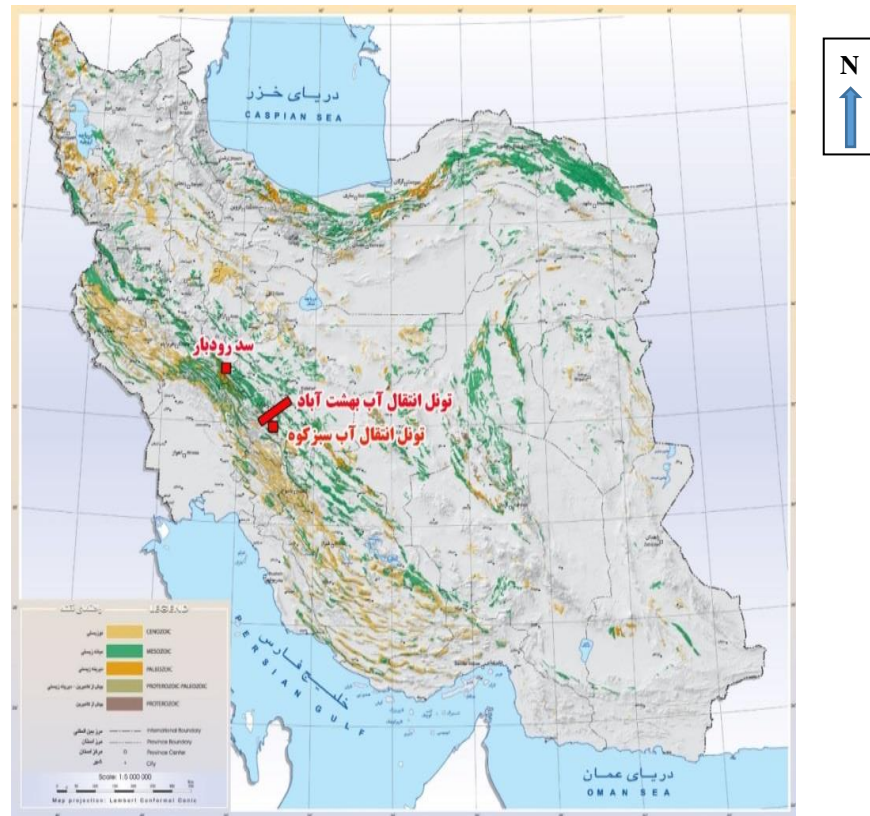
$$E_s = \rho V_p^2 \quad \text{رابطه (۱)}$$

در این رابطه ρ بر حسب gt/cm^3 ؛ V_p بر حسب km/s و E_s بر حسب Gpa می‌باشند.

درصد جذب آب

وجود یا عدم آب در سنگ متخلخل و مقدار درصد آن بر کلیه خواص فیزیکی و مکانیکی سنگ تأثیر می‌گذارد. رطوبت طبیعی موجود و میزان توانایی جذب آب در سنگ به علت اندرکنشی که با کانی‌های تشکیل دهنده دارد و تغییراتی که در مشخصات این سطوح و طبیعت پیوند بین آنها ایجاد می‌کند، مقاومت و مشخصات ژئوتکنیکی سنگ را کاهش می‌دهد. این کاهش ممکن است بخاطر افزایش فشار منفذی و یا کاهش C و ϕ باشد (Goodman, 1980).

همچنین واکنش‌های شیمیایی که بین آب و فاز جامد سنگ اتفاق می‌افتد باعث تغییر ترکیب شیمیایی کانی‌ها شده و اکثر این تغییرات در جهت تضعیف مقاومت سنگ عمل می‌کنند. در برخی از سنگ‌ها نظیر سنگ‌های آهک، رطوبت کم باعث ایجاد رفتار خزشی در سنگ می‌گردد و با افزایش مقدار رطوبت، پیوند بین اتم‌ها شکسته شده و یونیزه می‌شوند که اصطلاحاً گفته می‌شود سنگ در آب حل شده است.



شکل ۱. موقعیت پروژه‌های عمرانی مورد بررسی بر روی نقشه پراکندگی سنگ‌های کربناته (سازمان زمین شناسی و اکتشافات معدنی کشور، ۱۳۸۷)

استفاده نمود.

تخلخل در سنگ به دو نوع اولیه و ثانویه تقسیم می‌گردد. تخلخل اولیه سنگ به شکل و اندازه دانه‌های متشکله، میزان تنوع دانه‌ها، نحوه سخت‌شدگی و نحوه تجمع کانی‌ها بستگی دارد. تخلخل ثانویه مربوط به وجود ریز ترک‌ها و درزه‌ها در سنگ می‌باشد. به طور معمول تخلخل سنگ‌های رسوبی از سنگ‌های آذرین بیشتر است. تخلخل در سنگ‌های رسوبی وابسته به درجه سیمانی شدن سنگ می‌باشد. علاوه بر آن در نمونه مغزه سنگ بکر، میزان تخلخل وابسته به حفرات موجود در سنگ نیز می‌باشد. در چنین نمونه‌هایی، تخلخل ارتباط مستقیم با نفوذپذیری دارد (Zhang, 2005).

بنابراین ارتباطی قوی بین چگالی، تخلخل و مقاومت سنگ بکر وجود دارد. به طور کلی در سنگ‌های رسوبی با افزایش تخلخل همه ویژگی‌های مقاومتی نمونه و به تبع آن مدول الاستیسیته کاهش می‌یابند. میزان این کاهش به نوع و مقاومت سنگ بستگی دارد. با افزایش مقاومت سنگ، تأثیر مشخصه تخلخل (n) بر مقاومت کاهش یافته و خصوصاً در نمونه‌های با مقاومت متوسط، همبستگی چندانی با مقاومت نشان نمی‌دهد.

از منظر دیگر، با توجه به این‌که با افزایش تخلخل میزان خلل و فرج داخل سنگ افزایش می‌یابد و به علت این‌که سرعت موج در هوا نسبت به جاهای متراکم‌تر کمتر است، این حالت باعث کاهش سرعت موج می‌شود. از آن‌جا که سرعت موج فشاری با مقاومت نسبت مستقیم دارد، می‌توان گفت سرعت موج با تخلخل رابطه‌ی عکس نشان می‌دهد. که این مورد را می‌توان به کاهش

بدین ترتیب، درصد رطوبت طبیعی و میزان جذب آب سنگ‌ها برای پیش بینی رفتار مهندسی آن‌ها حائز اهمیت است و در اکثر آزمایش‌های مکانیک باید حداقل مقاومت کششی برای سنگ منظور گردد (Jensen et al., 2010; Goodman, 1980)

مقاومت کششی برزیلی (غیر مستقیم)

مقاومت کششی سنگ حداکثر تنش کششی است که سنگ قادر به تحمل آن می‌باشد. مصالح سنگی معمولاً مقاومت کششی پایینی دارند. این مسئله می‌تواند به دلیل وجود میکرو ترک‌ها در سنگ باشد. به طور کلی مقاومت کششی سنگ‌ها حدود $\frac{1}{10}$ تا $\frac{1}{18}$ مقاومت فشاری تک محوره است و به

طور کاملاً مشخص، مقاومت فشاری سنگ‌ها بزرگتر از مقاومت کششی آن‌ها می‌باشد. با توجه به رابطه‌ی مستقیم میان مدول الاستیسیته و مقاومت فشاری و نیز رابطه‌ی میان مقاومت کششی غیر مستقیم و مقاومت فشاری، بدیهی است که مدول الاستیسیته و مقاومت کششی سنگ رابطه‌ی مستقیمی دارند. به دلیل اینکه سنگ‌ها تحت کشش به راحتی می‌شکنند، در طراحی‌ها سنگ باید درصد رطوبت و میزان جذب آب نمونه به دقت تعیین گردد (Jensen et al., 2010).

تخلخل

در نمونه‌های سنگ، تخلخل و درصد جذب آب رابطه‌ی نزدیکی دارند که می‌تواند به دلیل نوع حفره‌های درون سنگ و مرتبط بودن آن‌ها با یکدیگر باشد. بنابراین در مدل‌سازی به جای درصد جذب آب می‌توان از تخلخل نیز

مؤثر نمی‌باشد و تنها مشخصات دانه‌ها (بلورها) مؤثر است. علاوه بر آن نتیجه یک سری مطالعات میکروسکوپی نشان می‌دهد که بافت سنگ، نحوه تماس بین ذرات و درجه قفل شدگی ذرات در یکدیگر کنترل کننده‌ی خواص ژئومکانیک بوده و بر ویژگی مقاومت نیز اثر گذار است.

