

استفاده از روش های مختلف هوشمند در نرم افزار Orange برای تخمین مدول تغییر شکل پذیری توده سنگ

هادی فتاحی^۱، فاطمه جیریایی شرایی^۲

پذیرش مقاله: ۱۴۰۱/۱۲/۲۱

دریافت مقاله: ۱۴۰۱/۰۴/۲۰

چکیده

مدول تغییر شکل پذیری نشان دهنده ی میزان قابلیت تغییر شکل دادن توده سنگ در پاسخ به هرگونه بارگذاری و باربرداری است و به دلیل ابفای نقش در طراحی اکثر سازه های زیرزمینی حائز اهمیت می باشد. این پارامتر به صورت برجا، معمولاً به کمک دو آزمایش بارگذاری صفحه ای و دیلاتومتری انجام می شود که با صرف هزینه و زمان زیادی همراه است. بعلاوه وجود ناپیوستگی ها و درزه و شکاف ها در توده سنگ، تست های آزمایشگاهی بر روی نمونه های استوانه ای نیز با خطا مواجه می شود. امروزه برای تعریف یک رابطه میان یک پارامتر و پارامترهای وابسته آن و ساخت یک مدل برای تخمین یا پیش بینی پارامتر مورد نظر از انواع روش های هوش محاسباتی استفاده می شود و البته نتایج مطلوبی را نیز ارائه می دهند. هدف از این تحقیق به کارگیری این نوع الگوریتم ها به منظور ایجاد یک مدل کارآمد برای پیش بینی مدول تغییر شکل پذیری بر روی یک پایگاه داده می باشد. در این راستا عملکرد سه مدل ایجاد شده توسط روش های شبکه عصبی مصنوعی، نزدیک ترین همسایگی و جنگل تصادفی، به کمک نرم افزار Orange ارزیابی شده اند. نتایج نشان داد مدل شبکه عصبی مصنوعی با $RMSE=0/116$ و $MAE=0/094$ دارای بهترین عملکرد و دقت است. همچنین آنالیز حساسیت پارامترهای ورودی نشان می دهد که پارامتر سیستم طبقه بندی توده سنگ RMR به عنوان یک پارامتر مهم و مؤثر به شمار می رود.

کلید واژه ها: توده سنگ، مدول تغییر شکل پذیری، شبکه عصبی مصنوعی، آنالیز حساسیت، نرم افزار Orange

۱ عضو هیات علمی دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک h.fattahi@arakut.ac.ir

۲ دانشجوی دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

* مسئول مکاتبات

۱. مقدمه

هر روزه ایجاد ساختارهای گوناگونی در زیر زمین یا روی آن بیش از پیش احساس می‌شود و امر طراحی و اجرای آن‌ها را با اهمیت می‌سازد. در مسائل مختلف پارامترهای متفاوتی از خاک و سنگ به نمایندگی از آن‌ها انتخاب شده و شرایط فیزیکی و مکانیکی را بر حسب نیاز بیان می‌کنند. یکی از پارامترهای مهم سنگ که رفتار مکانیکی آن قبل از گسیختگی و شکست را توصیف می‌کند، مدول تغییرشکل پذیری (Deformation Modulus) است. مدول تغییرشکل‌پذیری، مطابق تعریفی که به‌طور رایج مورد استفاده قرار می‌گیرد، نسبت تنش به کرنش متناظر در طول بارگذاری توده سنگ، شامل رفتار الاستیک و غیر الاستیک می‌باشد. وقتی سنگ تحت شرایط تنش محیطی از نوع بارگذاری یا باربرداری قرار می‌گیرد، در صورتی که خواص همگن و همسانگرد داشته باشد، در آن تغییر شکل الاستیک یا برگشت‌پذیر ایجاد می‌شود. اما از آنجاکه اکثر سنگ‌ها دارای درزه و شکاف فراوانی هستند، تحت این شرایط ممکن است رفتار الاستیک نداشته باشند و از این رو برای تعریف ظرفیت سنگ برای تغییر شکل دادن، تحت تنش محیطی، از پارامتر مدول تغییر شکل‌پذیری استفاده می‌شود (Kayabasi et al. 2003). تخمین پارامتر تغییرشکل‌پذیری توده سنگ در تعدادی از پروژه‌ها جزء مسائل حیاتی به‌شمار می‌رود. به‌عنوان مثال در پروژه‌های سدسازی تعیین نادرست این پارامتر ممکن است باعث آسیب رسیدن به دیواره سد و یا جدا شدن دیواره سد از بدنه‌ی آن شود. همچنین در پروژه‌هایی که به تغییر شکل کم نیز حساس هستند نظیر سدهای قوسی، نیروگاه‌های هسته‌ای، تونل‌های تحت فشار و برج‌های مسکونی، تغییرشکل ناهمگن باعث افزایش شدید تنش در سازه می‌شود. بنابراین مدول تغییرشکل‌پذیری بایستی به‌درستی شناخته شده و ارزیابی و

