

## تخمین مدول تغییر شکل پذیری توده سنگ با استفاده از مدل های آماری و هوش مصنوعی

محمد رضائی<sup>\*۱</sup>

۱- دانشیار، گروه مهندسی معدن، دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران.

دریافت: ۱۴۰۳/۰۴/۱۷؛ پذیرش: ۱۴۰۳/۰۶/۳۱

(\*نویسنده مسئول: [m.rezaei@uok.ac.ir](mailto:m.rezaei@uok.ac.ir))

### چکیده

اندازه‌گیری مستقیم مدول تغییر شکل پذیری توده سنگ با استفاده از آزمایش‌های برجا و آزمایشگاهی فرآیندی هزینه‌بر و زمان‌بر است. بنابراین، استفاده از روش‌های غیرمستقیم مانند الگوریتم‌های هوش مصنوعی برای تخمین این پارامتر می‌تواند جایگزینی مفید، سریع و مقرون به صرفه باشد. در این تحقیق، مدل‌سازی مدول تغییر شکل پذیری توده سنگ با استفاده از مدل‌های برنامه‌ریزی بیان ژن (*GEP*)، سیستم استنتاج فازی (*FIS*) و رگرسیون خطی چند متغیره (*MLR*) انجام گرفته است. داده‌های ورودی جهت تخمین مدول تغییر شکل پذیری شامل ارتفاع روباره، شاخص کیفیت توده سنگ، هواز دگی، مقاومت فشاری تک محوری، زاویه تمایل لایه‌بندی، ضریب سختی درزه و میزان پرشدگی درزه می‌باشد که در ساختگاه سد بختیاری جمع‌آوری گردیده است. پس از انجام مدل‌سازی، نتایج حاصل از سه مدل *FIS*، *GEP* و *MLR* با همدیگر، با داده‌های واقعی و با مدل‌های مشابه قبلی مقایسه شده است. مقدار شاخص‌های ارزیابی عملکرد ریشه میانگین مربعات خطا، میانگین خطای مطلق، واریانس حساب شده، ضریب بازدهی و ضریب تعیین به ترتیب برابر با ۱/۲۷، ۱/۸۵، ۰/۹۹۱۲، ۰/۹۸۸۹، ۰/۹۸۶۹ و ۰/۹۸۶۹ برای مدل برنامه‌ریزی بیان ژن، ۱/۵۱، ۲/۰۵، ۰/۹۸۷۶، ۰/۹۸۲۳ و ۰/۹۷۷۸ برای مدل فازی و ۴/۴۵، ۴/۹۷، ۰/۷۶۴۱، ۰/۷۵۶۹ و ۰/۷۴۴۴ برای مدل آماری به دست آمد. نتایج فوق‌تر از آن می‌دهد که دقت مدل‌های *FIS* و *GEP* بالاتر و خطای آنها کمتر از مدل *MLR* است. بر اساس ارزیابی نتایج مدل‌ها و مقایسه آنها با مقادیر واقعی و نتایج مدل‌های مشابه قبلی، قابلیت بالای دو مدل *FIS* و *GEP* در پیش‌بینی مدول تغییر شکل پذیری و برتری نسبی آنها نسبت به مطالعات قبلی اثبات گردید. با این حال، دقت *GEP* تا حدودی بالاتر از *FIS* بوده و نتایج آن تطابق نسبتاً بهتری با مقادیر واقعی دارد. در نهایت، نتایج تحلیل اهمیت متغیر نشان داد که پارامترهای هواز دگی و ارتفاع روباره به ترتیب بیش‌ترین و کم‌ترین تأثیر را بر مدول تغییر شکل پذیری توده سنگ در این تحقیق دارند.

مدول تغییر شکل پذیری توده سنگ، سد بختیاری، برنامه‌ریزی بیان ژن، سیستم استنتاج فازی، رگرسیون خطی چند متغیره

واژگان کلیدی

## ۱- مقدمه

با توجه به اینکه توده سنگ در اصل یک محیط ناپیوسته و غیرهمگن شامل ناپیوستگی‌های مختلف از جمله لایه‌بندی‌ها، گسل‌ها، ترک‌ها، درزه‌ها و شکستگی‌ها می‌باشد لذا رفتار تغییرشکل‌پذیری توده سنگ به نحوه رفتار و خصوصیات این ناپیوستگی‌ها و صفحات ضعیف آن بستگی دارد. همچنین، فراوانی درزه‌ها و شکستگی‌ها و جهت‌دهی آنها نقش مهمی در مقاومت توده سنگ دارد. رفتار الاستیکی و تغییرشکل‌پذیری توده سنگ برای طراحی ایمن ساختارهای مختلف مانند تونل‌ها، سدها و پل‌ها بسیار مهم می‌باشد. بنابراین، مدول تغییرشکل‌پذیری جزو مهم‌ترین خصوصیات توده سنگ است که شاخصی برای نشان دادن رفتار مکانیکی آن بوده و در طراحی بسیاری از پروژه‌های مهندسی معدن و مکانیک سنگ از جمله حفاری‌های سطحی و زیرزمینی مورد استفاده قرار می‌گیرد. به‌طور کلی، روش‌های معمول برای تعیین مدول تغییرشکل‌پذیری توده سنگ شامل روابط تجربی و تست‌های آزمایشگاهی و برجا می‌باشد. محققین مختلف از تکنیک‌های گوناگون مانند روش‌های مستقیم و غیر مستقیم برای تعیین مدول تغییرشکل‌پذیری توده سنگ استفاده کرده‌اند که بیشتر بر اساس سیستم‌های طبقه‌بندی توده سنگ، تعمیم نتایج آزمایشگاهی برای توده سنگ و غیره است [۴-۱]. در ارتباط با تخمین مدول تغییرشکل‌پذیری توده سنگ، روابط مختلفی ارائه شده است که بر اساس طبقه‌بندی‌های مختلف مانند طبقه‌بندی ژئومکانیکی توده سنگ [۵]، شاخص کیفیت تونل‌زنی [۶]، شاخص توده سنگ [۷ و ۸]، شاخص کیفیت سنگ [۹] و شاخص مقاومت زمین‌شناسی [۱۰] می‌باشند. به‌علت مشکلات موجود در انجام تست‌های برجا، توسعه مدل‌های پیشگویانه مانند الگوریتم‌های هوش مصنوعی برای تعیین خصوصیات تغییرشکل‌پذیری توده سنگ از جمله مدول تغییرشکل‌پذیری برای مهندسی مکانیک سنگ مطالعه‌ای جذاب و ضروری به‌نظر می‌رسد [۱۱-۱۳]. خصوصیات مکانیکی توده سنگ در بسیاری از مواقع به‌علت طبیعت غیر همگن و پیچیده آن با عدم قطعیت همراه است. به‌عنوان مثال، پیش‌بینی مدول تغییرشکل‌پذیری توده سنگ همواره مشکل بوده و معمولاً با خطا همراه بود. به‌عبارت دیگر، تعیین مدول تغییرشکل‌پذیری به شدت از عدم قطعیت مربوط به خصوصیات مختلف توده سنگ تأثیر می‌پذیرد. از آنجا که انجام

تست‌های برجا و آزمایشگاهی برای تعیین مدول تغییرشکل‌پذیری هزینه‌بر و اجرای دقیق آن‌ها مشکل است، لذا توسعه مدل‌های مبتنی بر هوش مصنوعی برای تخمین این پارامتر می‌تواند روشی سریع، مفید و مقرون به‌صرفه باشد [۱].

در سال‌های اخیر، استفاده از روش‌های هوش مصنوعی مانند شبکه‌های عصبی مصنوعی، سیستم‌های استنتاج فازی، سیستم‌های عصبی-فازی، برنامه‌ریزی بیان ژن و الگوریتم ژنتیک، به‌عنوان یک موضوع تحقیقاتی جذاب و نوین توسط نویسندگان مختلف در مهندسی مکانیک سنگ مورد مطالعه قرار گرفته است [۲۱-۱۴]. به‌صورت ویژه، مطالعات مختلفی هم در زمینه تخمین مدول تغییرشکل‌پذیری توده سنگ با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین انجام شده است. همچنین، از مدل‌های آماری مختلف به‌ویژه رگرسیون چند متغیره برای تخمین این پارامتر استفاده شده است. بر اساس مروری بر منابع مختلف، خلاصه‌ای از تحقیقات انجام شده در زمینه تخمین مدول تغییرشکل‌پذیری توده سنگ با استفاده از الگوریتم‌های مختلف هوش مصنوعی و مدل‌های آماری در جدول ۱ نشان داده شده است. همان‌طور که در جدول ۱ مشاهده می‌شود، در تحقیقات قبلی پارامترهای تأثیرگذاری مانند زاویه تمایل لایه‌بندی، ضریب سختی درزه و میزان پر شدگی درزه برای تخمین مدول تغییرشکل‌پذیری توده سنگ در نظر گرفته نشده است. همچنین، الگوریتم‌های هوشمند مورد استفاده محدود بوده و از مدل برنامه‌ریزی بیان ژن برای تخمین پارامتر مدول تغییرشکل‌پذیری توده سنگ استفاده نشده است. بنابراین، در این تحقیق سعی شده است که با در نظر گرفتن پارامترهای تأثیرگذار بیشتر و استفاده از سیستم استنتاج فازی و الگوریتم برنامه‌ریزی بیان ژن، بخشی از محدودیت‌های فوق برطرف گردد.

سیستم‌های استنتاج فازی یکی از تواناترین شاخه‌های هوش مصنوعی است که می‌تواند با حل سیستم‌های پیچیده و مبهم که بسیاری از پارامترهای مربوطه بایستی در آن گنجانده شوند، مقابله کند. در دو دهه گذشته، افزایشی در کاربردهای مدل‌های فازی در زمینه مهندسی معدن، علوم زمین و مکانیک سنگ مشاهده شده است [۲۲]. از طرف دیگر، الگوریتم برنامه‌ریزی بیان ژن به‌عنوان یک ابزار پیش‌بینی در مهندسی مکانیک سنگ در راستای بهینه‌سازی مورد استفاده

مورد استفاده قرار دهند. ضمناً قابلیت تعمیم پذیرش سریع در سایر کاربردهای مشابه مکانیک سنگ را دارند [۲۰]. در این تحقیق از دو مدل هوش مصنوعی شامل سیستم استنتاج فازی<sup>۱</sup> (FIS) و برنامه‌ریزی بیان ژن<sup>۲</sup> (GEP) یا به‌همراه مدل آماری رگرسیون خطی چند متغیره<sup>۳</sup> (MLR) یا برای تخمین مدول تغییرشکل پذیری توده سنگ استفاده شده است. نتایج حاصل از این مدل‌ها با یکدیگر و با مقادیر واقعی مقایسه و مورد تجزیه و تحلیل قرار گرفته‌اند. در نهایت، تحلیل اهمیت متغیرهای ورودی در مدل‌سازی پارامتر مدول تغییرشکل پذیری توده سنگ انجام شده و تأثیر هر کدام از متغیرها بر خروجی مشخص گردیده است.