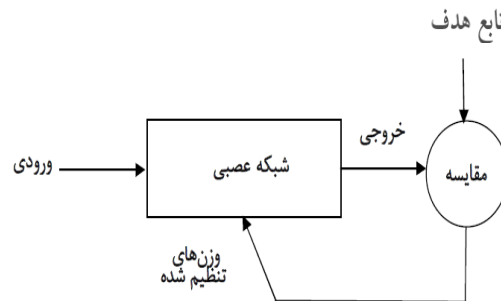
شبکه عصبی مصنوعی

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. این عناصر که نورون یا گره نامیده می‌شوند، از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. همانطور که در (شکل ۲) دیده می‌شود، شبکه بر مبنای تطابق و هم‌سنجی بین ورودی و هدف سازگار می‌شود تا اینکه خروجی شبکه و خروجی مورد نظر (هدف) بر هم منطبق گردند. پس از تنظیم یا همان آموزش شبکه عصبی، اعمال یک ورودی خاص به آن منجر به دریافت پاسخ خاصی خواهد شد.

کیفیت سنگ مرتبط ساخت (Zhang, 2005; Tucker, 2009). به طور کلی در سنگ‌های رسوبی با افزایش تخلخل همه ویژگی‌های مقاومتی نمونه و به تبع آن مدول الاستیسیته کاهش می‌یابند. دلیل این امر توزیع تنش در ریز ترک‌های سنگ با افزایش تخلخل می‌باشد. این در حالی است که تخلخل نمونه‌های مقاوم‌تر مربوط به منافذ سنگ است که اثر کمتری بر کاهش مقاومت نسبت به تخلخل مربوط به ریز ترک‌ها دارد. در کل یک رابطه‌ی بدیهی و منطقی بین مدول الاستیسیته سنگ و مقاومت فشاری تک محوره وجود دارد، بدین صورت که هرچه سنگ قوی‌تر باشد، مدول الاستیسیته بالاتری دارد. البته باید به این نکته توجه شود که این رابطه به طور کاملاً خطی نیست و به نوع و بافت سنگ بستگی دارد.

عوامل دیگر

در سنگ‌های رسوبی علاوه بر خصوصیات دانه‌ها (بلورها)، نوع و نحوه‌ی سیمانی شدن نیز اهمیت دارد. البته در مورد سنگ‌های آهکی پارامتر سیمان




شکل ۲. نحوه عملکرد شبکه‌های عصبی مصنوعی

می‌شود. هر لایه شامل نورون‌هایی است که اتصالات وزن‌دار یک سیگنال را از نورونی به نورون دیگر منتقل می‌کنند. جهت انتقال جمع سیگنال‌های وزندار شده، از تابع انتقال استفاده می‌شود. مدل ریاضی شبکه عصبی به صورت (شکل ۳) می‌باشد (Demuth and Beale, 1993).

از نظر نوع اتصال، ساختار شبکه‌های عصبی را می‌توان به دو دسته کلی شبکه‌های پیش‌خور و بازگشتی تقسیم‌بندی نمود. از منظر دیگر، انواع شبکه عصبی مصنوعی عبارتند از: شبکه‌های پس‌انتشار (BP)، شبکه‌های با توابع شعاع مینا (RBF)، شبکه‌های پاد انتشار Counter-propagation شبکه‌های خود سامانده Kohonen و غیره.

ساده‌ترین شکل شبکه عصبی چند لایه از دو لایه ورودی و خروجی تشکیل یافته است که با اضافه نمودن لایه پنهان به پیچیدگی شبکه افزوده



شکل ۳. مدل ریاضی شبکه عصبی مصنوعی

عنوان تقریب زنده‌های جامع معرفی و به یکی از پراستفاده‌ترین و پرکاربردترین شبکه‌ها تبدیل گشته‌اند (Xie et al., 2011). گره‌هایی که در لایه ورودی هستند نورون‌هایی هستند که هیچ عملیاتی

معمولاً شبکه‌های عصبی چند لایه پیش‌خور با حداقل یک لایه پنهان و تابع انتقال سیگموئید، در صورت دارا بودن نورون‌های پنهان به اندازه کافی، قادر به تقریب اکثر توابع با دقت دلخواه می‌باشند. لذا این نوع شبکه‌ها به

متغیرها معنی دار باشد، می توان آن را با الگوهای ریاضی بیان نمود. معمولاً چنین الگویی ممکن است از نوع خطی یا غیر خطی باشد. به معادله ای که رابطه ی بین دو متغیر مستقل و وابسته را نشان می دهد، معادله رگرسیونی می گویند. اگر بتوان الگوی همبستگی را به صورت یک معادله خطی نوشت، رگرسیون خطی بوده و در غیر این صورت رگرسیون را غیرخطی می نامند. هدف از این روش ساخت مدلی است که متغیر وابسته Y را به بیش از یک متغیر مستقل مرتبط سازد. که این رابطه به صورت معادله ی ۳ بیان می شود:

$$y_i = \mu_i + \varepsilon_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (3)$$

در این رابطه μ_i مقدار واقعی متغیر وابسته است، در حالی که مقادیر متغیر مستقل X_1, X_2, \dots, X_p برابر با $X_{i1}, X_{i2}, \dots, X_{ip}$ بوده و $\beta_0, \beta_1, \dots, \beta_p$ ضرایب نامعلوم رگرسیون هستند که μ_i را به $X_{i1}, X_{i2}, \dots, X_{ip}$ مرتبط می سازند و ε_i میزان خطاست (Chatterjee and Hadi, 2013).

بحث

در بررسی های صورت گرفته در مطالعات مرحله اول پروژه های رودبار لرستان، سد و تونل بهشت آباد و تونل سبزکوه، اطلاعات مغزه های تهیه شده مانند چگالی خشک، چگالی اشباع، تخلخل، درصد جذب آب، شاخص دوام، سرعت امواج فشاری (V_p) و برشی (V_s)، مقاومت فشاری تک محوری (UCS)، مدول الاستیسیته (E) و نسبت پواسون (ν) مورد بررسی قرار گرفتند. از گزارش های تهیه شده به علت عدم امکان تهیه این خصوصیات از تمامی مغزه های حفاری، تعداد ۱۲۱ نمونه انتخاب گردید. در (جدول ۱) برخی از خصوصیات آماری پارمترهای مذکور، آورده شده است.

جدول ۱. خصوصیات آماری پارمترهای مؤثر

مقاومت تک محوره (MPa)	چگالی (gr/cm^3)	تخلخل (%)	سرعت موج فشاری (m/s)	مقاومت کششی غیر مستقیم (MPa)	درصد جذب آب (%)	مدول الاستیسیته (Gpa)	عمق (m)
۱۵۴/۱۷	۲/۸۳	۱۰/۵۱	۷۴۱۸/۲۰	۱۴۹/۰۸	۲/۸۶	۱۴۶/۹۰	۵۴۶/۳۵
۱۱۸۷	۲/۴۴	۰/۱۸	۳۱۸۸	۳/۱۰	۰/۱۱	۰/۶۶	۷/۱۰
۳۹/۱۴	۲/۶۹	۲/۵۹	۵۱۹۱/۷۱	۵۱/۸۶	۱/۰۳	۱۴/۹۸	۱۵۷/۵۰
۳۷/۷۷	۲/۷۰	۲/۵۱	۵۲۴۰/۹۰	۵۱/۷۹	۱/۰۵	۱۴/۸۴	۱۲۱/۰۳
۱۸/۸۲	۰/۰۶	۱/۵۸	۷۵۰/۱۶	۱۹/۵۳	۰/۶۶	۷/۰۲	۱۲۴/۵۰

تعداد نمونه ها در کل پروژه ها، اغلب نمونه ها مربوط به پروژه بهشت آباد می باشند. نتایج به دست آمده از طبقه بندی مقاومتی سنگ ها نیز مؤید این مطلب است. که نمونه های پروژه بهشت آباد نسبت مدول بالا و مقاومت متوسط رو به پایین و پایداری دارند و این نتیجه در مورد کل نمونه ها نیز به

بر روی آنها صورت نمی گیرد و در محاسبه تعداد لایه ها نیز مورد استفاده قرار نمی گیرند. گره های لایه خروجی نورون های پاسخ دهنده هستند که پاسخ حل مسئله در آنها نمایان می شود. اغلب بین نورون های ورودی و خروجی نیز نورون های پنهان قرار دارند.

درون هر نورون وزن خاصی است که بر مقادیر ورودی به نورون تأثیر می گذارد. سپس مقادیر وزن دار به توابع انتقال برده می شوند و تابع خروجی مقدار اصلی را به خود می گیرد و با توجه به اینکه آیا جواب مناسب بدست آمده است یا خیر، این مقادیر با بردار هدف مقایسه می شوند و در صورت اختلاف با بردار هدف به عقب برگشت داده می شوند تا وزن های مناسب تری برای آن بردارها انتخاب گردد.