چاره‌اندیشی شود. فاکتورهای بسیاری بر میزان این پارامتر تأثیرگذار هستند، ازجمله می‌توان به برخی از ویژگی‌های ناپیوستگی‌ها مانند چگالی درزه‌ها، جهت‌گیری، زبری، هوازدگی و مواد پرکننده آن‌ها و برخی ویژگی‌های ساختاری مانند تخلخل، رطوبت، دما، عمق، مقاومت فشاری تک محوری سنگ بکر، بافت توده سنگ، نوع سنگ بستر و لایه‌بندی ایجاد شده در آن را نام برد (Sun and Fanourakis 2022). برای به‌دست آوردن مقدار این پارامتر می‌توان از آزمایشات برجا مانند بارگذاری صفحه‌ای (Plate Loading) و دیلاتومتری (Dilatometer)، آزمون‌های آزمایشگاهی و روابط تجربی استفاده کرد. در بیشتر اوقات پیاده‌سازی و انجام آزمایشات برجا زمان‌بر و هزینه‌بر می‌باشند و همچنین فراهم کردن شرایط واقعی که در زمین بر نمونه حاکم بوده، در آزمایشگاه امکان‌پذیر نیست و یا نتایج فرضی و غیر واقعی استخراج می‌شود (Palmström et al. 2001a). به‌همین دلیل محققان در طول تاریخ برای محاسبه‌ی مدول تغییر شکل‌پذیری توده سنگ همسانگرد روابط تجربی فراوانی را براساس شاخص‌های طبقه‌بندی، مانند شاخص کیفیت تونلسازی (Q)، سیستم طبقه‌بندی توده‌سنگ (RMR)، شاخص مقاومت زمین شناسی (GSI) و تعیین کیفیت سنگ (RQD)، ابداع کرده‌اند. اولین رابطه را بیناوسکی در سال ۱۹۷۳ بین سیستم طبقه‌بندی توده سنگ RMR و مدول تغییر شکل‌پذیری (E_m) مطابق رابطه‌ی ۱ ارائه داد (Galera et al. 2007).

$$E_m = 2RMR - 100 \quad RMR > 55 \quad (1)$$

پس از آن سرافیم و پریرا رابطه‌ی ۲ را براساس RMR ارائه دادند (Serafim and Pereira 1983).

$$E_m = 10^{(RMR-10)/40} \quad (RMR \leq 50) \quad (2)$$

هوک و براون (Hoek et al. 1997)، هوک و همکاران (Hoek

et al. 2002) و بار دیگر هوک و دیدریکس (Hoek et al.

2006) به ترتیب روابط ۱۲ تا ۱۴ را برای پیش‌بینی E_m

براساس GSI و UCS و D (ضریب اغتشاش) پیشنهاد کردند.

$$E_m = \sqrt{\frac{UCS}{100}} \times 10^{\left(\frac{GSI-10}{40}\right)} \quad (12)$$

$$E_m = \left(1 - \frac{D}{2}\right) \sqrt{\frac{UCS}{100}} \times 10^{\left(\frac{GSI-10}{40}\right)} \quad UCS \leq 100 (MPa) \quad (13)$$

$$E_m = \left(1 - \frac{D}{2}\right) \times 10^{\left(\frac{GSI-10}{40}\right)} \quad UCS \geq 100 (MPa)$$

$$E_m = 100.000 \left(\frac{1 - D/2}{1 + e^{((75+25D-GSI)/11)}} \right) \quad (14)$$

$$E_m = E_i \left(0.02 + \frac{1 - D/2}{1 + e^{((60+15D-GSI)/11)}} \right)$$

سونمز و همکاران رابطه‌ی ۱۵ را E_i (مدول الاستیسیته سنگ بکر)، GSI و D ارائه دادند (Sonmez et al. 2004).

$$E_m = E_i (S^a)^{0.4} \quad (15)$$

$$S = \exp\left(\frac{GSI - 100}{9 - 3D}\right)$$

$$a = 0.5 + \frac{1}{6} (e^{-GSI/15} - e^{-20/3})$$

گاردنر (Gardner 1987)، ژانگ و اینشتین (Zhang et al.

2004) به ترتیب روابط ۱۶ و ۱۷ را براساس E_i و RQD

پیشنهاد دادند.

$$E_m = \alpha_E E_i \quad \alpha_E = 0.0231RQD - 1.32 \quad (16)$$

$$\frac{E_m}{E_i} = 10^{0.0186RQD - 1.91} \quad (17)$$

پالمستروم و سینگ روابط ۱۸ را براساس شاخص طبقه‌بندی

توده سنگ RMI ارائه دادند (Palmström et al. 2001b).

$$E_m = 7RMI^{0.4} \quad 1 < RMI < 30 \quad (18)$$

$$E_m = 5.6RMI^{0.375} \quad 0.1 < RMI$$

کوچ اوغلو و همکاران رابطه ۱۹ را براساس UCS، RQD و

درجه هوازدگی سنگ (WD) پیشنهاد دادند (Gokceoglu et

al. 2003).

ورمن و همکاران سپس رابطه‌ی ۳ را براساس RMR، وزن

روباره H و پارامتر کمکی α به‌دست آوردند (Verman et al.

1997).

$$E_m = 0.3H^\alpha \times 10^{\frac{RMR-20}{38}} \quad (3)$$

$$0.16 < \alpha < 0.3$$

نیکلسون و بیناویسکی فرمولی مطابق رابطه ۴ شامل مدول

الاستیسیته سنگ بکر و RMR پیشنهاد کردند (Nicholson et

al. 1990).

$$E_m \quad (4)$$

$$= E_i \left[0.0028RMR^2 + 0.9 \exp\left(\frac{RMR}{22.82}\right) \right] / 100$$

مهرتورا (Mehrotra 1992)، دیدریکس و کایسر (Diederichs

et al. 1999)، رید (Read et al. 1999)، کیم (Kim 1993)،

میتری (Mitri et al. 1995)، روابط ۵ تا ۹ را برای پیش‌بینی

مدول تغییر شکل‌پذیری براساس RMR پیشنهاد کردند.

$$E_m = 10^{(RMR-20)/38} \quad (5)$$

$$E_m = 7(\pm 3)\sqrt{Q'} \quad (6)$$

$$Q' = 10((RMR - 44)/21)$$

$$E_m = 0.1(RMR/10)^3 \quad (7)$$

$$E_m = 300 \exp(0.07RMR) \times 10^{-3} \quad (8)$$

$$E_m = 0.5E_i \left[1 - \cos\left(\pi(RMR/100)\right) \right] \quad (9)$$

گرمستاد و بارتن فرمول تجربی جدیدی را مطابق رابطه‌ی

۱۰ براساس سیستم Q استخراج کردند (Grimstad and

Barton 1993).