قرار گرفته است [۲۳]. در مقایسه با سایر روش‌های هوش مصنوعی، مزیت سیستم‌های استنتاج فازی و الگوریتم برنامه‌ریزی بیان ژن مورد استفاده در تحقیق حاضر این است که می‌توانند مسائل چند متغیره پیچیده و غیرخطی را به‌صورت شفاف توصیف کرده و هدف مورد نظر را به‌خوبی پیش‌بینی نمایند. همچنین، مدل‌های فازی می‌توانند با عدم قطعیت‌های احتمالی مختلف که در مهندسی سنگ رایج هستند مقابله کنند. بعلاوه، مدل برنامه‌ریزی بیان ژن قادر به تخمین دقیق تابع هدف به‌منظور بهینه‌سازی عملیات اندازه‌گیری آن می‌باشد. این ویژگی‌ها به مهندسان مکانیک سنگ اجازه می‌دهد تا بدون نیاز به ابزارهای محاسباتی پیچیده یا نرم‌افزارهای اضافی، این مدل‌ها را به‌طور کارآمد

جدول ۱- خلاصه‌های از تحقیقات انجام شده در زمینه تخمین مدول تغییرشکل پذیری توده سنگ با استفاده از الگوریتم‌های هوش مصنوعی و مدل‌های آماری

منبع	نوع سنگ	پارامترهای ورودی	روش مورد استفاده
[۲۴]	کوارتز دیوریت، سنگ آهک	$E_i, RQD, WD$	سیستم استنتاج فازی، رگرسیون آماری
[۲۵]	کوارتز دیوریت، سنگ آهک	$E_i, RQD, WD, UCS$	سیستم نو-فازی
[۲۶]	شیل، ماسه‌سنگ کوارتزی، آهک، سیلتستون، گل‌سنگ، مارن-آهک	$E_i, RQD, UCS, n, \rho_d, J/m$	برنامه ریزی ژنتیک
[۲۷]	شیل، ماسه‌سنگ کوارتزی، آهک، سیلتستون، گل‌سنگ، مارن-آهک	$GSI, RQD, UCS, n, \rho_d, J/m$	سیستم استنتاج نو-فازی، خوشه‌بندی فازی
[۲۸]	شیل	$I_s, \rho, n$	منطق فازی، رگرسیون چند متغیره
[۲۹]	سنگ آهک	$E_i, RQD, UCS, \rho$	سیستم عصبی-ژنتیک
[۳۰]	آهکی- دولومیتی	$GSI, Q, UCS$	شبکه عصبی مصنوعی
[۳۱]	-	$RMR, GSI$	مدل بی‌زین
[۳۲]	سیلتستون	$E_i, RQD, UCS, RMR$	شبکه عصبی، فازی-عصبی، برنامه‌ریزی ژنتیک
[۳۳]	توده‌سنگ‌های جنوب غربی ابران	$E_i, RMR$	رگرسیون خطی چند متغیره
[۳۴]	-	$E_i, H, UCS, RMR$	شبیه‌سازی مونت کارلو
[۳۵]	-	$RMR$	مدل‌های بی‌زین و رگرسیون
[۳۶]	گرانیت، کوارتز، میکا، شیست، کوارتزی آهکی، سنگ مرمر	$RMR, I_s$	شبکه عصبی، جنگل تصادفی، شبکه همسایگی
[۳۷]	-	$E_i, H, UCS, RMR$	$K$ ، رگرسیون خطی چند متغیره شبکه عصبی مصنوعی، نزدیکترین همسایگی و جنگل تصادفی، رگرسیون خطی چند متغیره

توجه:  $E_i$  مدول الاستیسته،  $RQD$  شاخص کیفیت سنگ،  $WD$  درجه هوازدگی،  $UCS$  مقاومت فشاری تک محوری،  $n$  تخلخل،  $\rho_d$  چگالی خشک،  $J/m$  تعداد درزه در هر متر،  $GSI$  شاخص مقاومت زمین‌شناسی،  $I_s$  شاخص بار نقطه‌ای،  $\rho$  چگالی طبیعی،  $Q$  شاخص تونل‌زنی (سیستم طبقه‌بندی بارتن)،  $RMR$  شاخص ژئومکانیکی توده‌سنگ، و  $H$  عمق (ارتفاع) روباره است.

<sup>3</sup> Multiple linear regression

<sup>1</sup> Fuzzy inference system

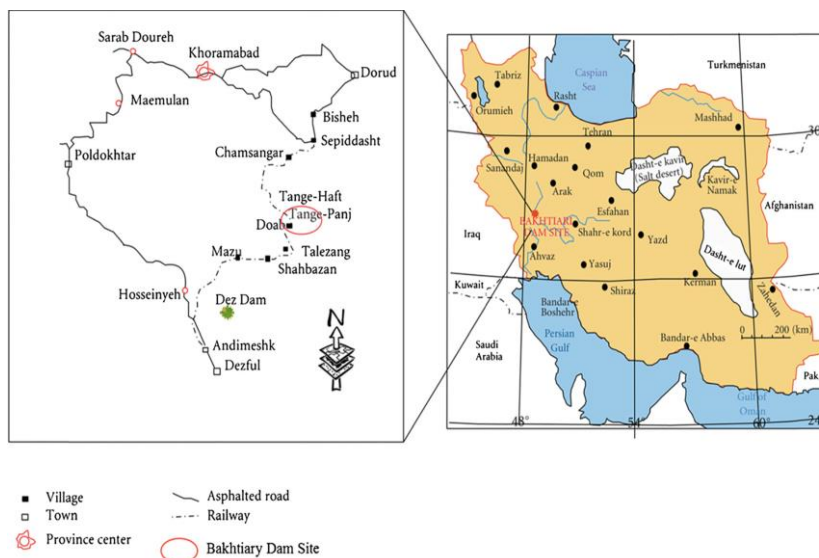
<sup>2</sup> Gene expression programming

## ۲- مطالعه موردی

### ۲-۱- موقعیت جغرافیایی

سد بختیاری به‌عنوان مطالعه موردی در این تحقیق در نظر گرفته و داده‌های مورد استفاده از ساختگاه این سد گردآوری شده است. طرح سد و نیروگاه برق-آبی بختیاری در استان لرستان واقع در جنوب غربی ایران، شمال شرقی ایستگاه راه‌آهن تنگه‌پنج از مسیر خط راه‌آهن تهران- اهواز قرار دارد.

ساختگاه این سد در محلی با طول جغرافیایی  $48^{\circ}46'50''$  و عرض جغرافیایی  $32^{\circ}57'41''$  قرار گرفته است. موقعیت این پروژه بر روی رودخانه بختیاری، یکی از شاخه‌های رود دز و ۵ کیلومتر بالاتر از محل برخورد رودخانه‌های بختیاری و سزار در میان کوه‌های زاگرس و ۵۰ کیلومتر بالاتر از سد دز قرار دارد. نزدیک‌ترین مرکز استان به محل پروژه، شهر خرم‌آباد با فاصله تقریباً ۱۰۰ کیلومتر می‌باشد [۳۸ و ۳۹]. موقعیت جغرافیایی سد بختیاری در شکل ۱ نشان داده شده است.




شکل ۱- موقعیت جغرافیایی سد بختیاری [۳۹]

از دیدگاه زمین‌شناسی در زون زاگرس چین‌خورده واقع شده است. در نقشه‌های زمین‌شناسی، لایه‌های سنگی محدوده ساختگاه سد تحت عنوان گروه بنگستان نامگذاری شده است. مجموعه لایه‌های سنگی این گروه در محدوده ساختگاه و مخزن سد رخنمون دارند و اغلب واحدهای ساختگاه از آهک‌های ریزدانه، تیره رنگ، گاه به سن کرتاسه میانی تشکیل شده‌اند که در آن، گرهک‌های چرتی و گاهی میان لایه‌های چرتی سازند سروک مشاهده می‌شود [۳۸ و ۳۹]. بر اساس اطلاعات برداشت شده از درزه‌ها در گالری‌های حفر شده و رخنمون‌های سطحی و رسم آنها بر روی صفحه استریونت، جمعاً سه دسته درزه اصلی شامل  $J1$ ،  $J1A$  و  $J1B$ ،  $J2$ ،  $J2A$  و  $J2B$ ، و  $J3$  و دو لایه‌بندی اصلی شامل در ساختگاه سد بختیاری وجود دارد. تصویر شماتیک از ناپیوستگی‌ها و صفحات لایه‌بندی موجود در ساختگاه سد بختیاری در شکل ۴

### ۲-۲- وضعیت زمین‌شناسی

محدوده سد و نیروگاه بختیاری در شمال غربی زاگرس چین‌خورده و در یک ناحیه تکتونیزه شده با لایه‌بندی‌های منحصر به فردی قرار دارد. مقطع زمین‌شناسی ساختگاه سد بختیاری و نمونه‌های از لایه‌بندی‌ها و چین‌خوردگی‌های موجود به‌ترتیب در شکل ۲ و شکل ۳ نشان داده شده است. ساختگاه سد عمدتاً از آهک‌های سیلیسی سازند سروک مربوط به دوران کرتاسه تشکیل شده که به هفت واحد شامل  $Sv1$  تا  $Sv7$  تقسیم‌بندی شده است (جدول ۲). نیروگاه زیرزمینی سد در تکیه‌گاه چپ و در ناحیه‌ای شامل آهک همراه با ندول‌های سیلیسی با ضخامت لایه‌بندی متفاوت قرار گرفته است. ساختار غالب در ساختگاه سد بختیاری شامل لایه‌بندی‌های مختلف همراه با سه دسته درزه است. محل سد



شکل ۴- تصویر شماتیک از ناپیوستگی‌ها و صفحات لایه‌بندی موجود در ساختگاه سد بختیاری [۳۹]


### ۲-۳- داده‌های جمع‌آوری شده

همان‌طور که قبلاً اشاره شد، برای طراحی و ارزیابی مدل‌های هوش مصنوعی و آماری در این تحقیق از داده‌های اندازه‌گیری شده در ساختگاه سد بختیاری استفاده شده است. پارامترهایی که برای مدل‌سازی مدول توده سنگ با استفاده از مدل‌های هوش مصنوعی و آماری مورد استفاده قرار گرفته است، شامل هفت پارامتر ارتفاع روباره، شاخص کیفیت توده سنگ، هوازدگی، مقاومت فشاری تک محوری، زاویه تمایل لایه‌بندی، ضریب سختی درزه و میزان پر شدگی به‌عنوان ورودی و مدول تغییرشکل‌پذیری توده سنگ به‌عنوان خروجی می‌باشد. همچنین، تعداد داده‌های جمع‌آوری شده شامل ۱۰۴ سری داده ورودی-خروجی می‌باشد.