تابع انتقال یک تابع خطی و یا غیرخطی می باشد. از تابع انتقال برای تعیین خصوصیات نورون در راستای حل مسائل مختلف استفاده می شود. برخی از توابع انتقال رایج در شبکه های عصبی عبارتند از: تابع انتقال Hardlimit، تابع انتقال خطی، تابع انتقال سیگموئید. از تابع سیگموئید معمولاً در شبکه های پس انتشار Backpropagation استفاده می شود. این تابع مقادیر ورودی را در محدوده $-\infty$ تا $+\infty$ دریافت کرده و بر اساس (رابطه ۲) مقدار خروجی بین 0 و 1 تولید می نماید (Demuth and Beale, 1993; Galushkin, 2007).

$$\alpha = \frac{1}{1 + e^{-n}} \quad (2)$$

رگرسیون غیر خطی

برای تعیین میزان رابطه بین دو یا چند متغیر، شاخص های متعددی وجود دارد که همه این شاخص ها میزان رابطه ی بین متغیرها را تنها با یک مقدار به نام ضریب همبستگی نشان می دهند. در صورتی که رابطه ی بین

طبقه بندی سنگ های پروژه ها

بر اساس طبقه بندی ISRM سنگ های مورد مطالعه به صورت زیر دسته بندی شده اند: طبق (جدول ۲)، اکثر سنگ های مورد مطالعه نسبت مدول بالا و مقاومت متوسط رو به پایین و پایداری دارند. با توجه به پراکندگی

چشم می خورد.

در واقع می توان این طور نتیجه گرفت که رفتار کل نمونه ها تابع رفتار نمونه های بهشت آباد می باشد. بنابراین در بخش های بعدی به جای استفاده از نتایج تک تک پروژه ها، فقط از نتایج کل پروژه ها استفاده شده است. در این مدل سازی، پارامترهای دخیل به ترتیب اثرگذاری عبارتند از: مقاومت فشاری تک محوری، سرعت موج فشاری و مقاومت کششی غیر مستقیم. طراحی مدل شبکه عصبی مصنوعی در این تحقیق با استفاده از نرم افزار MATLAB، برای پیش بینی مدول الاستیسیته در نظر گرفته شده است. برنامه نوشته شده از چند قسمت کلی تشکیل می شود که عبارتند از: معرفی داده ها به برنامه، نرمال سازی داده ها، ایجاد شبکه، مرحله آموزش و مرحله آزمایش شبکه. در انتها خطای مراحل آموزش و آزمایش تعیین می شود. در این قسمت به ترتیب مراحل طراحی و انتخاب شبکه توضیح داده خواهند شد و سپس نتایج حاصل از بهترین شبکه در پیش بینی آورده می شوند.

مرحله اول: اولین مرحله شناسایی، نوع شبکه و آزمون آن است. در این مطالعه از شبکه های عصبی پیش خور استفاده می شود. زیرا برای تقریب توابع، شبکه های پیش خور نسبت به شبکه های دیگر بهتر عمل می کنند. در این نوع شبکه، خروجی هر لایه ورودی لایه بعدی است و جزء بهترین شبکه

از نوع یادگیری با ناظر و آموزش این نوع شبکه، آموزش پس انتشار خطا می باشد. شبکه چندلایه با الگوریتم پس انتشار به صورت موفقیت آمیز به عنوان ابزار نگاشت یا پیش بینی در زمینه مهندسی ژئوتکنیک استفاده شده است (Sonmez et al., 2006).

مرحله دوم: دومین مرحله انتخاب ورودی های مدل یا همان واحدهای لایه ورودی و یا به عبارت دیگر، متغیرهای توضیحی مدل است که شامل ۶ پارامتر از میان پارامترهای مختلف آزمایش سنگ می باشد. این پارامترها عبارتند از: چگالی اشباع، مقاومت فشاری تک محوره، مقاومت کششی، سرعت موج فشاری، درصد جذب آب، تخلخل و مدول الاستیسیته سنگ بکر.

مرحله سوم: در این مرحله ابتدا داده ها به دو دسته آموزش و آزمون تقسیم شدند. واضح است که در تقسیم داده ها با حالات متفاوتی مواجه هستیم. برای در نظر گرفتن درصد مناسبی از داده ها، شبکه با داشتن ۶ ورودی مذکور در شرایط یکسان و با پارامترهای برابر اجرا شده است. در (جدول ۳) درصد های مختلف آموزش و آزمایش به همراه نتایج آن ها نشان داده شده است.

جدول ۲. نتایج طبقه بندی مقاومت برای نمونه های پروژه ها

کل نمونه ها	رودبار لرستان	سبزکوه	بهشت آباد
نسبت مدول بالا و مقاومت متوسط رو به پایین	نسبت مدول بالا و مقاومت متوسط رو به بالا	نسبت مدول بالا و مقاومت متوسط رو به بالا	نسبت مدول بالا و مقاومت متوسط رو به پایین

جدول ۳. نتایج اختصاص درصد های مختلف به آموزش

درصد نمونه های آزمایش	R ² (train)	R ² (test)	RMSE(train)	RMSE(test)
۳۰٪	۰/۹۴	۰/۸۱	۰/۱۱	۰/۱۷
۲۰٪	۰/۹۳	۰/۸۱	۰/۱۱	۰/۲۰
۲۵٪	۰/۹۴	۰/۸۲	۰/۱۰	۰/۲۱

اجرای برنامه، بهترین مدل انتخاب و با سایر متغیرها ترکیبات سه تایی ساخته می شود. سپس به همین ترتیب ترکیبات چهار تایی و الی آخر ساخته خواهد شد. این روند تا جایی ادامه پیدا خواهد کرد که خطای مدل نسبت به مدل قبل به مقدار قابل توجهی افزایش یابد. ابتدا جهت تعیین عوامل مؤثر در مدل، با ثابت نگه داشتن تمام پارامترهای شبکه می توان هر متغیر را در هر مرحله حذف کرده و نتایج را برآورد نمود. نتایج حاصل از حذف تک پارامترها در (جدول ۴) ارائه شده است.

با توجه به نتایج (جدول ۳)، در این تحقیق تعداد ۳۰٪ داده ها که برابر ۳۶ نمونه می باشد، برای قسمت آزمایش در نظر گرفته شده است.

مرحله چهارم: مرحله تعیین متغیرهای ورودی مناسب است. مجموعه داده ها از ۱۲۱ نمونه تشکیل یافته اند که به طور تصادفی ۷۰٪ آن ها در مرحله آموزش و ۳۰٪ باقیمانده در مرحله آزمایش مورد استفاده قرار می گیرند. روند کلی به این صورت است که ابتدا تمام ترکیبات دوتایی متغیر-ها با مدول الاستیسیته بررسی شده و سپس با توجه به میانگین نتایج ۲۵ بار

جدول ۴. نتایج حاصل از حذف تک تک پارامترها

پارامتر	درصد خطا
مقاومت فشاری تک محوره	۶/۴
سرعت موج فشاری	۲/۲
درصد جذب آب	۰/۳۹
مقاومت کششی غیر مستقیم	۰/۶۱
تخلخل	۰/۳۳
چگالی	۰/۴۴

نتایج بهترین ترکیب مدل‌ها در (جدول ۵) آورده شده است. همانطور که نتایج نشان می‌دهند، با افزایش پارامترهای خطای شبکه نیز افزایش پیدا می‌کند. (جدول ۶)

همان گونه که از (جدول ۴) استنتاج می‌شود، موثرترین پارامتر، مقاومت فشاری تک محوره می‌باشد، چرا که با حذف آن بیشترین خطا در مدل ایجاد می‌شود و پارامترهایی چون درصد جذب آب، چگالی و تخلخل پارامترهایی هستند که با حذف هر یک از آن‌ها احتمال افزایش کارایی مدل وجود دارد.

جدول ۵. نتایج ترکیبات مختلف از پارامترها


ردیف	مدل	$R^2(\text{train})$	$R^2(\text{test})$	RMSE(train)	RMSE(test)
بهترین ترکیب دو تایی	E, σ	۰/۸۷	۰/۸۰	۰/۱۶	۰/۱۹
بهترین ترکیب سه تایی	E, σ, Vp	۰/۸۷	۰/۸۷	۰/۱۳	۰/۲۰
بهترین ترکیب چهار تایی	E, σ, Vp, σ_r	۰/۸۹	۰/۸۹	۰/۱۲	۰/۱۹
بهترین ترکیب پنج تایی	$E, \sigma, Vp, \sigma_r, Wa$	۰/۸۹	۰/۷۸	۰/۱۳	۰/۳۰

جدول ۶. نتایج ترکیبات پنج تایی از پارامترها

ردیف	مدل	نورون بهینه	$R^2(\text{train})$	$R^2(\text{test})$	RMSE(train)	RMSE(test)
۱	$E, \sigma, Vp, \sigma_r, n$	۲	۰/۸۵	۰/۷۶	۰/۱۷	۰/۳۳
۲	$E, \sigma, Vp, \sigma_r, \gamma$	۲	۰/۸۶	۰/۷۷	۰/۱۶	۰/۳۴
۳	$E, \sigma, Vp, \sigma_r, Wa$	۲	۰/۸۹	۰/۷۸	۰/۱۳	۰/۳۰

دارای تأثیر تقریباً یکسانی هستند. در (شکل ۴) رگرسیون میان Wa و n نشان داده شده است.