$$E_M = 25 \log_{10} Q \quad \text{for } Q \geq 30 \quad (10)$$

$$E_M = 8Q^{0.4} \quad \text{for } 1 \leq Q \leq 30$$

بارتن همچنین فرمول ۱۱ شامل Q و UCS (مقاومت فشاری

تک محوره) را برای تخمین مدول تغییر شکل‌پذیری به‌دست

آورد (Barton and sciences 2002).

$$E_m = 10Q_c^{\left(\frac{1}{3}\right)} \quad Q_c = Q \times \frac{UCS}{100} \quad (11)$$

(et al. 2010). غلام‌نژاد و همکاران (۲۰۱۳) نتایج یک مطالعه در کاربرد تکنیک شبکه عصبی مصنوعی و مدل‌های رگرسیون برای تخمین مدول تغییر شکل‌پذیری توده سنگ ارائه دادند (Gholamnejad et al. 2013). فتاحی (۲۰۱۶) به منظور پیش‌بینی مدول تغییر شکل‌پذیری به ساخت مدل SVR (Support Vector Regression) پرداخت و برای بهینه‌سازی آن از ترکیبی از روش‌های جستجوی هارمونی (Harmony Search)، تکامل تفاضلی (Differential Evolution) و ازدحام ذرات (Particle Swarm Optimization) استفاده کرد (Fattahi 2016). نرم‌افزار Orange با توانایی داده‌کاوی و ایجاد الگوریتم‌های یادگیری ماشین، در بسیاری زمینه‌ها چون پزشکی، کامپیوتر و اطلاعات و علم فیزیک مورد استفاده قرار گرفته است (Elshoush and Dinar 2019; Rebuffi and del Rio 2017). همچنین فتاحی و جیریایی (۲۰۲۱) با به‌کارگیری الگوریتم‌های طبقه‌بندی موجود در نرم‌افزار، به ارزیابی پتانسیل روانگرایی خاک در اثر وقوع زمین‌لرزه پرداختند (فتاحی و جیریایی فردوسی ۲۰۲۱). علاوه بر این، فتاحی و جیریایی (۲۰۲۲) در تحقیقی دیگر از رویکردهای طبقه‌بندی که در نرم‌افزار ایجاد شده‌اند، تزریق‌پذیری خاک‌های دانه‌ای را برای یک پایگاه داده‌ی آزمایشگاهی، پیش‌بینی کردند (فتاحی and معدن ۲۰۲۲).

هدف از این تحقیق تعریف یک مدل پیش‌بینی مدول تغییر شکل‌پذیری توسط روش‌های شبکه عصبی مصنوعی، نزدیکترین همسایگی و جنگل تصادفی و همچنین معرفی نرم‌افزار Orange در راستای این هدف می‌باشد. مدل‌سازی‌ها بر روی یک پایگاه داده شامل ۶۰ نمونه با چهار پارامتر ورودی سیستم طبقه‌بندی توده سنگ RMR، مقاومت فشاری تک محوره UCS، عمق D و مدول الاستیسیته E_i و پارامتر خروجی مدول تغییر شکل‌پذیری انجام می‌شود. بعلاوه آنالیز

$$E_m = 0.001 \left[\frac{\left(\frac{E_i}{UCS} \right) \left(1 + \frac{RQD}{100} \right)}{WD} \right]^{1.5528} \quad (19)$$

کیاباسی و همکاران رابطه ۲۰ را بر اساس WD ، E_i و RQD ارائه کردند (Kayabasi et al. 2003).

$$E_m = 0.135 \left[\frac{E_i (1 + RQD/100)}{WD} \right]^{1.1811} \quad (20)$$

$$E_m = 0.1423 \left[\frac{E_i (1 + \frac{RQD}{100})}{WD} \right]^{1.1747}$$

این نوع روابط، به دلیل وجود ساختارهای پیچیده در مجموعه داده‌های متفاوت، دقت و کارایی خود را نسبت به روش‌های نوین هوش مصنوعی (Artificial Intelligence) از دست داده‌اند. روش‌های مختلف هوش مصنوعی در عرصه‌های گوناگون مسائل پیش‌بینی و تخمین را با عملکرد مطلوب و دقت بسیار بالایی حل می‌کنند. از جمله پژوهش‌هایی که در این راستا انجام شده‌اند به شرح زیر است:

گوکچه اغلو و همکاران (۲۰۰۴) به‌ساخت یک سیستم عصبی فازی متشکل از دو ورودی، یک خروجی و سه لایه برای تخمین مدول تغییر شکل‌پذیری توده سنگ پرداختند و در مجموع به ۱۸ قانون فازی اگر-آنگاه رسیدند (Gokceoglu et al. 2004). چون و همکاران (۲۰۰۹) مقدار مدول تغییر شکل‌پذیری را بر اساس یک تجزیه و تحلیل چند جمله‌ای و چندگانه به طور غیر مستقیم برآورد کردند و در آن پارامتر طبقه‌بندی توده سنگ RMR را به عنوان پارامتر ورودی انتخاب کردند (Chun et al. 2009). مجیدی و بیکی (۲۰۱۰) کارایی الگوریتم ژنتیک در طراحی و بهینه‌سازی ساختاری یک مدل شبکه عصبی مصنوعی و کاربرد آن برای پیش‌بینی مدول تغییر شکل‌پذیری توده سنگ بررسی کردند. آن‌ها از GA برای یافتن تعداد بهینه نوروها در لایه پنهان و ضرایب آن، نرخ یادگیری و لایه خروجی شبکه استفاده کردند (Majdi