جهت ارزیابی همبستگی بین پارامترهای ورودی پایگاه داده در این تحقیق از ماتریس همبستگی استفاده و نتایج حاصله در شکل ۵ نشان داده شده است. همان‌طور که در شکل ۵ مشاهده می‌شود، ضریب همبستگی بین کلیه پارامترهای ورودی پایگاه داده کمتر از مقدار آستانه ۰/۷۵ است [۴۰]. این موضوع نشان می‌دهد که هم‌خطی نسبتاً ضعیفی بین پارامترهای ورودی پایگاه داده وجود دارد و می‌توان نتیجه گرفت که کلیه پارامترها بدون رابطه خطی قابل توجهی به‌صورت مستقل از یکدیگر عمل می‌کنند. این موضوع از منظر آماری حائز اهمیت است، چرا که نبود هم‌خطی شدید موجب افزایش دقت و پایداری مدل‌سازی خواهد شد.

به‌منظور ارزیابی میزان هم‌خطی بین پارامترهای ورودی در مدل‌سازی در این تحقیق، از شاخص آماری ضریب تورم

نشان داده شده است [۳۹].



شکل ۲- مقطع زمین‌شناسی ساختگاه سد و نیروگاه بختیاری [۳۹]




شکل ۳- لایه‌بندی و چین خوردگی‌های ساختگاه سد بختیاری [۳۹]

### جدول ۲- توصیف لیتولوژی واحدهای سروک [۳۹]

واحد	لیتولوژی
Sv1	سنگ آهک تا سنگ آهک مارنی متوسط تا ضخیم لایه به‌همراه مارن و شیل
Sv2	سنگ آهک تا سنگ آهک مارنی نازک تا متوسط لایه به‌همراه مارن و شیل
Sv3	سنگ آهک مارنی تا سنگ آهک سیلیسی
Sv4	سنگ آهک با گرهک‌های سیلیسی کوچک
Sv5	سنگ آهک ضخیم تا خیلی ضخیم با گرهک‌های سیلیسی
Sv6	سنگ آهک و آهک مارنی متوسط تا ضخیم لایه با میان لایه‌های نازک مارنی
Sv7	سنگ آهک و آهک مارنی نازک تا متوسط لایه


با خروجی ماتریس همبستگی همخوانی دارد. در فرآیند مدل‌سازی انجام گرفته در این تحقیق، ۸۴ سری از داده‌های جمع‌آوری شده برای آموزش و طراحی مدل‌ها و ۲۰ سری باقیمانده هم برای تست و ارزیابی آنها در نظر گرفته شده است. متغیرهای مورد استفاده در مدل‌سازی، علائم مربوطه و خصوصیات آماری کل داده‌های اندازه‌گیری شده (پایگاه داده)، داده‌های آموزشی و داده‌های تست به ترتیب در جدول ۴، جدول ۵ و جدول ۶ نشان داده شده است. بعلاوه، تعداد ۱۰ سری از داده‌های مورد استفاده در طراحی و آموزش مدل‌های *GEP*، *FIS* و *MLR* در جدول ۷ آورده شده است.

واریانس<sup>۴</sup> (*VIF*) استفاده شده است. این شاخص آماری نشان می‌دهد که تا چه اندازه بین پارامترهای ورودی یک مدل هم‌خطی وجود دارد. اگر مقدار *VIF* کمتر از ۵ و به ۱ نزدیک باشد بیانگر هم‌خطی پایین و یا عدم وجود هم‌خطی برای یک پارامتر است. مقادیر *VIF* بین ۵ تا ۱۰ بیانگر هم‌خطی متوسط و مقادیر بیش از ۱۰ بیانگر هم‌خطی بالای پارامتر ورودی مورد نظر و در نتیجه وجود همبستگی بالای آن با دیگر پارامترهای ورودی مدل است. نتایج تحلیل هم‌خطی بین پارامترهای ورودی مدل با استفاده از شاخص *VIF* در جدول ۳ و شکل ۶ نشان داده شده است. با توجه به جدول ۳ و شکل ۶، می‌توان دریافت که کلیه پارامترهای ورودی پایگاه داده دارای هم‌خطی پایینی بوده و مستقل از هم‌اند. لازم به ذکر است که این نتیجه



شکل ۵- ساختار ماتریس همبستگی بین پارامترهای ورودی پایگاه داده

<sup>4</sup> Variance Inflation Factor



شکل ۶- ساختار ماتریس همبستگی بین پارامترهای ورودی پایگاه داده

جدول ۳- مقادیر شاخص VIF برای تحلیل هم خطی بین پارامترهای ورودی پایگاه داده

پارامتر	H	RQD	W	UCS	I	JRC	FT
مقدار VIF	۱/۱۲	۱/۳۲	۲/۲۲	۲/۴۵	۱/۰۹	۱/۲۶	۱/۱۲

جدول ۴- پارامترهای مدل سازی، علائم متغیرها و ویژگی‌های آماری پایگاه داده مورد استفاده در مدل سازی

نوع متغیر	نام متغیر	نشانه	مقدار مینیمم	مقدار میانگین	مقدار ماکزیمم	انحراف معیار	واریانس	کشیدگی	چولگی
ورودی	هوازدگی (%)	W	۲۰	۶۱/۳	۱۰۰	۲۲/۱	۴۸۷/۷	-۰/۷۷	-۰/۸۸
	ضریب کیفیت توده سنگ (%)	RQD	۴۲	۹۰/۲	۱۰۰	۱۲/۸	۱۶۳/۹	-۱/۴۷	۱/۹۶
	زاویه تمایل لایه بندی (درجه)	I	۲/۵	۴۳/۹	۸۵	۱۹/۹	۳۹۳/۹	-۰/۵۲	۰/۱۳
	مقاومت فشاری تک محوری (مگاپاسکال)	UCS	۱۹	۷۸/۴	۱۲۵	۳۲/۱	۱۰۳۰/۹	-۰/۶۴	-۰/۸۴
	میزان پر شدگی (میلیمتر)	FT	۰	۱/۳	۴	۰/۸۵	۰/۷۲	۰/۹۱	۰/۷۸
خروجی	ارتفاع روباره (متر)	H	۶	۱۶۸/۵	۴۵۹/۴	۱۱۳/۶	۱۲۹۱۳	۰/۹۹	۰/۴۱
	ضریب سختی درزه (-)	JRC	۳	۸/۸	۱۹	۴/۶	۲۱/۲	۰/۹۴	-۰/۱۴
	مدول تغییرشکل پذیری (گیگاپاسکال)	$E_m$	۱/۴۹	۱۰/۳	۳۰	۶/۸	۴۶/۴	۰/۷۶	۰/۱

جدول ۵- پارامترهای مدل سازی، علائم متغیرها و ویژگی‌های آماری داده‌های آموزشی مورد استفاده در مدل سازی

نوع متغیر	نام متغیر	نشانه	مقدار مینیمم	مقدار میانگین	مقدار ماکزیمم	انحراف معیار	واریانس	کشیدگی	چولگی
ورودی	هوازدگی (%)	W	۲۰	۶۱/۲	۱۰۰	۲۲	۴۸۳/۷	-۰/۷۵	-۰/۸۹
	ضریب کیفیت توده سنگ (%)	RQD	۴۲	۹۰/۲	۱۰۰	۱۳/۱	۱۷۲/۱	-۱/۵	۲/۰۳
	زاویه تمایل لایه بندی (درجه)	I	۲/۵	۴۳/۵	۸۵	۲۰/۳	۴۱۱/۵	-۰/۰۳	-۰/۵۵
	مقاومت فشاری تک محوری (مگاپاسکال)	UCS	۱۹	۷۷/۹	۱۲۵	۳۱/۶	۹۹۹/۱	-۰/۶۴	-۰/۸۵
	میزان پر شدگی (میلیمتر)	FT	۰	۱/۳۳	۴	۰/۸۸	۰/۷۸	۰/۹۲	۰/۷۴
خروجی	ارتفاع روباره (متر)	H	۶	۱۶۵/۷	۴۵۹/۴	۱۱۱/۸	۱۲۴۹۸	۱/۰۴	۰/۶
	ضریب سختی درزه (-)	JRC	۳	۹/۰۲	۱۹	۴/۶۳	۲۱/۴	۰/۸۲	-۰/۴۲
	مدول تغییرشکل پذیری (گیگاپاسکال)	$E_m$	۱/۵	۹/۶	۳۰/۶	۶/۳	۳۹/۴	۰/۸	۰/۳۶

جدول ۶- پارمترهای مدل سازی، علائم متغیرها و ویژگی های آماری داده های تست مورد استفاده در اعتبارسنجی

نوع متغیر	نام متغیر	نشانه	مقدار مینیمم	مقدار میانگین	مقدار ماکزیمم	انحراف معیار	واریانس	کشیدگی	چولگی
	هوازگی (%)	<i>W</i>	۲۰	۶۲	۸۵	۲۲/۵	۵۰۴	-۰/۷۰	-۰/۸۷
	ضریب کیفیت توده سنگ (%)	<i>RQD</i>	۵۷	۹۰/۳	۱۰۰	۱۱/۴	۱۲۹	۱/۸۹	-۱/۲۲
	زاویه تمایل لایه بندی (درجه)	<i>I</i>	۲۸	۴۵/۵	۸۰	۱۷/۸	۳۱۶/۴	-۰/۶۲	۰/۸۲
ورودی	مقاومت فشاری تک محوری (مگاپاسکال)	<i>UCS</i>	۱۹	۸۰/۵	۱۲۵	۳۴/۱	۱۱۵۹/۵	-۰/۷۲	-۰/۶۴
	میزان پر شدگی (میلیمتر)	<i>FT</i>	۰	۱/۱۷	۲/۵	۰/۶۹	۰/۴۸	-۰/۴۳	۰/۴۶
	ارتفاع روباره (متر)	<i>H</i>	۲۰/۴	۱۷۹/۹	۴۵۹/۴	۱۲۰/۴	۱۴۴۹۳	۰/۱۱	۰/۷۸
	ضریب سختی درزه (-)	<i>JRC</i>	۳	۷/۷	۱۹	۴/۳۶	۱۹/۱	۲/۷۵	۱/۵۹
خروجی	مدول تغییر شکل پذیری (گیگاپاسکال)	<i>E<sub>m</sub></i>	۱/۵	۱۳	۳۰/۶	۸/۲	۶۷	-۰/۷۴	۰/۳۱

جدول ۷- نمونه ای (۱۰ سری) از داده های مورد استفاده برای طراحی مدل های آماری و هوش مصنوعی