در این مرحله پارامترهای چگالی، درصد جذب آب و تخلخل مقایسه شده‌اند. پارامترهای تخلخل و درصد جذب آب همان گونه که انتظار می‌رود،



شکل ۴. همبستگی تخلخل و درصد آب سنگ

نهایتاً در این مدل سازی، پارامترهای دخیل به ترتیب اثرگذاری عبارتند از: مقاومت فشاری تک محوری، سرعت موج فشاری و مقاومت کششی غیرمستقیم. مدل ساخته شده شبکه عصبی به صورت (شکل ۵) می باشد.

همان طور که در نمودار (شکل ۴) دیده می شود، تخلخل و درصد جذب آب همبستگی بسیار نزدیکی با یکدیگر دارند ($R^2=0.89$). این مورد می تواند به دلیل نوع حفره های درون سنگ و مرتبط بودن آن ها با یکدیگر در نمونه های مورد مطالعه باشد. در بخش قبل درباره تأثیر پارامتر چگالی بحث شده و نتایج این مرحله مؤثر نبودن این پارامتر را تأیید می نمایند. اضافه شدن تخلخل و درصد جذب آب نیز منجر به افزایش خطا می گردد.



شکل ۵. مدل ساخته شده توسط شبکه عصبی مصنوعی

در این روابط X_i و Y_i ، به ترتیب مقادیر واقعی و پیش بینی شده و \bar{X} و \bar{Y} به ترتیب میانگین مقادیر واقعی و پیش بینی شده و n تعداد داده ها می باشند. این دو معیار به عنوان معیار عملکرد در نظر گرفته شده اند.


از دیگر پارامترهای شبکه تعداد اپوک یا سیکل های آموزش است. تعداد اپوک برای به دست آوردن تعمیم مناسب ساختار شبکه اهمیت دارد. از نظر تئوری، آموزش بیش از حد Over-learning منجر به خطای نزدیک صفر در پیش بینی داده های آموزش شده و ممکن است باعث کم شدن توانایی شبکه عصبی در تعمیم دادن به داده های آزمون شود (Basheer and Hajmeer, 2000; Sonmez et al., 2006).

نقطه ای افزایش خطا در داده های آزمون یا نزدیک ترین نقطه به منحنی آموزش به عنوان تعداد بهینه سیکل ها برای معماری شبکه در نظر گرفته می شود. تعیین شبکه بهینه در (شکل ۶) نشان داده شده است.

مرحله پنجم: در این مرحله، الگوریتم یادگیری و معیار عملکرد انتخاب می شوند. الگوریتم یادگیری شبکه، الگوریتم لونیگ-مارکوارد (trainlm) در نظر گرفته شده است. علاوه بر الگوریتم ذکر شده، در شبکه های پس انتشار از الگوریتم های کاهش شیب و کاهش شیب با مومنتوم نیز استفاده می شود. در این تحقیق از الگوریتم پس انتشار به دلیل گستردگی استفاده از آن در مسائل تخمین و همچنین سریع تر بودن، استفاده شده است. فرآیند انتخاب متغیرهای ورودی به معیار کارایی مدل احتیاج دارد. دو معیار ساده برای ارزیابی کارایی مدل، جذر میانگین مربعات خطا RMSE و نیز مجذور ضریب همبستگی R^2 می باشند که از روابط ذیل به دست می آیند (Heidari et al., 2010):

$$R = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{(\sum (X_i - \bar{X})^2)(\sum (Y_i - \bar{Y})^2)}} \quad \text{رابطه (۴)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad \text{رابطه (۵)}$$



شکل ۶ تغییرات خطای شبکه در اپوک‌های مختلف

یادگیری اولیه به صورت آهسته کم شود (Basheer and Hajmeer, 2000).

نرخ آموزش شبکه، حساس به نرخ یادگیری و ضریب مومنتوم است. در صورتی که نرخ یادگیری کوچک انتخاب شود، نرخ یادگیری ممکن است آهسته گردد، زیرا مقادیر کوچک باعث تغییرات کوچکتری در وزن‌های شبکه می‌شوند. اگر نرخ یادگیری خیلی بزرگ انتخاب شود، باعث نوسان در مرحله آموزش خواهد شد. در این تحقیق جهت نرخ یادگیری، با بررسی مطالعات پیشین در این زمینه (Tiryaki, 2008; Sonmez et al., 2006; Heidari et al., 2010; Dehghan et al., 2010) مورد بررسی قرار گرفته‌اند. بازه مذکور به چهار زیر بازه تقسیم و نقطه وسط هر بازه و نیز کوچکترین و بزرگترین عدد بازه به شبکه داده شده‌اند. نتایج این بررسی مطابق (جدول ۷) است.

برای داده‌های مورد بررسی در این تحقیق، مطابق (شکل ۶)، تعداد ۱۰۰ سیکل (epoch) برای شبکه مناسب تشخیص داده شد. وزن‌های اولیه، ضرایب مومنتوم و نرخ یادگیری شبکه در همگرایی قانون یادگیری بازگشتی تأثیر می‌گذارند (Das and Basudhar, 2008). در تحقیقات معمولاً وزن‌های اولیه به صورت مقادیر کوچک تصادفی تنظیم می‌شوند. در این تحقیق نیز وزن‌دهی اولیه بر همین اساس صورت گرفته است. علاوه بر این روش در تحقیقات معدودی نیز از محدوده‌های متفاوتی برای تنظیم وزن‌های اولیه استفاده شده است. مانند: (Tiryaki, 2008) (۰/۱ تا -۰/۱)، (Looney, 1996; Dehghan et al., 2010) (۰/۳ تا -۰/۳)، (Hamid et al., 2010) (۰/۵ تا -۰/۵) و (Ripley, 1993) (۰/۵ تا -۰/۵). مقدار اولیه وزن‌ها اثر مهمی بر معماری و همگرایی شبکه دارد (Fahlman, 1988) و محدوده‌ی خیلی کوچک، منجر به شیب کم خطا شده که ممکن است پروسه

جدول ۷. تأثیر نرخ یادگیری بر شبکه

RMSE(test)	RMSE(train)	R ² (test)	R ² (train)	نرخ یادگیری‌های مختلف
۰/۲۰	۰/۱۱	۰/۸۲	۰/۹۳	۰/۰۱
۰/۱۶	۰/۱۳	۰/۸۲	۰/۹۲	۰/۱۲ (۰-۰/۲۵)
۰/۲۵	۰/۱۲	۰/۷۷	۰/۹۲	۰/۳۷ (۰/۲۵-۰/۵)
۰/۱۹	۰/۱۴	۰/۸۳	۰/۸۹	۰/۷۵ (۰/۵-۱)
۰/۱۸	۰/۱۴	۰/۸۷	۰/۸۸	۰/۹

طبق نتایج (جدول ۷)، نرخ یادگیری در شبکه ۰/۱۲ در نظر گرفته شده است. ضریب مومنتوم اثر پایداری در الگوریتم بازگشتی دارد (Negnevitsky, 2005). مقادیر پیشنهادی برای این پارامتر عبارتند از: ۰/۴ تا ۰/۹ (Wythoff, 1993)، ۰ تا ۱ (Fu, 1994) و ۱

طبق نتایج (جدول ۷)، نرخ یادگیری در شبکه ۰/۱۲ در نظر گرفته شده است. ضریب مومنتوم اثر پایداری در الگوریتم بازگشتی دارد (Negnevitsky, 2005). مقادیر پیشنهادی برای این پارامتر عبارتند از: ۰/۴ تا ۰/۹ (Wythoff, 1993)، ۰ تا ۱ (Fu, 1994) و ۱

جدول ۸. مقادیر مختلف ضریب مومنتوم

RMSE(test)	RMSE(train)	R ² (test)	R ² (train)	نرخ یادگیری های مختلف
۰/۱۶	۰/۱۴	۰/۸۶	۰/۹۰	۰/۰۱
۰/۱۸	۰/۱۲	۰/۸۵	۰/۹۳	۰/۱۲ (۰-۰/۳۵)
۰/۱۸	۰/۱۵	۰/۸۴	۰/۸۸	۰/۳۷ (۰/۲۵-۰/۵)
۰/۱۷	۰/۱۵	۰/۸۶	۰/۸۷	۰/۷۵ (۰/۵-۱)
۰/۱۸	۰/۱۵	۰/۸۴	۰/۸۸	۰/۹

صورت نمی پذیرد.

از طرف دیگر اگر تعداد لایه میانی بیش از حد لزوم باشد شبکه نگاشت غیرخطی پیچیده‌ای تولید می‌کند که داده‌های آموزشی را به خوبی یاد می‌گیرد (حفظ می‌کند)، اما در مقابل داده‌های جدید عملکرد مناسبی ندارد و در واقع شبکه قدرت تعمیم خود را از دست می‌دهد. به همین منظور یک سری روابط پیشنهادی بر اساس نورون‌های ورودی و خروجی به صورت خلاصه در (جدول ۱۰) آورده شده‌اند (Sonmez et al., 2006).