مهمترین بخش این روش پردازشگرهایی هستند که نوروں نام دارند. وظیفه‌ی این عضو کشف روابط ذاتی بین داده‌ها است که با تقسیم مسئله به سه لایه ورودی، خروجی و پنهان سعی می‌کند بهترین نگاشت را میان آن‌ها ایجاد کند. مطابق شکل ۱، لایه پنهان اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهد. هر شبکه با دریافت مثال‌هایی آموزشی می‌بیند و در نهایت منجر به یادگیری می‌شود. در طی مراحل آموزش، وزن نوروں‌ها در هر لایه را طوری تغییر می‌کند که خطای تخمین پارامتر خروجی به حداقل برسد. در شرایطی که خطای به دست آمده در حد قابل قبول باشد می‌توان به مدل ساخته شده اعتماد کرد (Wang 2003).


حساسیت پارامترهای ورودی برای تعیین اهمیت آن‌ها اجرا می‌شود.

۲. روش‌های هوش محاسباتی استفاده شده در این تحقیق

در حوزه هوش محاسباتی هر روزه انواع الگوریتم‌ها با رویکردهای متفاوت توسعه یافته‌اند. در اینجا سه مورد از آن‌ها مورد استفاده قرار گرفته است که در ادامه شرح داده خواهد شد.

۲.۱. روش شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی (Artificial Neural Network) روشی است که در مسائل طبقه‌بندی و رگرسیون به کار گرفته می‌شود. زمانی که پارامتر خروجی در داده‌ها از نوع کیفی و کلاس‌بندی شده باشد مسئله از نوع طبقه‌بندی و زمانی که از نوع عددی و پیوسته باشد مسئله از نوع رگرسیون می‌باشد.




شکل ۱: روند کلی عملکرد شبکه عصبی مصنوعی به صورت شماتیک (Althafi 2010; Bazdar et al. 2015).

رگرسیون مورد استفاده قرار می‌گیرد. در این روش پارامتر K نقش کلیدی دارد. K تعداد همسایه‌ها یا نزدیک‌ترین نمونه‌های آموزشی به نمونه مورد نظر است. در رگرسیون KNN ، خروجی برابر با میانگین K نزدیکترین همسایه تعیین

۲.۲. نزدیک‌ترین همسایگی (KNN)

روش نزدیکترین همسایگی (K-fold Nearest Neighbors) یک روش غیر پارامتریک است که در مسائل طبقه‌بندی و

مقداردهی شوند. mtry تعداد متغیرهای کمکی مورد استفاده در هر درخت تصمیم است و می‌تواند از یک تا تعداد کل متغیرهای کمکی باشد. ntree نیز تعداد کل درختان تصمیم است که توسط کاربر و معمولاً از ۵۰۰ تا ۱۰۰۰ انتخاب می‌گردد. شکل ۲ جنگل تصادفی متشکل از سه یا تعداد بیشتری درخت تصمیم را نشان می‌دهد (Pal 2005).



شکل ۲: ورود یک نمونه‌ی آزمایشی (X) به جنگل تصادفی و خروج نتیجه (Y) از آن

۳. معرفی اجمالی نرم‌افزار Orange

نرم‌افزار Orange یک نرم‌افزار متن باز و مبتنی بر زبان برنامه‌نویسی پایتون در حوزه داده‌کاوی است، که در آزمایشگاه بیوانفورماتیک دانشکده علوم کامپیوتر و اطلاعات در دانشگاه لیوبلیانا (Ljubljana) اسلوونی توسعه یافته است. مسائل رگرسیون و طبقه‌بندی را به راحتی می‌توان توسط الگوریتم‌هایی که در این نرم‌افزار موجود است مدل‌سازی و ارزیابی کرد. یا حتی کاربر می‌تواند الگوریتم مورد نظر خود را در آن برنامه‌نویسی کند. علاوه بر این قابلیت‌های مناسبی نیز برای تحلیل‌های آماری و فرآیند پیش‌پردازش داده‌ها در آن وجود دارد. این نرم‌افزار بسیار تعاملی بوده و قابلیت گرافیکی بالایی دارد که کار با آن را برای کاربر لذت بخش می‌کند. سایت www.orangedatamining.com نیز یک پشتیبان قوی برای این نرم‌افزار به شمار می‌رود.

شده می‌باشد. از این نظر که مرحله‌ی یادگیری این روش با مرحله‌ی آزمون یکی است و به‌طور یکجا انجام می‌شود، به آن الگوریتم تنبل نیز گفته می‌شود. نمونه‌های تعیین شده را نیز می‌توان متناسب با فاصله‌ی آن‌ها با نمونه‌ی موردنظر وزن‌دار کرد. همچنین این روش برای یافتن نمونه‌های همسایه از انواع معیارهای تخمین فاصله به خصوص نوع فاصله‌ی اقلیدسی استفاده می‌کند. این فاصله به شکل رابطه‌ی ۲۱ به‌دست می‌آید.

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (21)$$

که در آن X، نمونه‌های تعلیم و Y نمونه‌های مورد آزمایش با تعداد پارامتر i است. پس از آن نمونه‌های تعلیم براساس فاصله‌ی آن‌ها به صورت صعودی مرتب شده و به تعداد K مورد از آن‌ها انتخاب شده و در تخمین متغیر هدف از آن‌ها استفاده می‌شود. بنابراین تعیین تعداد همسایه‌ها (K) یکی از مؤثرترین مراحل این روش است که با سعی و خطا انجام می‌شود (Kramer 2013).