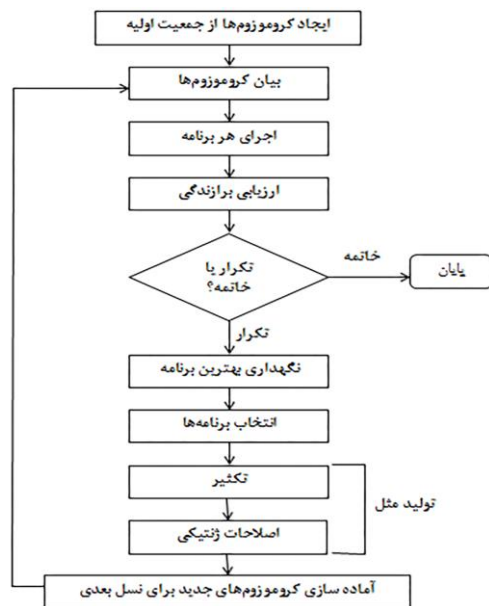
شماره	<i>W</i> (%)	<i>RQD</i> (%)	<i>I</i> (درجه)	<i>UCS</i> (مگاپاسکال)	<i>FT</i> (میلیمتر)	<i>H</i> (متر)	<i>JRC</i> (-)	<i>E<sub>m</sub></i> (گیگاپاسکال)
۱	۶۵	۸۰	۸۵	۹۴	۰/۵	۱۳۸/۶	۱۹	۲/۳۵
۲	۲۰	۵۷	۳۶/۲۵	۱۹	۱	۱۲۱/۵	۱۰/۵	۱۳/۴۷
۳	۷۰	۴۲	۴۲	۹۶/۵	۱	۱۷۴/۳	۱۳	۲/۰۲
۴	۸۵	۱۰۰	۸۰	۱۰۶/۵	۱	۱۹۲/۲۵	۱۱/۵	۲۰/۳
۵	۲۵	۷۳	۵۵	۲۵	۳	۱۷۴/۳	۱۷	۳/۷۳
۶	۷۸	۱۰۰	۴۰	۸۷/۵	۰/۵	۴۵۹/۴	۹	۲۲/۳۸
۷	۸۳	۹۳	۵۲	۱۲۵	۱/۵	۲۰/۴	۴	۳۰/۶
۸	۷۵	۱۰۰	۴۵	۹۴	۰/۵	۴۳۱/۹	۷	۱۵/۳۸
۹	۸۵	۱۰۰	۲۰	۱۰۶/۵	۱/۵	۱۶۹/۲۵	۷	۱۱/۹
۱۰	۶۰	۱۰۰	۷۵	۶۹	۱/۵	۴۵/۵	۵	۳/۷۴

### ۳- روش های مورد استفاده

#### ۳-۱- الگوریتم برنامه ریزی بیان ژن

برازش به وسیله پردازش تعدادی نمونه از مسئله هدف، که موارد برازش نیز نامیده می شوند، ارزیابی می گردد. اگر کیفیت رضایت بخش از یک راه حل پیدا شود و یا نسل ها به تعداد معینی برسند، تکامل متوقف شده و بهترین راه حل یافت می گردد تا آن مرحله، گزارش داده شود. از طرف دیگر، اگر شرایط توقف یافت نشود، بهترین راه حل از نسل حاضر نگه داشته می شود (که به معنای نخبه گزینی است) و بقیه راه حل ها به فرآیندی گزینشی واگذار می شوند. گزینش یا انتخاب، نقش بقاء شایستگی را انجام داده و بر اساس آن بهترین افراد شانس بهتری برای تولید فرزندان دارند. کل این

الگوریتم برنامه ریزی بیان ژن برای اولین بار توسط فریرا در سال ۱۹۹۹ ارائه شده است [۴۱]. اولین مرحله در الگوریتم برنامه ریزی بیان ژن، تولید جمعیت اولیه از راه حل هاست. این موضوع می تواند به وسیله یک فرآیند تصادفی و یا با استفاده از مقداری اطلاعات درباره مسئله انجام شود. سپس کروموزوم ها به صورت بیان درختی اظهار شده، که این هم مطابق با یک تابع برازش ارزیابی می گردد تا میزان مناسب بودن یک راه حل در حیطه مسئله تعیین گردد. معمولاً تابع




شکل ۷- فلوجارت مدل سازی برنامه ریزی بیان ژن [۴۱]

روند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو، انتظار می‌رود که کیفیت جمعیت نیز به طور متوسط بهبود یابد [۴۲]. مراحل اصلی طراحی برنامه ریزی بیان ژن به طور شماتیک در شکل ۷ نشان داده شده است. همان طور که مشاهده می‌شود، فرآیند با تولید تصادفی کروموزوم‌ها از تعداد معینی افراد (جمعیت اولیه) آغاز می‌شود. سپس، این کروموزوم‌ها به صورت بیان درختی اظهار می‌شوند و میزان برازندگی هر فرد در مقابل مجموعه‌ای از موارد برازش، ارزیابی می‌گردد (که انتخاب محیط نیز نامیده می‌شود). در ادامه، افراد مطابق شایستگی خود (عملکرد آنها در آن محیط ویژه) انتخاب می‌شوند تا با اصلاحات و بهبودهایی، دوباره ساخته شوند و در نتیجه فرزندان با ویژگی‌های جدید باقی می‌گذارند. این فرزندان جدید، در یک چرخه، تحت همان فرآیند توسعه‌ای قرار می‌گیرند که شامل بیان ژنوم، مواجهه با انتخاب محیط، انتخاب بر مبنای برازش، و تولید مثل با بهبود می‌باشد. این فرآیند برای تعداد معینی از نسل‌ها تکرار می‌شود تا راه حل خوب و مناسبی پیدا شود. قابل ذکر است که تولید مثل تنها شامل تکثیر نیست بلکه فعالیت عملگرهای ژنتیکی توانا در ایجاد تنوع ژنتیکی را نیز در برمی‌گیرد. در واقع تولید مثل، شامل تکثیر و اصلاحات ژنتیکی است. تکثیر عملیاتی است که چندین فرد مناسب از نسل حاضر را برای نسل بعد نگه می‌دارد. در طول تکثیر، ژنوم کپی شده و به نسل بعد انتقال داده می‌شود. بدیهی است، تکثیر به تنهایی نمی‌تواند تغییرات را نشان دهد و فقط به واسطه فعالیت بقیه عملگرها، تغییرات ژنتیکی داخل جمعیت نشان داده می‌شود. این عملگرها، کروموزوم‌ها را به طور تصادفی انتخاب می‌کنند تا اصلاح شوند. بنابراین در برنامه ریزی بیان ژن، یک کروموزوم در یک زمان ممکن است بوسیله یک یا چند عملگر ژنتیکی اصلاح شود و یا اصلاً مورد اصلاح قرار نگیرد. اصلاحات ژنتیکی شامل چندین جزء از قبیل جهش، وارون سازی، ترانسپوز، درج متوالی، ترانسپوز ریشه درج متوالی، ترانسپوز ژن، ترکیب تک نقطه‌ای، ترکیب دو نقطه‌ای و ترکیب ژنی است [۴۱].

### ۲-۳- سیستم استنتاج فازی

سیستم‌های استنتاج فازی بر پایه تئوری فازی هستند که در سال ۱۹۶۵ توسط پروفیسور لطفی زاده در مقاله‌ای تحت عنوان «مجموعه فازی» ارائه شده است [۴۳]. اساساً سیستم‌های فازی پدیده‌های غیرقطعی و نامشخص را توصیف می‌کنند، با این حال، خود تئوری فازی یک تئوری دقیق و معتبر است. سیستم‌های فازی، سیستم‌هایی خبره مبتنی بر قواعد هستند که خروجی را با استفاده از روش‌های مبتنی بر اصول منطق فازی از ورودی‌های خاص پیش‌بینی می‌کنند. یک سیستم فازی نیاز به تعدادی ورودی فازی و مجموعه‌ای از قواعد "اگر- آنگاه" دارد تا خروجی فازی را مشخص کند. کاربر مقادیر عددی را وارد می‌کند که این مقادیر باید به متغیرهای فازی تبدیل شده تا به وسیله قوانین فازی پردازش شوند (مرحله استنتاج). نتیجه مرحله استنتاج مقادیر فازی بوده که بعداً با استفاده از روش‌های غیرفازی سازی به عدد تبدیل می‌شوند. به طور کلی، نقطه شروع ساخت یک سیستم فازی به دست آوردن مجموعه‌ای از قواعد اگر-آنگاه فازی از دانش افراد خبره یا دانش حوزه مورد بررسی بر اساس اندازه‌گیری می‌باشد. مرحله بعدی ترکیب این قواعد در یک سیستم واحد است. سیستم‌های فازی مختلف از اصول و روش‌های متفاوتی برای ترکیب این قواعد استفاده می‌کنند.

فازی سازی مقادیر عددی (صریح) ورودی، ایجاد پایگاه قواعد فازی (بیان قواعد سیستم)، انتخاب موتور استنتاج فازی و غیرفازی سازی مقادیر فازی خروجی است [۴۴]. این مراحل در شکل ۸ نشان داده شده است.



شکل ۸- ساختار اصلی سیستم‌های فازی با فازی‌ساز و غیرفازی‌ساز [۴۴]

در این تحقیق از نرم افزار *GenXProTools 4* برای طراحی الگوریتم برنامه‌ریزی بیان ژن استفاده شده است. به منظور طراحی مدل مورد نظر و به دست آوردن مناسب‌ترین مدل برای حل مسئله، مجموعه‌ای از تنظیمات پارامترهای مختلف در عملیات مدل‌سازی بایستی در نظر گرفته شود که معمولاً بر اساس روش سعی و خطا تعیین می‌گردد. از مهم‌ترین پارامترهای موجود در این زمینه، تعیین تعداد ژن‌ها است که بر اساس دقت، تعداد پارامترهای ورودی و کاربرد مدل ساخته شده، انتخاب می‌گردد. با افزایش تعداد ژن‌ها، دقت مدل ارائه شده بیشتر می‌شود. در این حالت رابطه ریاضی به دست آمده طولانی شده و باعث عدم کاربرد مدل می‌گردد. البته باید همواره تعداد ژن‌ها را به صورتی انتخاب کرد که دقت تابع را کاهش ندهد. در مجموع با توجه به شرایط فوق در این مقاله، از سه ژن استفاده شده است. سایر پارامترهای مورد استفاده در تخمین مدول تغییر شکل پذیری با استفاده از روش *GEP* به طور خلاصه در جدول ۸ ارائه گردیده است.