N_i و N_o به ترتیب تعداد نورون‌های ورودی و خروجی می‌باشند.

تعداد نورون‌های لایه مخفی با توجه به (جدول ۱۰) از ۱ تا ۹ تغییر می‌کند. در این مطالعه با بررسی این بازه توسط شبکه، این محدوده به برنامه داده شده و با ثابت بودن سایر پارامترها بهترین ترکیب مدل با ۴ نورون مناسب تشخیص داده شده است.

پرکاربردترین توابع فعالسازی برای تخمین، توابع تانژانت، هیپربولیک، سیگموئید و لگاریتم سیگموئید می‌باشند (Sonmez et al., 2006). نتایج حاصل از ۲۵ بار اجرای برنامه بر روی مدل نهایی در (جدول ۱۱) ارائه شده است.

با توجه به نتایج (جدول ۱۱)، تعداد نورون‌های لایه مخفی ۴ نورون انتخاب شده است. قبلاً این نتیجه از شبکه عصبی با بررسی بازه ۲ تا ۹ نورون به دست آمده بود. علاوه بر تعداد نورون به کمک این نتایج نوع تابع فعالسازی نیز تعیین می‌شود. همانگونه که نتایج نشان می‌دهند، شبکه با ۴ نورون و تابع $tansig$ دقت خوبی دارد. با زیادتر شدن تعداد نورون، شبکه پیچیده‌تر شده و دقت پایین می‌آید. اگرچه در مرحله آموزش، نتایج بهبود یافته‌اند، اما این مسئله می‌تواند به دلیل حفظ کردن شبکه و نه یادگیری آن باشد، زیرا در مرحله آزمون دقت نهایی پایین می‌آید.

با توجه به مراحل ذکر شده بالا، برای مطالعه تعداد زیادی شبکه طراحی و هرکدام چندین بار مورد آزمون قرار گرفتند و در نهایت شبکه عصبی با دو لایه و چهار نورون در لایه مخفی و یک نورون در لایه خروجی و یک سری داده در لایه ورودی انتخاب شد که به صورت ANN34 دارای ۳ ورودی و ۴ نورون نشان داده می‌شود. نمودار نتیجه آموزش و آزمایش داده‌ها در (شکل ۷) آورده شده است.

همانگونه که در (جدول ۸) نشان داده شده است، به ازای ضریب مومنتوم‌های متفاوت، تغییرات محسوسی مشاهده نمی‌شود. می‌توان نتیجه گرفت ضریب مومنتوم در الگوریتم لونیبرگ-مارکوارت پارامتر مهم و اثرگذاری نمی‌باشد. در این مدل نیز از اثر دادن این پارامتر صرف نظر شده است پارامترهای شبکه به صورت (جدول ۹) در برنامه استفاده شده‌اند.

جدول ۹. پارامترهای شبکه عصبی

۱۰۰	اپوک
۰/۱۲	نرخ یادگیری
لونیبرگ-مارکوارت (trainlm)	قانون یادگیری
tansig	تابع عملکرد

مرحله ششم: در این مرحله، تعداد لایه‌های شبکه انتخاب می‌شود. همانطور که پیش‌تر نیز ذکر شد، یک شبکه چندلایه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه مخفی تشکیل یافته است. هر لایه شامل چند نورون می‌باشد. در این مطالعه لایه‌های ورودی و خروجی به ترتیب دارای ۳ و ۱ نورون می‌باشند. در اغلب موارد یک لایه مخفی قادر به تخمین هر تابع پیوسته‌ای می‌باشد (Das and Basudhar, 2008). وجود دو لایه مخفی معمولاً برای توابع دارای ناپیوستگی لازم خواهد شد (Hecht-Nielsen, 1987; Sonmez et al., 2006). بنابراین در این مطالعه از یک لایه مخفی استفاده شده است.

مرحله هفتم: در این مرحله، توابع فعال سازی مختلف برای لایه‌های شبکه انتخاب می‌شوند و با سعی و خطا و توجه به نتایج حاصل از شبکه، تعداد نورون و نوع تابع فعال‌سازی مناسب تعیین خواهند شد.

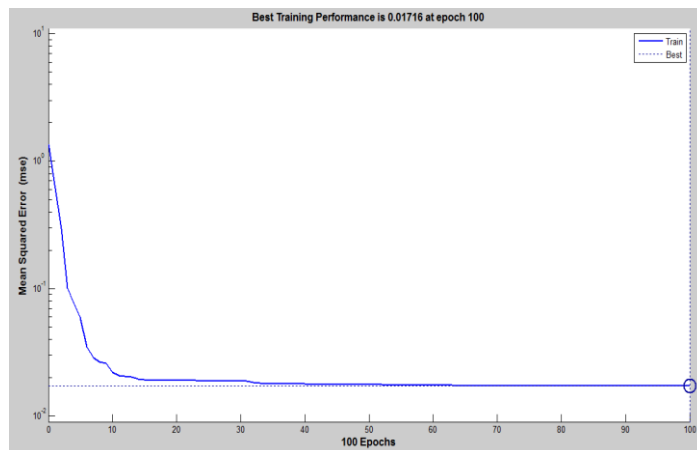
مرحله هشتم: در این مرحله، تعداد نورون‌های لایه مخفی تعیین می‌شوند. تعداد نورون‌ها در این لایه نقش مهمی در قدرت شبکه خواهند داشت. در صورتی که تعداد نورون‌ها خیلی کم باشد، شبکه نمی‌تواند نگاشت غیرخطی بین ورودی و خروجی را با دقت لازم منعکس کند و تخمین به درستی

جدول ۱۰. روابط پیشنهادی جهت تعیین تعداد نورون‌های لایه مخفی (Sonmez et al., 2006)

محققان	تعداد نورون محاسبه شده برای این مطالعه	روابط
(Hecht-Nielsen, 1987)	≤ 7	$\leq 2 \times N_i + 1$
(Hush, 1989)	۹	$3N_i$
(Ripley, 1993)	۲	$(N_i + N_o)/2$
(Paola, 1994)	۱	$\frac{2 + N_o \times N_i + 0.5N_o \times (N_o^2 + N_i) - 3}{N_o + N_i}$
(Wang, 1994)	۲	$2N_i/3$
(Kaastra and Boyd, 1996)	۱	$\sqrt{N_i \times N_o}$
(Kanellopoulos and Wilkinson, 1997)	۶	$2N_i$

جدول ۱۱. نتایج شبکه عصبی حاصل از ۲۵ بار اجرای برنامه برای توابع و نورون‌های مختلف

RMSE(test)	RMSE(train)	$R^2(\text{test})$	$R^2(\text{train})$	نوع تابع فعالسازی	تعداد نورون	مدل نهایی
۰/۱۷	۰/۱۴	۰/۸۸	۰/۸۹	tansig	۲	E, σ, Vp, σ_f
۰/۱۵	۰/۱۵	۰/۸۲	۰/۸۹	Logsig		E, σ, Vp, σ_f
۰/۲۰	۰/۱۲	۰/۸۲	۰/۹۲	tansig	۳	E, σ, Vp, σ_f
۰/۱۷	۰/۱۴	۰/۸۶	۰/۹۰	Logsig		E, σ, Vp, σ_f
۰/۱۴	۰/۱۴	۰/۸۸	۰/۸۹	tansig	۴	E, σ, Vp, σ_f
۰/۲۳	۰/۱۱	۰/۸۰	۰/۹۲	Logsig		E, σ, Vp, σ_f
۰/۱۶	۰/۱۳	۰/۸۹	۰/۹۰	tansig	۵	E, σ, Vp, σ_f
۰/۱۹	۰/۱۱	۰/۸۶	۰/۹۲	Logsig		E, σ, Vp, σ_f
۰/۲۱	۰/۱۰	۰/۷۸	۰/۹۵	tansig	۶	E, σ, Vp, σ_f
۰/۲۳	۰/۱۱	۰/۸۱	۰/۹۴	Logsig		E, σ, Vp, σ_f
۰/۲۳	۰/۱۰	۰/۷۹	۰/۹۵	tansig	۷	E, σ, Vp, σ_f
۰/۱۶	۰/۱۱	۰/۷۸	۰/۹۵	Logsig		E, σ, Vp, σ_f
۰/۲۶	۰/۰۸	۰/۷۴	۰/۹۷	tansig	۸	E, σ, Vp, σ_f
۰/۲۳	۰/۱۱	۰/۸۱	۰/۹۴	Logsig		E, σ, Vp, σ_f
۰/۲۳	۰/۱۰	۰/۸۳	۰/۹۴	tansig	۹	E, σ, Vp, σ_f
۰/۲۷	۰/۰۹	۰/۷۶	۰/۹۵	Logsig		E, σ, Vp, σ_f



شکل ۷. روند کاهش خطا در شبکه

میزان تأثیر هر کدام مشخص می‌گردد. با توجه به نتایج (جدول ۱۲) درصد تأثیرگذاری پارامترها بر روی مدول الاستیسیته طبق (جدول ۱۳) می‌باشد.