۳.۲. جنگل تصادفی (RF)

روش جنگل تصادفی (Random Forest) از جمله روش‌های درخت پایه به‌شمار می‌رود که برای مسائل رگرسیون و طبقه‌بندی از آن استفاده می‌شود. جنگل تصادفی روش نسبتاً پیچیده‌ای است که با هدف افزایش دقت مدل، در آن چندین درخت تصمیم آموزش داده می‌شود و با هم ترکیب می‌شوند. هر درخت تصمیم با یک نمونه آموزش می‌بیند و انتخاب متغیرهای پیش‌بینی کننده که برای تقسیم گره‌ها به کار می‌رود به صورت تصادفی می‌باشد. در جنگل تصادفی دو ویژگی mtry و ntree ایفای نقش می‌کنند که باید به درستی

ساده برای اجرا کردن و درک کردن می‌باشد و به طور کلی برای درک بهتر داده‌ها مناسب است. در مسائل طبقه‌بندی بررسی ویژگی‌ها به تنهایی به این صورت است که مقدار ویژگی در کلاس‌های متغیر پاسخ مقایسه می‌شود. در واقع برای تشخیص اینکه ویژگی مورد بررسی از نظر آماری در کلاس‌های مختلف تفاوت معناداری دارد یا خیر، از آزمون t، ANOVA و سایر آزمون‌های آماری استفاده می‌شود (Jović et al. 2015).

۵. تحلیل و نتایج

امروزه در تعیین بعضی پارامترهای فیزیکی سنگ از جمله مدول تغییر شکل‌پذیری، از طریق آزمون‌های آزمایشگاهی به دلایل مختلفی چون زمان‌بر بودن، پرهزینه بودن، سخت و در مواردی فاصله گرفتن از شرایط واقعی حاکم بر نمونه، از هوش محاسباتی به عنوان روش جایگزین استفاده می‌شود. در این زمینه روش‌های بسیاری ابداع و در مسائل مختلف صحت سنجی شده‌اند. در این مقاله به منظور ایجاد یک مدل پیش‌بینی برای تخمین مدول تغییر شکل‌پذیری مجموعه داده‌های جمع‌آوری شده از سایت‌های ساخت و ساز جاده‌ای و راه‌آهن در کشور کره، مورد استفاده قرار گرفته است (Chun et al. 2009). این پایگاه داده شامل ۶۰ نمونه می‌باشد که از ۴ پارامتر ورودی سیستم طبقه‌بندی توده سنگ RMR، عمق (D)، مقاومت فشاری تک‌محوره (UCS) و مدول الاستیسیته (E_i) و پارامتر خروجی مدول تغییر شکل‌پذیری (E_m) جمع‌آوری شده است. مقدار مدول تغییر شکل‌پذیری در اکثر نمونه‌ها از طریق تست‌های فشار سنج اندازه‌گیری شده است. برای ارزیابی تغییر شکل‌پذیری توده سنگ، انواع مختلفی از آزمون‌های برجا قابلیت کاربرد دارند، از جمله آزمون

۴. آنالیز حساسیت

تحلیل یا آنالیز حساسیت عبارت است از شناخت تاثیرگذاری متغیرهای مستقل بر متغیر وابسته و بررسی اهمیت آن‌ها نسبت به یکدیگر در یک مجموعه‌ی داده. در مسائل طبقه‌بندی و رگرسیون روش‌های مختلفی برای آنالیز حساسیت ایجاد شده است، که در ادامه به دو مورد از روش‌هایی که برای رتبه‌بندی پارامترهای ورودی به‌کار گرفته شده اشاره خواهد شد.

۴.۱. روش ReliefF

این روش شامل الگوریتمی است که توسط Kira و Rendell در سال ۱۹۹۲ توسعه یافته است و رویکردی با روش فیلتر برای انتخاب ویژگی‌ها دارد و به‌طور قابل‌توجهی به ارتباط بین ویژگی‌ها یا پارامترها حساس است. این روش در ابتدا برای مسائل طبقه‌بندی باینری طراحی شده بود، اما پس از آن برای انواع مسائل پیش‌بینی توسعه یافت. در این روش برای هر ویژگی یک امتیاز محاسبه می‌شود و بر اساس آن ویژگی‌ها رتبه‌بندی و انتخاب می‌شوند. امتیازدهی بر اساس شناسایی تفاوت مقدار ویژگی در جفت نمونه‌های نزدیک به هم انجام می‌شود. به طوریکه اگر تفاوت مقدار ویژگی در یک جفت نمونه همسایه با هم با همان کلاس یا همان مقدار از پارامتر خروجی مشاهده شود امتیاز ویژگی کاهش می‌یابد (Spolaôr et al. 2013).

۴.۲. روش Univariate Regression

روش Univariate Regression یا انتخاب ویژگی تک متغیره، هر ویژگی را به صورت جداگانه بررسی می‌کند تا قدرت رابطه ویژگی با متغیر پاسخ را تعیین کند. این روش، بسیار


ایجاد کند. مزیت اصلی تست فشارسنج نسبت به سایر تست‌ها کم هزینه بودن آن است. به همین دلیل در رابطه با داده‌های حاضر از تست فشارسنج استفاده شده است. شاخص‌های آماری پارامترهای ورودی و خروجی در جدول ۱ آورده شده است و همچنین نمودار فراوانی پارامترها در جدول ۲ نشان داده شده است.