جدول ۸- مقادیر پارامترهای مدل برنامه‌ریزی بیان ژن بهینه به منظور تخمین مدول تغییر شکل پذیری

عملگرهای ژنتیکی	تنظیمات کلی
نرخ جهش ۰/۰۴۴	اندازه راس ۸
نرخ وارون سازی ۰/۱	تعداد کروموزوم‌ها ۳۰
نرخ ترانهش درج متوالی ۰/۱	تعداد ژن‌ها در هر کروموزوم ۳
نرخ ترانهش ریشه درج متوالی ۰/۱	تعداد جمعیت تولیدی ۱۰۰۰
نرخ ترکیب تک نقطه‌ای ۰/۳	تابع پیوند جمع (+)
نرخ ترکیب دو نقطه‌ای ۰/۳	تابع برازش ریشه نسبی مربعات خطا
نرخ ترکیب ژن ۰/۱	
نرخ ترانهش ژن ۰/۱	

یکی از روش‌های مرسوم برای ترکیب قواعد فازی و استنتاج آن، استفاده از موتور استنتاج مددانی است. در مرحله بعد، خروجی فازی حاصل از استنتاج بایستی با استفاده از توابع غیرفازی سازی به مقادیر عددی تبدیل شوند. بر این اساس، روش پیاده‌سازی سیستم فازی شامل چهار مرحله کلی

### ۳-۳- رگرسیون خطی چند متغیره

روش رگرسیون خطی چند متغیره یکی از زیرمجموعه‌های مدل‌های آماری است که برای استخراج رابطه بین متغیرهای ورودی و متغیر(های) خروجی در مدل‌سازی به کار می‌رود. این روش می‌تواند با فراهم نمودن یک فرآیند پیشگویانه، تأثیر طبیعی متغیرهای مختلف ورودی بر یک یا چند خروجی را نشان دهد. در حالت کلی، یک مدل رگرسیون خطی چند متغیره برای تعداد  $n$  ورودی به صورت رابطه شماره (۱) نشان داده می‌شود [۴۵].

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (1)$$

در رابطه فوق،  $y$  متغیر خروجی،  $a_0$  ضریب ثابت معادله و  $a_1$  تا  $a_n$  ضرایب متغیرهای ورودی  $x_1$  تا  $x_n$  هستند.

### ۴- مدل سازی مدول تغییر شکل پذیری


#### ۴-۱- مدل سازی با استفاده از الگوریتم *GEP*

شده اند. بعلاوه، از شکل ۱۰ و شکل ۱۱ می توان دریافت که مقادیر پیش بینی شده توسط مدل برنامه ریزی بیان ژن در هر دو فاز آموزش و آزمایش به مقادیر واقعی آن بسیار نزدیک است. بنابراین، می توان نتیجه گرفت که مدل برنامه ریزی بیان ژن پیشنهادی قابلیت بسیار بالایی در تخمین مدول تغییرشکل پذیری توده سنگ دارد.


$$E_m = \sin \left[ \left( \frac{H^2 \cdot \sqrt[3]{I}}{-7.77} \right) - 1.99H \right] + \frac{\sin(1.055UCS)}{\sin H + \ln W} + UCS + H - \sin[\text{Arctan}(W - 5) \cdot \sqrt{\text{Arctan}RQD}] \quad (2)$$

بر اساس داده های آموزش و با استفاده از نرم افزار *GenXProTools 4*، مدل برنامه ریزی بیان ژن برای تخمین مدول تغییرشکل پذیری طراحی گردید. نمایش درختی ارتباط پارامترهای تأثیرگذار بر مدول تغییرشکل پذیری حاصل از مدل برنامه ریزی بیان ژن در شکل ۹ و بهترین معادله برازش شده به صورت رابطه رابطه (۲) نشان داده شده است. همچنین، عملکرد مدل طراحی شده در مراحل آموزش و آزمایش به ترتیب در شکل ۱۰ و شکل ۱۱ نشان داده شده است. همان طور که در شکل ۹ و رابطه (۲) مشخص است، مدل برنامه ریزی بیان ژن بهینه صرفاً از پنج پارامتر ارتفاع روباره، شاخص کیفیت توده سنگ، هوازدگی، مقاومت فشاری تک محوری و زاویه تمایل لایه بندی به عنوان متغیرهای تأثیرگذار بر مدول تغییرشکل پذیری استفاده نموده و دو پارامتر ضریب سختی درزه و میزان پر شدگی از نتایج مدل سازی حذف


Sub-ET 1



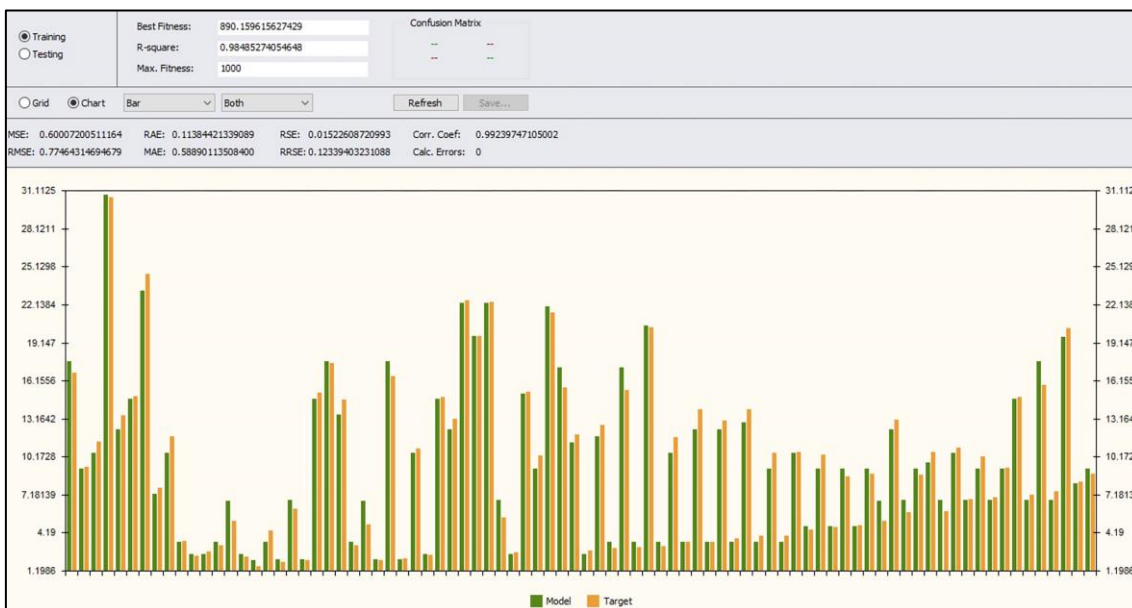
Sub-ET 2



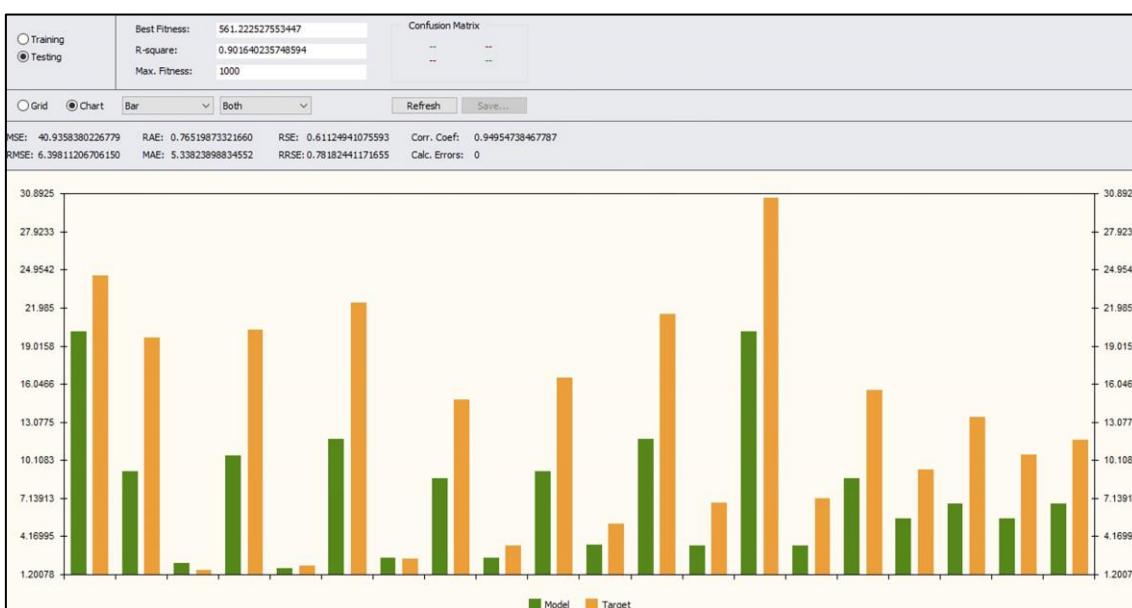
Sub-ET 3



شکل ۹- نمایش درختی معادل رابطه حاصل از مدل برنامه ریزی بیان ژن برای تخمین مدول تغییر شکل پذیری



شکل ۱۰- عملکرد مدل برنامه‌ریزی بیان ژن در مرحله آموزش به منظور تخمین مدول تغییرشکل پذیری



شکل ۱۱- عملکرد مدل برنامه‌ریزی بیان ژن در مرحله آزمون (تست) به منظور تخمین مدول تغییرشکل پذیری

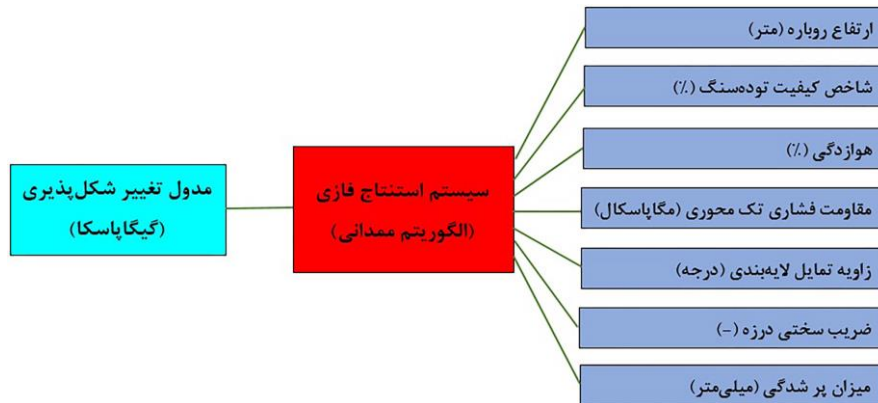
استفاده در مدل‌های فازی شرطی (اگر- آنگاه) هستند [۴۳]. لذا توابع عضویت فوق برای فازی‌سازی متغیرهای ورودی و خروجی در این تحقیق مورد استفاده قرار می‌گیرند. توابع عضویت ورودی‌ها و خروجی به صورت کم (*Low*)، متوسط (*Medium*) و زیاد (*High*) می‌باشد. به‌عنوان مثال، *VVL*