همانطوریکه اشاره شد، مدل نهایی بهینه متشکل از پارامترهای مرتبط مقاومت فشاری تک محوری، سرعت موج فشاری و مقاومت کششی غیرمستقیم تشخیص داده شد. با حذف هر یک از این پارامترها از مدل اصلی،

جدول ۱۲. حذف پارامترها مؤثر در مدل به صورت تک تک

مدل نهایی	تعداد نورون	نوع تابع فعالسازی	$R^2(\text{train})$	$R^2(\text{test})$	RMSE(train)	RMSE(test)
E, V_p, σ_r	۴	tansig	۰/۳۷	۰/۱۵	۰/۲۹	۰/۵۰
E, σ, σ_r	۴	tansig	۰/۸۸	۰/۷۶	۰/۱۵	۰/۲۱
E, σ, V_p	۴	tansig	۰/۹۰	۰/۸۴	۰/۱۳	۰/۱۹

جدول ۱۳. درصد تأثیر پارامترها

پارامترها	مقاومت فشاری تک محوره	مقاومت کششی برزیلی	سرعت موج فشاری
درصد تأثیر	٪ ۶۶	٪ ۱۰/۵	٪ ۱۹

مدل می‌باشد، مدل می‌شوند و وابسته به یک یا چند متغیر مستقل شناخته می‌شوند. برخی روابط رگرسیون غیرخطی قابل تبدیل به نوع خطی می‌باشند. معادله نشان دهنده‌ی این مدل می‌تواند به شکل خطی زیر نوشته شود (Heidari et al., 2010).

$$Y = aX_1^{b_1} X_2^{b_2} \dots X_n^{b_n} \quad \text{رابطه (۶)}$$

که در این رابطه Y مقدار پیش بینی شده مورد نظر، a جدا کننده، X_1 ، X_2 ، و X_n پیش بینی کننده‌ها و b_1 ، b_2 ، و b_n ضرایب رگرسیونی

بررسی کلی بر روی نتایج نشان می‌دهد که به طور کاملاً مشخص مقاومت فشاری سنگ‌ها بزرگتر از مقاومت کششی آن‌هاست. در این تحقیق نیز با توجه به ضرایب تعیین و نیز درصد تأثیر پارامترها این مسئله روشن می‌گردد.

روش رگرسیون غیرخطی

در بررسی آماری رگرسیون غیر خطی از نرم افزار SPSS استفاده شده است. در آمار، رگرسیون غیرخطی شکلی از تحلیل رگرسیون است که در آن داده‌های مشاهده‌ای توسط تابعی که خود ترکیب غیرخطی از پارامترهای

رابطه (۸) $Y' = a' + b_1 X_1' + b_2 X_2' + \dots + b_n X_n'$ می‌باشند. با لگاریتم گرفتن از دو طرف معادله داریم:
 رابطه (۷) $\log Y = \log a + b_1 \log X_1 + b_2 \log X_2 + \dots + b_n \log X_n$
 رابطه ۴ به صورت تابع رگرسیونی خطی زیر می‌تواند نوشته شود:
 در این تحقیق کلیه داده‌ها وارد نرم افزار شده و نتایج آن به صورت (جدول ۱۴) می‌باشد.

جدول ۱۴. نتایج حاصل از رگرسیون غیر خطی لگاریتمی

مدل	R^2	تعدیل شده R^2	RMSE	آماره دوربین واتسون
E, σ, Vp, σ_e	۰/۸۹	۰/۸۸	۰/۲۰	۱/۸۰

هریک از پارامترهای مستقل جداگانه، انواع رگرسیون غیر خطی برازش داده شده و بهترین برازش انتخاب گردیده و آن‌گاه میان همه‌ی پارامترهای مستقل و مدول الاستیسیته، رگرسیون خطی مناسب برقرار شده است. نتایج رگرسیون غیر خطی بین تک‌تک متغیرها در (جدول ۱۵) نشان داده شده است. مقدار ضریب همبستگی و جذر میانگین مربعات خطاها در (جدول ۱۶) آورده شده است.

آماره‌ی دوربین واتسون معیاری برای اعتبارسنجی مدل رگرسیون می‌باشد. هرچه این معیار به ۲ نزدیک‌تر باشد، رگرسیون قابل اعتمادتر است که در این‌جا این عدد ۱/۸ به دست آمده است.

با استخراج ضرایب، معادله رگرسیون به صورت زیر خواهد بود:

رابطه (۹) $\log E = -4.3 + 0.95\sigma + 0.027\sigma_e + 0.422Vp$
 در این مطالعه نوع دیگری از رگرسیون غیر خطی بین پارامترها در نظر گرفته شده است. بدین صورت که ابتدا بین دو متغیر مدول الاستیسیته و

جدول ۱۵. رگرسیون غیر خطی بین متغیرها

متغیرها	بهترین برازش	R^2	نوع معادله
E, σ_e	$E = 0.44\sigma_e^{0.96}$	۰/۸۸	توانی
E, Vp	$E = 11.47 \ln(Vp) - 83.029$	۰/۰۶	لگاریتمی
E, σ_e	$E = 2.54\sigma_e^{0.42}$	۰/۱۱	توانی

جدول ۱۶. نتایج حاصل از رگرسیون غیر خطی


مدل	R^2	R^2 adjusted	RMSE	آماره دوربین واتسون
E, σ, Vp, σ_e	۰/۸۷	۰/۸۶	۲/۵۵	۱/۳۰

در (شکل ۸) نمودار مقادیر تخمین زده شده توسط معادله رگرسیون غیر خطی در برابر مقادیر آزمایشگاهی، مشاهده می‌گردند.

در نهایت معادله رگرسیون به دست آمده برابر است با:

رابطه (۱۰) $E = 0.41\sigma_e^{0.96} - 0.35\sigma_e^{0.42} + 6.5 \ln(Vp) - 52.72$

Normal P-P Plot of Regression Standardized Residual



شکل ۸. نمودار مقادیر تخمین مدول الاستیسیته توسط معادله رگرسیون غیرخطی در برابر مقادیر مشاهده شده این پارامتر

جنس داده‌های مورد بررسی به شبکه جهت آزمایش داده شده است. تعداد این داده‌ها تقریباً حدود داده‌های آزمایش که قبلاً به شبکه داده شده، در نظر گرفته شده است. پارامترهای آماری این داده‌ها مطابق (جدول ۱۷) است. بنابراین تعداد ۲۸ داده وارد شبکه شده و نتایج خروجی و معیارهای عملکرد به صورت (جدول ۱۸) به دست آمده‌اند.

با مقایسه نتایج حاصل از هر دو روش می‌توان نتیجه گرفت شبکه عصبی، ضریب تعیین را نسبت به رگرسیون به اندازه‌ی ۱۰/۴۶٪ افزایش و میزان خطا را به اندازه‌ی ۹۳٪ کاهش داده است. نتایج برتری قابل توجه شبکه عصبی را نسبت به روش رگرسیون غیر خطی در تخمین پارامتر مدول الاستیسیته نشان می‌دهند.

بررسی اعتبار شبکه

جهت بررسی صحت نتایج به دست آمده از شبکه، یکسری نمونه مشابه

جدول ۱۷. مقادیر آماری داده‌های اعتبارسنجی

مدول الاستیسیته (Gpa)	مقاومت کششی غیر مستقیم (Mpa)	سرعت موج فشاری (m/s)	مقاومت تک محوره (Mpa)	
۳۹/۷۶	۱۰/۱۶۲	۶۳۱۹	۹۷/۸۳	حداکثر
۱۰/۴۸	۱۰/۴۲	۴۲۴۰/۴	۱۲/۹۰	حداقل
۱۸/۶۲	۵۵/۸۹	۵۲۷۵/۴	۴۹/۶۷	میانگین
۱۷/۴۷	۶۱/۳۵	۵۱۷۰/۱۵	۴۳/۱۲	میانه
۷/۰۲	۲۰/۸۳	۵۹۷/۲۰	۲۰/۵۳	انحراف معیار استاندارد