بارگذاری صفحه‌ای به صورت سطحی یا در ته چاه، آزمایش جکینگ شعاعی مانند تست جک گودمن و آزمایش نوع گمانه‌ای آن مانند تست فشار سنج (Pressuremeter test). انواع مختلف آزمایش‌ها برجا مدول تغییر شکل‌پذیری به دلیل بارگذاری و شرایط مرزی متفاوت می‌تواند نتایج مختلفی را ایجاد کنند. از میان آزمایش‌ها، تست فشارسنج توانسته همبستگی خوبی را بین مدول تغییر شکل‌پذیری و RMR

جدول ۱: آماره‌های داده‌ها در پارامترهای ورودی و خروجی مدل‌ها


Parameters	Symbol (Unit)	Min	Max	Mean	STD
Rock Mass Rating System	RMR	21	92	62.23	0.23
Uniaxial Compressive Strength	UCS (Mpa)	12.1	254.8	138.09	0.42
Depth	D(m)	4	166	35.11	1.04
Elastic modulus	E _i (Gpa)	17.1	60.7	49.95	0.21
Deformation modulus	E _m (Gpa)	3.92	45.62	14.59	0.62

جدول ۲: نمودار فراوانی پارامترهای ورودی و خروجی مدل‌ها



در ادامه هدف، به کار گرفتن چند الگوریتم از روش‌های هوش محاسباتی برای ساخت مدل پیش‌بینی پارامتر E_m است. به همین دلیل با بهره‌گیری از نرم‌افزار Orange، ۴ مدل شبکه عصبی مصنوعی (ANN)، نزدیکترین همسایگی (KNN) و جنگل تصادفی (RF) ایجاد شده است. شکل ۳ صفحه‌کار نرم‌افزار Orange با به‌کارگیری عملگرهای مورد نیاز برای مدل‌سازی را نشان می‌دهد. در این شکل عملگرهای استفاده شده، مانند Continuize برای تبدیل داده‌ها (نرمال سازی)، Test and Score برای ارزیابی مدل‌ها، Rank برای رتبه‌بندی پارامترها و Scatter plot برای رسم نمودار پراکندگی پارامترها به‌کار گرفته شده است. نتایج ارزیابی و صحت‌سنجی مدل‌ها در جدول ۳ آورده شده است. در این جدول برای مقایسه عملکرد روش‌ها از سه نوع خطای RMSE، MSE و MAE

استفاده شده است. معیار RMSE نوعی از محاسبه‌ی خطای ایجاد شده در عملیات پیش‌بینی نسبت به مقدار واقعی آن است و مسلماً هرچه مقدار آن کمتر باشد، پیش‌بینی دقیق‌تری انجام شده است. این معیار با جذر گرفتن از خطای MSE، یعنی میانگین مربعات خطا، حاصل می‌شود. بنابراین خطای RMSE برخلاف خطای MSE، بعد و مقیاس آن با پارامتر مورد نظر یکی است. معیار MAE نیز با قدرمطلق گرفتن از خطاها، به‌جای به توان رساندن آن‌ها، یک مقدار با بعد یکسان ارائه می‌دهد، اما در شرایطی مشتق‌پذیر نبوده و می‌تواند در بهینه‌سازی وابسته به گرادیان مشکل‌ساز باشد. این معیارها توسط روابط ۲۲ تا ۲۴ تعریف می‌شوند. به علاوه شاخص RMSE در نمودار ستونی شکل ۴ به صورت گرافیکی به مقایسه خطا و عملکرد مدل‌ها می‌پردازد.



شکل ۳: شمایی از صفحه‌کار نرم‌افزار Orange در پایان مدل‌سازی

$$MSE = \frac{1}{n} \sum_{k=1}^n (t_k - \hat{t}_k)^2 \quad (22)$$


که در آن مقدار اندازه گیری شده پارامتر E_m در نمونه‌ی k ام t_k و مقدار پیش‌بینی شده نظیر آن است و n تعداد نمونه‌ها می‌باشد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (t_k - \hat{t}_k)^2} \quad (23)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |t_k - \hat{t}_k| \quad (24)$$

جدول ۳: نتایج دقت و خطای مدل‌سازی‌های انجام شده

Models	MSE	RMSE	MAE
Artificial Neural Network	0.013	0.116	0.094
K-Nearest Neighbor	0.018	0.134	0.1
Random Forest	0.022	0.15	0.117



شکل ۴: نمایش مقادیر RMSE مدل‌ها به صورت نمودار ستونی

مربوط به مدل RF می‌شود. در مدل‌سازی‌ها و شرکت دادن پارامترهای ورودی متفاوت چیزی که اهمیت پیدا می‌کند، تحلیل حساسیت پارامتر خروجی نسبت به پارامترهای ورودی و پی بردن به نحوه‌ی تاثیرگذاری آنها بر پارامتر خروجی است. در اینجا برای شناخت اهمیت پارامترها و رتبه بندی آنها از دو روش RReliefF و Univariate Regression استفاده شده است. در جدول ۴ به کمک این دو


همانطور که از جدول ۳ استنباط می‌شود، مدل شبکه عصبی مصنوعی از نظر انواع خطاها، نسبت به دو مدل دیگر دقت و عملکرد بهتری داشته است. مقدار معیارهای مورد نظر برای مدل جنگل تصادفی از سه مدل دیگر ضعیف‌تر بوده است. این نتایج را می‌توان در نمودار شکل ۴ نیز مشاهده کرد. کمترین خطای RMSE به مدل شبکه عصبی مصنوعی اختصاص یافته است و بالعکس بیشترین خطای RMSE.

مدول الاستیسیته نیز در پایین‌ترین سطح از اهمیت قرار می‌گیرد. برای درک بهتر این موضوع از دو نمودار پراکندگی E_m نسبت به RMR و UCS در شکل‌های ۵ و ۶ کمک گرفته شده است.