#### ۴-۲- مدل‌سازی با استفاده از مدل FIS

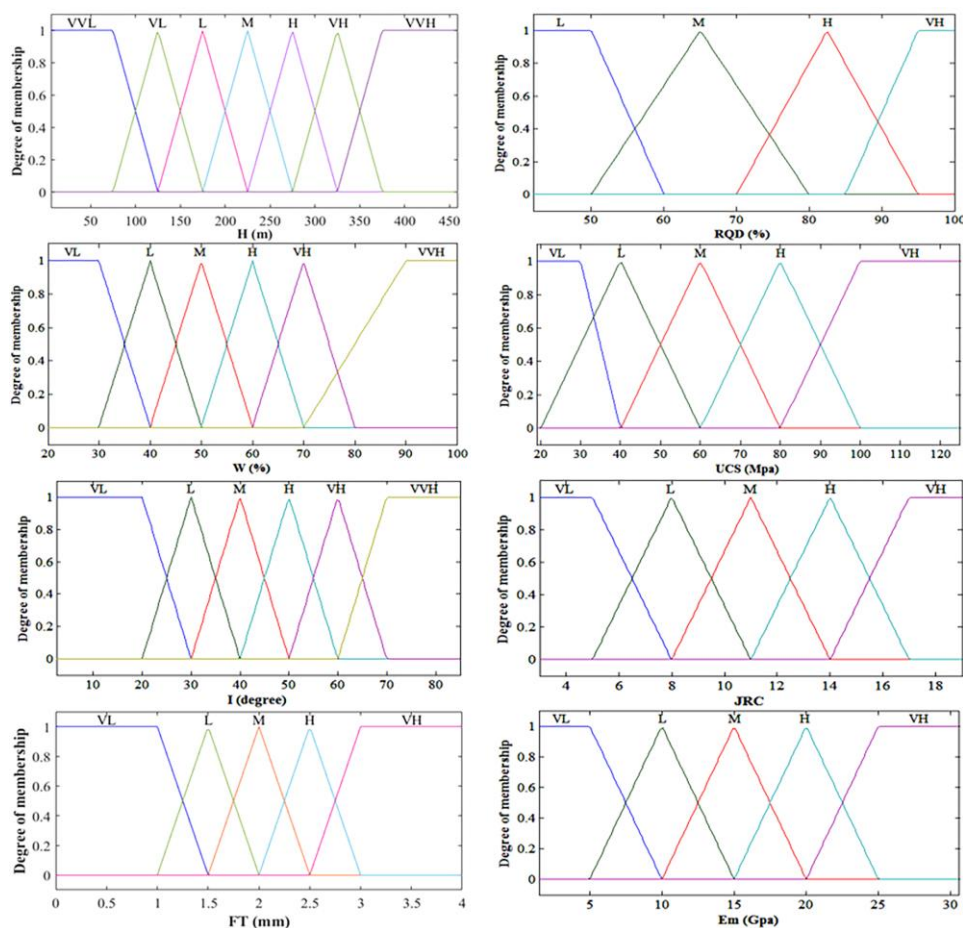
در طراحی مدل‌های بر پایه سیستم استنتاج فازی، اولین مرحله شامل فازی‌سازی مقادیر ورودی و خروجی است که با استفاده از توابع عضویت انجام می‌شود. با توجه به اینکه توابع عضویت مثلثی و دوزنقه‌ای معمول‌ترین توابع عضویت مورد

تغییر شکل پذیری در شکل ۱۲ و توابع عضویت پارامترهای ورودی و خروجی در شکل ۱۳ نشان داده شده است.

نشانه خیلی خیلی کم و  $VVH$  هم نشانه خیلی خیلی زیاد می باشد. ساختار سیستم فازی جهت پیش بینی مدول



شکل ۱۲- اسکلت اصلی سیستم استنتاج فازی برای پیش بینی مدول تغییر شکل پذیری توده سنگ



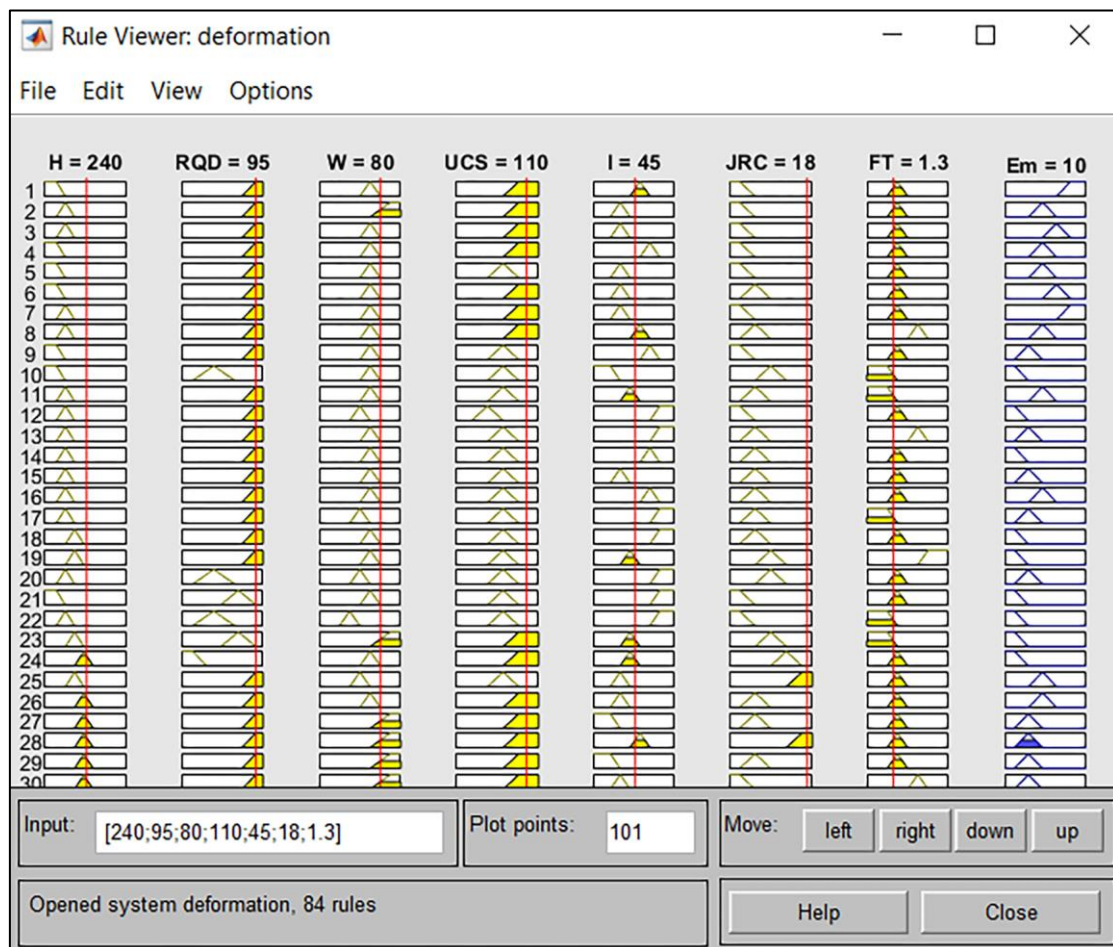
شکل ۱۳- فرم توابع عضویت پارامترهای ورودی و خروجی برای تخمین مدول تغییر شکل پذیری توده سنگ

برای عددی کردن نتایج فازی حاصل از مرحله استنتاج هم از متداول‌ترین و بهترین غیرفازی‌ساز مورد استفاده در سیستم‌های فازی یعنی روش مرکز ثقل استفاده شده است [۴۴]. پس از اتمام این مراحل، در صورت اجرا کردن مدل وارد نمودن هر مقدار از پارامترهای ورودی، مدل قادر به پیش‌بینی مدول تغییرشکل‌پذیری توده سنگ می‌باشد که نمونه‌ای از این مکانیزم استنتاج فازی برای تخمین مدول تغییرشکل‌پذیری بر اساس مقادیر مشخص متغیرهای ورودی در شکل ۱۵ نشان داده شده است.

مرحله بعدی در طراحی سیستم فازی، ساخت پایگاه قواعد است که بر اساس داده‌های جمع‌آوری شده و تجربه محقق انجام می‌شود. تعداد ۱۵ نمونه مختلف از قواعد اگر-آنگاه مورد استفاده در مدل‌سازی سیستم استنتاج فازی در شکل ۱۴ نشان داده شده است. پس از ایجاد پایگاه قواعد، با انتخاب موتور استنتاج و روش غیرفازی‌سازی مناسب، مدل‌سازی تکمیل می‌شود. در این تحقیق، به دلیل آسان‌تر بودن تفسیر و تحلیل موتور استنتاج ممدانی در مقایسه با دیگر روش‌های استنتاج [۴۴]، از این الگوریتم استفاده گردید.

The screenshot shows the 'Rule Editor: deformation' window. It contains a list of 15 fuzzy rules. Rule 5 is highlighted: '5. If (H is VVL) and (RQD is VH) and (W is VH) and (UCS is H) and (I is L) and (JRC is VL) and (FT is L) then (Em is M) (1)'. Below the list, the configuration for rule 5 is shown. The 'If' conditions are: H is VVL, RQD is VH, W is VH, UCS is H, and I is L. Each condition has a dropdown menu and a 'not' checkbox. The 'Connection' section has 'and' selected. The 'Weight' is set to 1. Buttons for 'Delete rule', 'Add rule', and 'Change rule' are present. The bottom of the window shows 'FIS Name: deformation', 'Help', and 'Close' buttons.