جدول ۱۸. مقایسه مقادیر (E) به دست آمده از شبکه و مقادیر واقعی

ردیف	مقدار به دست آمده توسط شبکه	مقدار واقعی	ردیف	مقدار به دست آمده توسط شبکه	مقدار واقعی
۱	۲۰/۲۵	۲۰/۹۱	۱۵	۱۵/۸۲	۱۴/۸۹
۲	۲۷/۰۳	۲۷/۳۸	۱۶	۱۹/۷۸	۱۹/۰۶
۳	۱۱/۱۵	۱۰/۴۸	۱۷	۱۰/۰۷	۱۱/۲۲
۴	۱۹/۴۰	۱۹/۰۲	۱۸	۱۲/۴۰	۱۲/۰۹
۵	۱۹/۰۶	۱۸/۸۵	۱۹	۱۴/۹۰	۱۴/۸۶
۶	۲۰/۵۲	۲۰/۶۷	۲۰	۱۸/۳۹	۱۸/۶۶
۷	۱۰/۹۸	۱۰/۷۶	۲۱	۱۱/۳۹	۱۰/۵۲
۸	۱۶/۷۲	۱۷/۵۲	۲۲	۱۴/۴۴	۱۵/۸۹
۹	۱۶/۷۰	۱۶/۰۲	۲۳	۱۷/۵۴	۱۷/۴۲
۱۰	۱۴/۵۱	۱۳/۵۱	۲۴	۲۶/۵۴	۲۶/۸۳
۱۱	۱۲/۰۴	۱۱/۹۸	۲۵	۳۰/۴۳	۳۰/۵۳
۱۲	۳۸/۶۵	۳۹/۷۶	۲۶	۲۵/۸۹	۲۶/۰۴
۱۳	۱۵/۴۰	۱۵/۰۰	۲۷	۳۰/۳۰	۳۰/۰۶
۱۴	۱۴/۱۳	۱۳/۰۶	۲۸	۱۸/۳۷	۱۸/۴۸

مقادیر تابع عملکرد مطابق (جدول ۱۹) می باشد. همانگونه که در (جدول ۱۹) نشان داده شده است، نتایج به دست آمده از اعتبارسنجی بسیار نزدیک به نتایج به دست آمده از مدلسازی شبکه بر روی داده‌های پیشین می‌باشند.

به طوریکه R^2 و RMSE به ترتیب ۹/۱٪ (۰/۸۸--۰/۸۰) و ۲۱/۴٪ (۰/۱۷) - (۰/۱۴) تغییر داشته‌اند.

جدول ۱۹. نتایج حاصل از شبکه عصبی برای داده‌های اعتبارسنجی

RMSE	R^2	
۰/۱۷	۰/۸۰	نتایج داده‌های اعتبارسنجی

نتیجه گیری

بهینه شبکه عصبی انتخاب گردیده است. با افزودن تعداد نورون‌ها، شبکه پیچیده تر شده و دقت پایین می‌آید. با مقایسه نتایج حاصل از دو روش تخمین توسط معیارهای ضریب تعیین R^2 و جذر مجموع مربعات خطا RMSE نتیجه گرفته شده که کاربرد شبکه عصبی ضریب تعیین را نسبت به رگرسیون به اندازه‌ی ۱۰/۴۶٪ افزایش و میزان خطا را به اندازه‌ی ۹۳٪ کاهش داده است و نتایج برتری قابل توجه مدل شبکه عصبی را نسبت به روش رگرسیون غیر خطی در تخمین پارامتر مدول الاستیسیته نشان می‌دهند. با افزایش پارامترها، خطای شبکه نیز افزایش پیدا نموده است. جهت تعیین عوامل مؤثر در مدل شبکه عصبی، با ثابت نگاه داشتن تمام پارامترهای شبکه، هر متغیر را در هر مرحله حذف نموده و نتایج بررسی شده است. مؤثرترین پارامتر، مقاومت فشاری تک محوره می‌باشد، چرا که با حذف آن بیشترین خطا در مدل (۶/۴٪) ایجاد می‌شود و سرعت موج فشاری (۲/۲٪) دومین پارامتر مهم می‌باشد. پارامترهایی چون درصد جذب آب، چگالی و تخلخل پارامترهایی هستند که با حذف هر یک از آن‌ها کارایی مدل افزوده می‌گردد. بنابراین در این مدل‌سازی، مقاومت فشاری تک محوری، سرعت موج فشاری و مقاومت کششی غیرمستقیم، پارامترهای دخیل به ترتیب اثرگذاری در عملکرد شبکه عصبی می‌باشند.

قدردانی

از تحصیلات تکمیلی دانشگاه اصفهان که با حمایت‌های مالی زمینه انجام این تحقیق را فراهم نمودند و همچنین از شرکت آب منطقه‌ای اصفهان برای در اختیار گذاردن داده‌های مورد نیاز تقدیر و تشکر می‌شود.

پارامتر مدول الاستیسیته یک خصوصیت مهم مهندسی سنگ است که در طبقه‌بندی مهندسی سنگ بکر، بررسی معیارهای شکست سنگ و در مرحله طراحی بسیاری از پروژه‌های عمرانی نظیر سد، پایداری شیب، احداث تونل و حفاری‌های معدنی کاربرد کلیدی دارد. علاوه بر این، استفاده از مدل‌های تحلیلی و عددی ژئومکانیک نیازمند تعیین این پارامتر می‌باشد. در بسیاری از موارد به دلیل عدم دسترسی به مغزه‌های با کیفیت، تعیین این پارامتر در آزمایشگاه امکان پذیر نبوده و این پارامتر از طریق روابط و مدل‌های ریاضی تخمین زده می‌شود. در این تحقیق از پارامترهای مختلف بدست آمده از آزمایشات سنگ شامل چگالی اشباع، مقاومت فشاری تک‌محوره، مقاومت کششی، سرعت موج فشاری، درصد جذب آب و تخلخل در تخمین مدول الاستیسیته سنگ بکر به توسط مدل‌های رگرسیون غیر خطی و شبکه عصبی بهره گرفته شده است. در مجموع، ۱۲۱ داده حاصل از آزمایشات سنگ سه پروژه بهشت آباد، رودبار لرستان و سبزکوه در تخمین مورد نظر استفاده شده‌اند. بطور تصادفی ۷۰٪ داده‌های مورد استفاده در مرحله آموزش و ۳۰٪ بقیه در مرحله آزمون مدل مورد استفاده واقع شده‌اند. جهت طراحی شبکه عصبی، تعیین مقدار بهینه اجزای شبکه عصبی مورد بررسی قرار گرفته است. در شبکه طراحی شده، تعداد ۱۰۰ سیکل مناسب تشخیص داده شده و تغییر ضریب مومنتم اثری بر روی نتیجه شبکه عصبی در بر نداشته است. با طراحی تعداد زیادی شبکه و انجام آزمون، در نهایت شبکه عصبی با دو لایه و چهار نورون در لایه مخفی، یک نورون در لایه خروجی و یک سری داده در لایه ورودی و بکارگیری تابع tansig به عنوان ساختار

منابع

- شرکت مهتاب قدس، ۱۳۸۳، گزارش مطالعات مرحله دوم طرح سد انحرافی و سیستم انتقال آب سبزکوه.
- شرکت توسعه منابع آب و نیروی ایران، ۱۳۸۵، گزارش آزمایش‌های آزمایشگاهی مکانیک سنگ طرح سد و نیروگاه رودبار لرستان، مطالعات مرحله دوم، وزارت نیرو.
- شرکت آب منطقه‌ای اصفهان، ۱۳۸۳، گزارشات مطالعات پروژه بهشت آباد، شرکت مدیریت منابع آب ایران، وزارت نیرو.
- پسندی، م.، اجل لوییان، ر.، فروغی ابری، ر.، ۱۳۹۲، تخمین خوردن سیمان پرده آب‌بند با استفاده از شبکه‌ی عصبی مصنوعی، زمین شناسی کاربردی پیشرفته، شماره ۷، ص ۳۲-۴۳.
- ذلولی، ا.، خامه‌چیان، م.، نیکودل، م.، ۱۳۹۳، ارزیابی تغییرات مقاومت فشاری تک محوری نمونه‌هایی از تراورتن‌ها در مقابل تبلور نمک با استفاده از مدل تابع زوال، زمین شناسی کاربردی پیشرفته، شماره ۱۲، ص ۱۴-۲۴.
- سازمان زمین شناسی و اکتشافات معدنی کشور، ۱۳۸۷، نقشه پراکندگی سنگ‌های کربناته، مقیاس ۱:۵۰۰۰۰۰.
- Anagnos, J.N., Kennedy.T.W., 1972, Practical method of conducting the indirect tensile test, Center for Highway Research University of Texas at Austin.
- Basheer.I.A., Hajmeer.M., 2000, Artificial neural networks: fundamentals, computing, design, and application, Journal of microbiological methods, Vol:43, No:1, p: 3-31.
- Braspenning.P.J., Thuijsman.F., Weijters.A.J.M.M., 1995, Artificial neural networks: an introduction to ANN theory and practice, Lecture Notes in Computer Science, Springer.
- Broch.E., Franklin.J., 1972, The point-load strength test, International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts, Vol:9, No:6, p: 669-676.
- Chatterjee.S., Hadi.A.S., 2013, Regression analysis by example, John Wiley and Sons, New Jersey.
- Charitaras.B., Auger.F., Mosse.E., 1994, Determination of the moduli of elasticity of rocks. Comparison of the ultrasonic velocity and mechanical resonance frequency methods with direct static methods, Materials and Structures, Vol:27, No:4, p: 222-228.
- Das.S.K., Basudhar.P.K., 2008, Prediction of residual friction angle of clays using artificial neural network, Engineering Geology, Vol:100, No:3, p: 142-145.
- Deere.D.U., Miller.R.P., 1966, Engineering Classification and Index Properties of Intact Rock. Technical Report No. AFWL-TR-65-116, Air Force Weapons Laboratory, Kirkland Air Force Base, New Mexico.