معیار امتیاز متناسب با هر پارامتر برآورد شده و به ترتیب اهمیت آن‌ها در جدول قرار گرفته‌اند. سیستم طبقه‌بندی توده سنگ RMR، بیشترین امتیاز را در هر دو معیار به خود اختصاص داده و بنابراین اهمیت و تأثیرگذاری بالاتری در تخمین مدول تغییر شکل‌پذیری دارد. پس از آن مقاومت فشاری تک محوره و سپس عمق اهمیت بیشتری داشته‌اند.

جدول ۴: رتبه‌بندی و امتیاز دهی پارامترهای ورودی

Parameters	Rank	Univar.Reg	RReliefF
Rock Mass Rating System	1	61.169	0.253
Uniaxial Compressive Strength	2	53.779	0.205
Depth	3	29.691	0.18
Elastic modulus	4	23.489	0.211



شکل ۵: نمودار پراکندگی پارامتر E_m نسبت به RMR



شکل ۶: نمودار پراکندگی پارامتر E_m نسبت به UCS

- مدل‌های ساخته شده به‌طور کلی دارای نتایج خوبی هستند و در پیش‌بینی مدول تغییرشکل‌پذیری به جای روش‌های آزمایشات برجا، آزمون‌های آزمایشگاهی و روابط تجربی می‌توانند مورد استفاده قرار گیرند.

- صحت‌سنجی و ارزیابی مدل‌ها نشان داد مدل شبکه عصبی مصنوعی با $RMSE=0.116$ و $MAE=0.094$ عملکرد بهتری داشته است و مدل جنگل تصادفی نسبت به دو مدل دیگر عملکرد ضعیف‌تری از خود نشان داده است.

- مدل‌سازی‌ها و کدنویسی روش‌های مختلف در انواع برنامه‌های کدنویسی می‌تواند کار سخت و زمان‌بری باشد به همین دلیل نرم افزار Orange گزینه مناسبی برای ساخت مدل‌های پیش‌بینی می‌باشد.

- آنالیز حساسیت پارامترهای ورودی به کمک دو معیار RRelief و Univariate Regression نشان داد دو پارامتر RMR و مقاومت فشاری تک محوره

مطابق واقعیتی که نمودارها نشان می‌دهد، E_m با RMR و UCS همبستگی خوبی را ایجاد کرده است و نقاط دارای یک جهت‌گیری منظمی هستند. ضریب R مربوط به خط برازش شده بر نقاط نیز مشخص شده است که دارای مقادیر بالایی می‌باشد.

۶. نتیجه‌گیری

مدول تغییر شکل‌پذیری سنگ بکر به عنوان یکی از پارامترهای مهم در طراحی سازه‌های زیرزمینی، تخمین مقدار آن به روش‌های کم هزینه‌تر و آسان‌تر اهمیت پیدا می‌کند. در این تحقیق به کمک نرم‌افزار Orange مدل‌هایی توسط سه روش هوش محاسباتی مدل شبکه عصبی مصنوعی، نزدیکترین همسایگی و جنگل تصادفی ساخته شده و برای پیش‌بینی مدول تغییر شکل‌پذیری صحت سنجی شده‌اند. همچنین پارامترهای سیستم طبقه‌بندی توده سنگ RMR، مقاومت فشاری تک محوره، عمق و مدول الاستیسیته به عنوان پارامترهای ورودی و تأثیرگذار بر مدول تغییر شکل‌پذیری انتخاب شده‌اند.

مورد کمترین تاثیرگذاری را دارد.

در روند تخمین مقدار مدول تغییر شکل پذیری
مؤثرتر هستند و همچنین مدول الاستیسیته در این

منابع

فتاحی ه، جیریایی ف (۲۰۲۱) ارزیابی پتانسیل روان‌گرایی خاک در اثر وقوع زمین‌لرزه با استفاده از چند الگوریتم طبقه‌بندی هوشمند در نرم‌افزار Orange مهندسی عمران فردوسی ۳۹:۳۴-۵۲ doi:10.22067/jfcei.2021.70257.1038

فتاحی ه، جیریایی ف (۲۰۲۲) تخمین تزریق‌پذیری خاک‌های دانه‌ای با به‌کارگیری داده‌های آزمایشگاهی و چند روش طبقه‌بندی هوشمند روش‌های تحلیلی و عددی در مهندسی معدن doi:10.29252/anm.2022.16513.1497