شکل ۱۴- فرم گرافیکی ۱۵ نمونه از قواعد اگر-آنگاه مورد استفاده در مدل‌سازی مدول تغییرشکل‌پذیری توده سنگ



شکل ۱۵- نمونه‌ای از مکانیسم استنتاج فازی در پیش‌بینی مدول تغییرشکل‌پذیری توده‌سنگ

به صورت رابطه (۳) می‌باشد.

$$\begin{aligned}
 E_m = & -2.16 + 0.006731H \\
 & + 0.006323RQD \\
 & - 0.0691W \\
 & + 0.12506UCS \\
 & + 0.00599I \\
 & - 0.572JRC \\
 & - 0.2184FT
 \end{aligned}
 \quad (3)$$

## ۵- نتایج و بحث

### ۵-۱- ارزیابی عملکرد مدل‌های مورد استفاده

جهت ارزیابی عملکرد مدل‌های برنامه‌ریزی بیان ژن، سیستم استنتاج فازی و رگرسیون خطی چند متغیره و همچنین مقایسه آن‌ها با همدیگر و با مقادیر واقعی از شاخص‌های

### ۳-۴- مدل‌سازی با استفاده از مدل *MLR*

همان‌طور که پیش‌تر هم اشاره شد، در این تحقیق از روش رگرسیون خطی چند متغیره برای پیش‌بینی مدول تغییرشکل‌پذیری بر اساس هفت پارامتر مذکور در جدول ۴ استفاده شده است. ارتباط بین پارامترهای ورودی تأثیرگذار و مدول تغییرشکل‌پذیری توده‌سنگ بر اساس روش آماری رگرسیون چند متغیره با استفاده از نرم‌افزار *SPSS* مورد تجزیه و تحلیل قرار گرفته است. بر اساس تحلیل رگرسیونی انجام گرفته، ضرایب بین متغیرهای مستقل (ورودی‌های مدل) و متغیر وابسته (خروجی مدل) به دست آمد که می‌توان از آن برای تخمین مدول تغییرشکل‌پذیری توده‌سنگ استفاده کرد. بر اساس ضرایب حاصله، رابطه آماری به دست آمده بین متغیرهای ورودی و مدول تغییرشکل‌پذیری توده‌سنگ

نتایج محاسبه شاخص‌های فوق‌الذکر برای مدل‌های مورد استفاده (*GEP*، *FIS* و *MLR*) بر اساس داده‌های تست در جدول ۹ نشان داده شده است. همان‌طور که مشاهده می‌شود، شاخص‌های همبستگی (واریانس حساب شده، ضریب بازدهی و ضریب تعیین) حاصل از دو مدل برنامه‌ریزی بیان ژن و سیستم استنتاج فازی بیشتر از مدل رگرسیون خطی چند متغیره است. همچنین، شاخص‌های خطا (ریشه متوسط مربعات خطا و خطای میانگین خطای مطلق) مربوط به دو مدل فوق کمتر از مدل رگرسیون خطی چند متغیره می‌باشد. با این حال، دقت مدل برنامه‌ریزی بیان ژن نسبتاً بیش‌تر و خطای آن کمتر از مدل سیستم استنتاج فازی است. برای ارزیابی بیشتر و مقایسه نتایج مدل‌های پیشنهادی با مقادیر واقعی بر اساس داده‌های تست، همبستگی بین مقادیر واقعی مدول تغییرشکل‌پذیری با مقادیر حاصل از مدل‌های *GEP*، *FIS* و *MLR* در شکل ۱۶ و میزان تطابق نتایج مدل‌های فوق با داده‌های واقعی در شکل ۱۷ نشان داده شده است. همان‌طور که در شکل‌های فوق هم مشاهده می‌شود، تطابق نتایج حاصل از دو مدل برنامه‌ریزی بیان ژن و سیستم استنتاج فازی با داده‌های واقعی بسیار بالاتر از مدل رگرسیون خطی چند متغیره می‌باشد. همچنین، مقادیر از مدل برنامه‌ریزی بیان ژن در مقایسه با مدل سیستم استنتاج فازی تطابق نسبتاً بهتری با داده‌های واقعی دارند. نتایج ارزیابی فوق نشان می‌دهد که هر دو مدل برنامه‌ریزی بیان ژن و سیستم استنتاج فازی دارای قابلیت خوبی در تخمین مدول تغییرشکل‌پذیری بوده و می‌توانند با قابلیت اطمینان بالایی در عمل مورد استفاده قرار گیرند.

ارزیابی عملکرد ریشه میانگین مربعات خطا (*RMSE*)، میانگین خطای مطلق (*MAE*)، واریانس حساب شده (*VAF*)، ضریب بازدهی (*CE*) و ضریب تعیین ( $R^2$ ) استفاده شده است. به‌طور کلی، یک مدل پیش‌بینی‌کننده زمانی کامل یا ایده‌آل خواهد بود که *MAE* و *RMSE* برابر با صفر و  $R^2$ ، *CE* و *VAF* برابر با ۱۰۰ درصد باشد. بر این اساس، میزان بالاتر  $R^2$ ، *CE* و *VAF* نشان دهند مطلوب بودن مدل بوده و پایین بودن *MAE* و *RMSE* عملکرد بهتر مدل را نشان می‌دهد. شاخص‌های فوق با استفاده از روابط زیر محاسبه می‌شوند [۴۵، ۴۶]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - y')^2} \quad (۴)$$

$$MAE = \frac{\sum_{i=1}^n |(y - y')|}{n} \quad (۵)$$

$$VAF = 100 \left( 1 - \frac{\text{var}(y - y')}{\text{var}(y)} \right) \quad (۶)$$

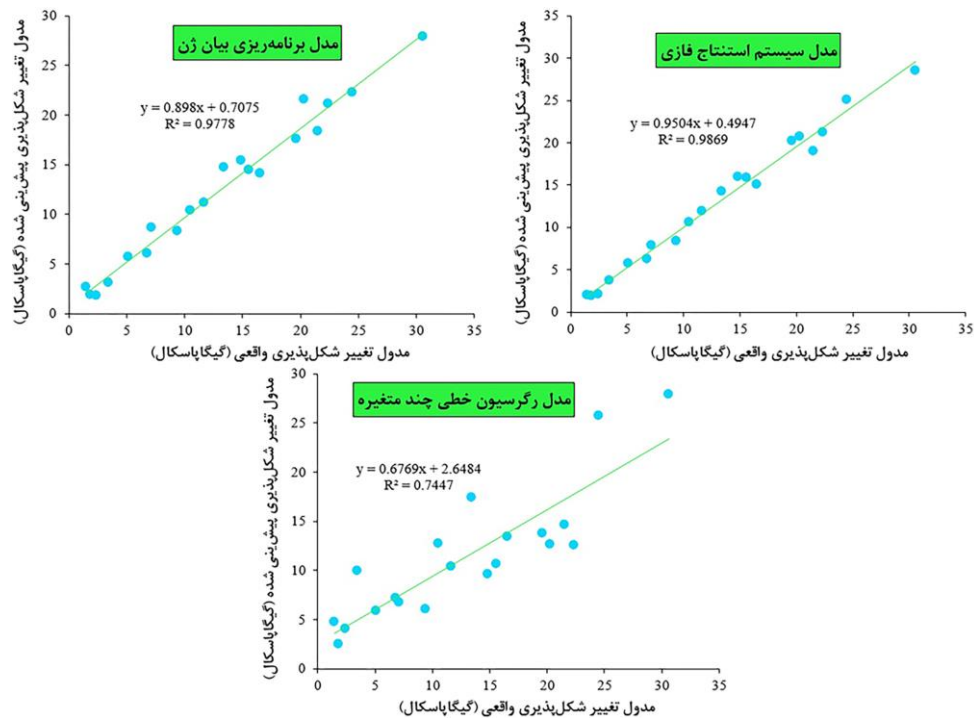
$$CE = \left( 1 - \frac{\sum_{i=1}^n |(y - y')|^2}{\sum_{i=1}^n |(y - \bar{y})|^2} \right) \quad (۷)$$

$$R^2 = 100 \left[ \frac{\sum_{i=1}^n (y - \bar{y})(y' - \bar{y}')}{\sqrt{\sum_{i=1}^n (y - \bar{y})^2 \sum_{i=1}^n (y' - \bar{y}')^2}} \right]^2 \quad (۸)$$


در روابط فوق،  $\bar{y}$  مقدار نامین داده واقعی (اندازه‌گیری شده)،  $\bar{y}'$  مقدار نامین داده پیش‌بینی شده (خروجی مدل)،  $\bar{y}$  و  $\bar{y}'$  به ترتیب مقدار متوسط داده‌های واقعی و پیش‌بینی شده و  $n$  تعداد سری‌های داده است.

جدول ۹- مقادیر شاخص‌های ارزیابی عملکرد مدل‌های مورد استفاده در مدل‌سازی مدول تغییرشکل‌پذیری توده سنگ

شاخص	مدل		
	برنامه‌ریزی بیان ژن	سیستم استنتاج فازی	رگرسیون خطی چند متغیره
ریشه میانگین مربعات خطا	۱/۲۷	۱/۵۱	۴/۴۵
میانگین خطای مطلق	۱/۸۵	۲/۰۵	۴/۹۷
واریانس حساب شده	۰/۹۹۱۲	۰/۹۸۷۶	۰/۷۶۴۱
ضریب بازدهی	۰/۹۸۸۹	۰/۹۸۲۳	۰/۷۵۶۹
ضریب تعیین	۰/۹۸۶۹	۰/۹۷۷۸	۰/۷۴۴۴



شکل ۱۶- ارتباط و همبستگی بین نتایج حاصل از مدل های مورد استفاده با مقادیر واقعی مدول تغییر شکل پذیری توده سنگ بر اساس داده های تست



شکل ۱۷- مقایسه مقادیر حاصل از مدل های مورد استفاده با مقادیر واقعی مدول تغییر شکل پذیری توده سنگ بر اساس داده های تست

و تست در بخش ۴-۱ حاکی از آن است که مدل ها نه تنها در مرحله آموزش بلکه در مرحله تست نیز دارای دقت بسیار

۲-۵- بیش برآزش، پایداری و قابلیت تعمیم مدل ها  
نتایج حاصل از مدل های *FIS* و *GEP* در هر دو مرحله آموزش

از توزیع گوسی تبعیت می‌کنند و روند خاصی ندارند. علاوه بر آن، در نمودارهای پراکندگی باقیمانده‌ها در برابر مقادیر پیش‌بینی شده، مشاهده می‌شود که داده‌ها به صورت تصادفی و یکنواخت حول محور صفر توزیع شده‌اند. عدم وجود الگوی مشخص در این توزیع نشان‌دهنده آن است که خطاها به متغیر پیش‌بینی شده وابسته نیستند و مدلی که ایجاد شده، نه تنها دقت بالایی دارد بلکه به خوبی تعمیم‌پذیر بوده و بدون بیش‌برازش است. ترکیب این تحلیل‌ها، به همراه شباهت بسیار نزدیک نتایج در دو مرحله آموزش و تست (با ضریب تعیین بیشتر از ۰/۹۸ در هر دو مرحله و خطاهای پایین)، حاکی از آن است که مدل‌ها دارای پایداری بالا بوده و هیچ نشانه‌ای از بیش‌برازش در آن‌ها دیده نمی‌شود. بنابراین می‌توان نتیجه گرفت که مدل‌های هوش مصنوعی استفاده‌شده در این مطالعه، علاوه بر دقت، از اعتبار و قابلیت تعمیم مناسبی نیز برخوردارند.