- Dehghan.S., Sattari.G.H., Chehreh Chelgani.S., Aliabadi.M.A., 2010, Prediction of uniaxial compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural networks, *Mining Science and Technology (China)*, Vol:20, No:1, p: 41-46.
- Demuth.H., Beale.M., 1993, *Neural network toolbox for use with MATLAB*.
- Diamantis.K., Gartzos.E., Migiros.G., 2009, Study on uniaxial compressive strength, point load strength index, dynamic and physical properties of serpentinites from Central Greece: test results and empirical relations, *Engineering Geology*, Vol:108, No:3-4, p: 199-207.
- Fahlman.S.E., 1988, An empirical study of learning speed in back-propagation networks, *Carnegie Mellon Report*, No CMU-Cs, pp. 88-162.
- Fu.L.M., 1994, *Neural networks in computer intelligence*, McGraw-Hill, New York.
- Galushkin.A.I., 2007, *Neural networks theory*, Springer, New York.
- Goodman.R.E., 1980, *Introduction to rock mechanics*, John Wiley and Sons, New York.
- Haghejad.A., Ahangari.K., Noorzad.A., Minaeian.B., 2013, Prediction relations between physical and mechanical properties of rocks-A case study: Asmari Formation in Iran, *International Journal of Geosciences Research (IJGR)*, Vol:1, No:1, p: 1-8.
- Hamid.R., Yusuf.K., Rashid.A.K.A., 2010, Optimization of Feed-Forward Neural Networks Configuration used for Bridge Condition Rating Approximation. Latest Trends on Engineering Mechanics, Structures, EMESEG'10 Proceedings of the 3rd WSEAS international conference on Engineering mechanics, structures, engineering geology, p: 408-412.
- Hecht-Nielsen.R., 1987, Kolmogorov's mapping neural network existence theorem, *Proceedings of the international conference on Neural Networks*, IEEE Press, New York, Vol:3, No:3, p: 11-14.
- Heidari.M., Khanlari.G.R., Momeni.A.A., 2010, Prediction of elastic modulus of intact rocks using artificial neural networks and non-linear regression methods, *Australian Journal of Basic and Applied Sciences*, Vol:4, No:12, p: 5869-5879.
- Hertz.J., Krogh.A., Palmer.R.G., 1991, *Introduction to the Theory of Neural Computation*, Addison-Wesley Publishing Co., Redwood City, CA.
- Hoek.E., Diederich.M.S., 2006, Empirical estimation of rock mass modulus, *International Journal of Rock Mechanics and Mining Sciences*, Vol:43, No:2, p: 203-215.
- Hubick.K.T., 1992, *Artificial neural networks in Australia*. Department of. Industry, Technology and Commerce, Commonwealth of Australia, Canberra.
- Hush, D., 1989, Classification with neural networks: a performance analysis, *IEEE International Conference on Systems Engineering*, p: 277-280.
- Jensen.L.R.D., Friis.H., Fundal.E., Møller.P., Jespersen.M., 2010, Analysis of limestone micromechanical properties by optical microscopy, *Engineering Geology*, Vol:110, No:3-4, p: 43-50.
- Kaastra.I., Boyd.M., 1996, Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, Vol:10, No:3, p: 215-236.
- Kanellopoulos.I., Wilkinson.G.G., 1997, Strategies and best practice for neural network image classification, *International Journal of Remote Sensing*, Vol:18, No:4, p: 711-725.
- Khandelwal.M., Singh.T.N., 2009, Correlating static properties of coal measures rocks with P-wave velocity, *International Journal of Coal Geology*, Vol:79, No:1-2, p:55-60.
- Kuhn.H., 2000, *Uniaxial Compression Testing*, Materials Park, OH: ASM International, p: 143-151.
- Lashkaripour.G.R., Nakhaei.M., 2001, A statistical investigation on mudrocks characteristics. In: *Proceedings of the ISRM regional symposium of rock mechanics*. Espoo, Finland, p: 131-136
- Looney.C.G., 1996, Advances in feedforward neural networks: demystifying knowledge acquiring black boxes, *Knowledge and Data Engineering*, IEEE Transactions on, Vol:8, No:2, p: 211-226.
- Negnevitsky.M., 2005, *Artificial Intelligence: A Guide to Intelligent Systems*. Addison Wesley, Harlow, England, 2nd edition.
- Ocak.I., 2008, Estimating the modulus of elasticity of the rock material from compressive strength and unit weight, *Journal-South African Institute of Mining and Metallurgy*, Vol:108, No:10, p: 621-626.
- Ocak.I., 2009, Empirical estimation of intact rock elastic modulus. In: *The 21st international mining congress of Turkey*. Antalya, Turkey, p: 165-172.
- Ocak.I., Evren Seker.S., 2012, Estimation of Elastic Modulus of Intact Rocks by Artificial Neural Network, *Rock Mechanics and Rock Engineering*, Vol:45, No:6, p: 1047-1054
- Okay Aksoy.C., Genis.M., Uyar Aldas.G., Ozacar.V., Ozer.S.C., Yilmaz.O., 2012, A comparative study of the determination of rock mass deformation modulus by using different empirical approaches, *Engineering Geology*, Vol:131-132, p: 19-28.
- Palchik.V., 1999, Influence of porosity and elastic modulus on uniaxial compressive strength in soft brittle porous sandstones, *Rock Mechanics and Rock Engineering*, Vol:32, No:4, p: 303-309.

- Palmstrom.A., Singh.R., 2001, The deformation modulus of rock masses-comparisons between in situ tests and indirect estimates, *Tunnelling and Underground Space Technology*, Vol:16, No:2, p: 115-131.
- Paola.J.D., 1994, Neural network classification of multispectral imagery, The University of Arizona, USA.
- Ripley.B.D., 1993, Statistical aspects of neural networks. In Barndorff-Nielsen.O.E., Jensen.J.L.,Kendall.W.S. (eds) *Networks and Chaos-Statistical and Probabilistic Aspects*. Chapman and Hall, London, p: 40-123
- Rohde.J., Feng.H., 1990, Analysis of the variability of unconfined compression tests of rock, *Rock Mechanics and Rock Engineering*, Vol:23, No:3, p: 231-236.
- Sachpazis.C.I., 1990,Correlating Schmidt hardness with compressive strength and Young's modulus of carbonate rocks, *Bulletin of the International Association of Engineering Geology*, Vol:42, No:1, p: 75-83.
- Shen.J., Karakus.M., Xu.C., 2012, A comparative study for empirical equations in estimating deformation modulus of rock masses, *Tunnelling and Underground Space Technology*, Vol:32, p: 245-250.
- Sonmez.H., Gokceoglu.C., Nefeslioglu.H.A., Kayabasi.A., 2006, Estimation of rock modulus: For intact rocks with an artificial neural network and for rock masses with a new empirical equation, *International Journal of Rock Mechanics and Mining Sciences*, Vol:43, No:2, p: 224-235.
- Tiryaki.B., 2008, Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees, *Engineering Geology*, Vol:99, No:1, p: 51-60.
- Tucker.M.E., 2009, *Sedimentary petrology: an introduction to the origin of sedimentary rocks*: John Wiley and Sons.
- Tuğrul.A., Zarif.I.H., 1999, Correlation of mineralogical and textural characteristics with engineering properties o selected granitic rock from Turkey, *Engineering Geology*, Vol:51, No:4, p: 303-317.
- Wang.C., 1994, A theory of generalization in learning machines with neural application, Doctoral Dissertation, The University of Pennsylvania, USA.
- Wythoff.B.J., 1993, Backpropagation neural networks: a tutorial, *Chemometrics and Inteligent Laboratory Systems*, Vol:18, No:2, p: 115-155.
- Xie.T., Yu.H., Wilamowski.B., 2011, Comparison between Traditional Neural Networks and Radial Basis Function Networks, *IEEE International Symposium on Industrial Electronics*, p: 1194-1199.
- Yagiz, S., 2009, Predicting uniaxial compressive strength, modulus of elasticity and index properties of rocks using the Schmidt hammer, *Bulletin of Engineering Geology and the Environment*, Vol:68, No:1, p: 55-63.
- Zhang.L., Einstein.H.H., 2004, Using RQD to estimate the deformation modulus of rock masses, *International Journal of Rock Mechanics and Mining Sciences*, Vol:41, No:2, p: 337-341.
- Zhang.L., 2005, Engineering properties of rocks, In: Elseviergeoengeering book series, Vol:4, Elsevier, Berlin, p: 180.