- Althafi A (2010) Artificial Neural Networks- The Hot Topic in Recent Pharmaceutical Research. <http://pharmacybooks.blogspot.com/2010/10/artificial-neural-networks-hot-topicpharmaceutical-research.html>
- Barton NJIjorm, sciences m (2002) Some new Q-value correlations to assist in site characterisation and tunnel design International Journal of Rock Mechanics and Mining Sciences 39:185-216
- Bazdar H, Fattahi H, Ghadimi F (2015) Hybrid ANN with Invasive Weed Optimization Algorithm, a New Technique for Prediction of Gold and Silver in Zarshuran Gold Deposit, Iran. Arak University of Technology
- Chun B-S, Ryu WR, Sagong M, Do J-NJIjorm, sciences m (2009) Indirect estimation of the rock deformation modulus based on polynomial and multiple regression analyses of the RMR system International Journal of Rock Mechanics and Mining Sciences 46:649-658
- Diederichs M, Kaiser PJIJoRM, Sciences M (1999) Stability of large excavations in laminated hard rock masses: the voussoir analogue revisited International Journal of Rock Mechanics and Mining Sciences 36:97-117
- Elshoush HT, Dinar EA Using adaboost and stochastic gradient descent (sgd) algorithms with R and orange software for filtering e-mail spam. In: 2019 11th Computer Science and Electronic Engineering (CEECE), 2019 .IEEE, pp 41-46
- Fattahi HJEwC (2016) Application of improved support vector regression model for prediction of deformation modulus of a rock mass Engineering with Computers 32:567-580
- Galera JM, Álvarez M, Bieniawski Z Evaluation of the deformation modulus of rock masses using RMR. Comparison with dilatometer tests. In: Workshop: Underground Works under Special Conditions, 2007. UNDERGROUND WORKS UNDER SPECIAL CONDITIONS ,
- Gardner WS Design of drilled piers in the Atlantic Piedmont. In: Foundations and excavations in decomposed rock of the Piedmont province, 1987. ASCE, pp 62-86
- Gholamnejad J, Bahaaddini H, Rastegar MJJoM, Environment (2013) Prediction of the deformation modulus of rock masses using Artificial Neural Networks and Regression methods Journal of Mining and Environment 4:35-43
- Gokceoglu C, Sonmez H, Kayabasi AJIJoRM, Sciences M (2003) Predicting the deformation moduli of rock masses International Journal of Rock Mechanics and Mining Sciences 40:701-710
- Gokceoglu C, Yesilnacar E, Sonmez H, Kayabasi AJC, Geotechnics (2004) A neuro-fuzzy model for modulus of deformation of jointed rock masses Computers and Geotechnics 31:375-383
- Grimstad E, Barton N Updating of the Q-system for NMT. Int. In: Symposium on Sprayed Concrete-Modern use of wet mix sprayed concrete for underground support, Fagernes (Editors Kompen, Opshall and Berg, Norwegian Concrete Association, Oslo), 1993 .
- Hoek E, Brown ETJIjorm, sciences m (1997) Practical estimates of rock mass strength International Journal of Rock Mechanics and Mining Sciences 34:1165-1186

- Hoek E, Carranza-Torres C, Corkum B. J. P. o. N. - T (2002) Hoek-Brown failure criterion-2002 edition Proceedings of NARMS 1:267-273
- Hoek E, Diederichs M. S. J. I. j. o. r. m, sciences m (2006) Empirical estimation of rock mass modulus International Journal of Rock Mechanics and Mining Sciences 43:203-215
- Jović A, Brkić K, Bogunović N A review of feature selection methods with applications. In: 2015 38th international convention on information and communication technology, electronics and microelectronics (MIPRO), 2015. Ieee, pp 1200-1205
- Kayabasi A, Gokceoglu C, Ercanoglu M. J. I. J. o. R. M, Sciences M (2003) Estimating the deformation modulus of rock masses: a comparative study International Journal of Rock Mechanics and Mining Sciences 40:55-63
- Kim G-W Revaluation of geomechanics classifications of rock masses. In: Proceedings of the Korean geotechnical society of spring national conference, Seoul, 1993. pp 33-40
- Kramer O (2013) K-nearest neighbors. In: Dimensionality reduction with unsupervised nearest neighbors. Springer, pp 13-23
- Majdi A, Beiki M. J. I. J. o. R. M, Sciences M (2010) Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses International Journal of Rock Mechanics and Mining Sciences 47:246-253
- Mehrotra V. J. U. o. R (1992) Estimation of engineering parameters of rock mass University of Roorkee
- Mitri H, Edrissi R, Henning J. T. - S. F. M. M, Incorporated E (1995) Finite-element modeling of cable-bolted stopes in hard-rock underground mines Transactions-Society for Mining Metallurgy 298:1897-1902
- Nicholson G, Bieniawski Z. J. I. j. o. M, engineering g (1990) A nonlinear deformation modulus based on rock mass classification International Journal of Mining and Geological Engineering 8:181-202
- Pal M. J. I. j. o. r. s (2005) Random forest classifier for remote sensing classification International journal of remote sensing 26:217-222
- Palmström A, Singh R. J. T, Technology US (2001a) The deformation modulus of rock masses—comparisons between in situ tests and indirect estimates 16:115-131
- Palmström A, Singh R. J. T, Technology US (2001b) The deformation modulus of rock masses—comparisons between in situ tests and indirect estimates Tunnelling and underground space technology 16:115-131
- Read S, Perrin N, Richards L Applicability of the Hoek-Brown failure criterion to New Zealand greywacke rocks. In: 9th ISRM Congress, 1999. OnePetro ,
- Rebuffi L, del Rio M. S. O. A. S. Y. S (OrAnge SYnchrotron Suite): an open-source graphical environment for x-ray virtual experiments. In: Advances in Computational Methods for X-Ray Optics IV, 2017. SPIE, pp 169-177
- Serafim J, Pereira J Considerations on the geomechanical classification of Bieniawski: experience from case histories. In: Proceedings of symposium on engineering geology and under-ground openings, Lisbon, 1983. pp 1133-1144
- Sonmez H, Gokceoglu C, Ulusay R. J. I. j. o. r. m, sciences m (2004) Indirect determination of the modulus of deformation of rock masses based on the GSI system International Journal of Rock Mechanics and Mining Sciences 41:849-857
- Spolaôr N, Cherman E. A., Monard M. C., Lee H. D. ReliefF for multi-label feature selection. In: 2013 Brazilian Conference on Intelligent Systems, 2013. IEEE, pp 6-11
- Sun R. W., Fanourakis G. C. J. S. C (2022) An assessment of factors affecting the elastic modulus of concrete 23:593-603
- Verman M, Singh B, Viladkar M, Jethwa J. J. R. m, engineering r (1997) Effect of tunnel depth on modulus of deformation of rock mass Rock Mechanics and Rock Engineering 30:121-127
- Wang S-C (2003) Artificial neural network. In: Interdisciplinary computing in java programming. Springer , pp 81-100
- Zhang L, Einstein H. J. I. J. o. R. M, Sciences M (2004) Using RQD to estimate the deformation modulus of rock masses International Journal of Rock Mechanics and Mining Sciences 41:337-341