از طرف دیگر، انجام تست‌های برجا برای اندازه‌گیری مدول تغییر شکل‌پذیری توده سنگ (به‌عنوان خروجی) بسیار هزینه‌بر و زمان‌بر است. همچنین، اندازه‌گیری پارامترهای ورودی مثل مقاومت فشاری تک محوری،  $RQD$ ، خواص درزه‌ها و هوازگی هم هزینه‌بر و زمان‌بر است. بنابراین، تهیه داده در مقیاس بزرگ تا حدودی امکان‌پذیر نیست. لذا گردآوری همین تعداد داده هم به نوعی می‌تواند ارزشمند بوده و مبنای خوبی برای انجام کارهای تحقیقاتی در مقیاس تحقیق حاضر باشد. با مقایسه تعداد داده‌ها و پارامترهای ورودی و خروجی این تحقیق با موارد مشابه در منابع معتبر، می‌توان نتیجه گرفت که با این تعداد داده پیدا کردن الگوی مناسب و قابل قبول بین پارامترهای ورودی و خروجی امکان‌پذیر است. نتایج ارزیابی مدل‌های پیشنهادی هم این مورد را اثبات می‌کند. با این حال در صورت وجود داده‌های بیش‌تر با دامنه تغییرات گسترده، نتایج مدل‌ها قطعاً دقیق‌تر خواهد بود و با قابلیت اطمینان بالایی می‌توان در عمل از آنها استفاده کرد. همچنین در صورت انجام مدل‌سازی با تعداد داده بیشتر، امکان تعمیم آن به سایر مطالعات موردی و فرامنطقه‌ای کردن مدل‌های پیشنهادی هم بیشتر خواهد بود.

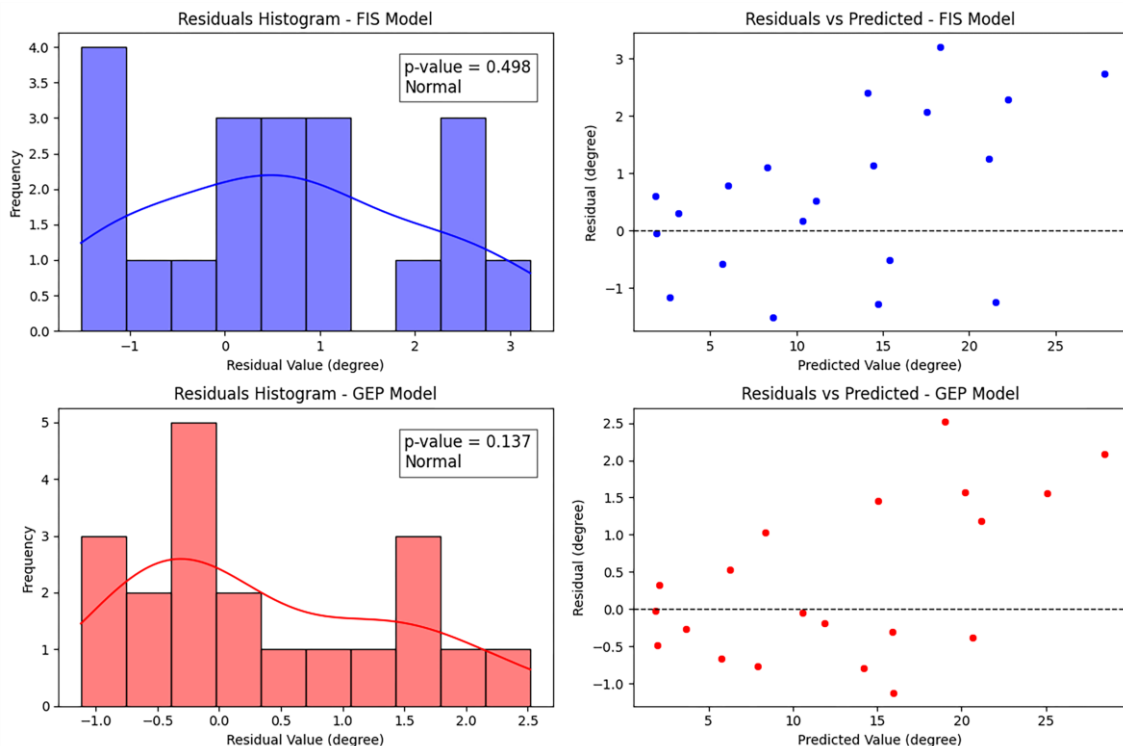
بالایی هستند. این موضوع با مقایسه شاخص‌های آماری نظیر  $RMSE$ ،  $MAE$  و  $EF$  به خوبی قابل مشاهده است. به‌طور مشخص، برای مدل  $GEP$  مقدار  $R^2$  برابر با ۰/۹۸۶۹،  $RMSE$  برابر با ۱/۲۷، و  $MAE$  برابر با ۱/۸۵ و برای مدل  $FIS$  مقدار  $R^2$  برابر با ۰/۹۷۷۸،  $RMSE$  برابر با ۱/۵۱، و  $MAE$  برابر با ۲/۰۵ به دست آمده است. این در حالی است که مدل خطی چند متغیره، که مبنای مقایسه قرار گرفته، دارای  $R^2$  برابر با ۰/۷۴۴۴ و  $RMSE$  برابر با ۴/۴۵ می‌باشد. این مقایسه به روشنی نشان می‌دهد که مدل‌های هوش مصنوعی نه تنها دقت بالاتری دارند، بلکه در پیش‌بینی داده‌های جدید نیز عملکرد موفق‌تری داشته‌اند. نزدیکی مقادیر شاخص‌های عملکرد در مراحل آموزش و تست، نشانه‌ای مهم از تعادل مناسب مدل‌ها بین دقت و تعمیم‌پذیری است. چنین رفتار پایدار و قابل اعتمادی در مدل‌ها، بیانگر آن است که پدیده بیش‌برازش رخ نداده و مدل‌ها توانسته‌اند روابط غیرخطی و پیچیده موجود در داده‌ها را به خوبی و بدون افراط در یادگیری جزئیات خاص مجموعه آموزش، درک کنند. از سوی دیگر، با توجه به اینکه ابزارهای مورد استفاده برای پیاده‌سازی مدل‌های  $FIS$  و  $GEP$  در این پژوهش، امکان اجرای مستقیم تکنیک‌های متداول اعتبارسنجی مانند اعتبارسنجی متقابل  $k$ -fold<sup>۵</sup> را ندارند، لذا ارزیابی مدل‌ها از طریق مجموعه تست به‌عنوان یک معیار معتبر در سنجش تعمیم‌پذیری مورد استفاده قرار گرفته است. بعلاوه چون داده‌های تست کاملاً مستقل از مرحله آموزش بوده‌اند، می‌توان عملکرد مدل‌ها را بر مبنای این ارزیابی به‌طور منطقی و قابل اطمینان قضاوت کرد.

به‌منظور بررسی پایداری، عملکرد واقع‌گرایانه و عدم بیش‌برازش مدل‌های هوش مصنوعی مورد استفاده، تحلیل دقیق آماری و تصویری با استفاده از هیستوگرام باقیمانده‌ها<sup>۶</sup> انجام شد. در این تحلیل، هیستوگرام و نمودار پراکندگی باقیمانده‌ها نسبت به مقادیر پیش‌بینی شده برای هر مدل رسم گردید (مطابق شکل ۱۸). نتایج حاصل از آزمون نرمال بودن شاپیرو-ویلک<sup>۷</sup> در شکل فوق نشان دهنده آن است که توزیع باقیمانده‌ها در هر دو مدل از لحاظ آماری نرمال هستند ( $p$ -value > 0.05). این نتیجه بیانگر آن است که باقی‌مانده‌ها

<sup>7</sup> Shapiro-Wilk

<sup>5</sup> k-fold cross-validation

<sup>6</sup> Residuals histogram



شکل ۱۸- هیستوگرام و نمودار پراکندگی باقیمانده‌ها برای مدل‌های FIS و GEP به منظور بررسی پایداری و عدم بیش‌برازش

### ۳-۵- تحلیل مقایسه‌ای

مورد استفاده، تحقیق حاضر در میانه تحقیقات قبلی قرار گرفته و از اعتبار مناسبی برای مدل‌سازی پارامتر مدول تغییرشکل‌پذیری توده سنگ برخوردار است. بعلاوه، با توجه به مقادیر  $R^2$  و  $RMSE$  حاصل از مدل‌های مورد مقایسه، می‌توان نتیجه گرفت که دقت مدل‌های هوش مصنوعی مورد استفاده در این تحقیق یعنی برنامه‌ریزی بیان ژن و سیستم استنتاج فازی در تخمین مدول تغییرشکل‌پذیری نسبت به اکثر مدل‌های قبلی بهتر بوده و تنها از یک مورد با اختلاف ناچیزی کمتر می‌باشد. در نهایت، مقادیر  $RMSE$  حاصله نشان می‌دهد که خطای مدل‌های هوش مصنوعی مورد استفاده در این تحقیق از اکثر مدل‌های مشابه قبلی (به غیر از دو مورد) کمتر می‌باشد. نتایج تحلیل مقایسه‌ای فوق نشان می‌دهد که تحقیق حاضر از جنبه‌های مختلف (پارامترهای تأثیرگذار در مدل‌سازی، تعداد داده مورد استفاده و دقت و خطای حاصل از مدل‌ها) دارای اعتبار خوبی بوده و نتایج حاصل از آن می‌تواند به منظور تخمین پارامتر مدول تغییرشکل‌پذیری در پروژه‌های مهندسی سنگ مورد استفاده قرار گیرد.

به منظور ارزیابی بیشتر مدل‌های مورد استفاده در این تحقیق و اعتبارسنجی نتایج حاصله، عملکرد آنها با عملکرد مدل‌های مشابه قبلی در زمینه تخمین مدول تغییرشکل‌پذیری توده سنگ مورد مقایسه قرار گرفته است. مقایسه فوق بر اساس پارامترهای ورودی در نظر گرفته شده برای مدل‌سازی، تعداد داده مورد استفاده و مقادیر  $R^2$  و  $RMSE$  حاصله می‌باشد که نتایج آن در جدول ۱۰ نشان داده شده است. همانطور در جدول فوق مشاهده می‌شود، تعداد پارامترهای تأثیرگذار در نظر گرفته شده به منظور مدل‌سازی مدول تغییرشکل‌پذیری توده سنگ در تحقیق حاضر بیشتر از مطالعات قبلی می‌باشد که مزیت مهمی به حساب می‌آید. از ۱۱ مطالعه قبلی که برای مقایسه در نظر گرفته شده است تعداد داده‌ها در ۵ مورد کمتر از تعداد داده‌های مورد استفاده در این تحقیق است، دو مورد نزدیک به تحقیق فعلی و در ۳ مورد هم با اختلاف قابل توجهی تعداد داده‌های مورد استفاده بیشتر است. لذا می‌تواند نتیجه گرفت که از جنبه تعداد داده

جدول ۱۰- مقایسه مقادیر همبستگی و خطای حاصل از مدل های پیشنهادی در این تحقیق با تحقیقات مشابه قبلی

منبع	RMSE	R <sup>2</sup>	تعداد داده	مدل مورد استفاده	پارامترهای ورودی در نظر گرفته شده برای مدل سازی
[۲۴]	۳/۶	۰/۷۷	۷۷	سیستم استنتاج فازی	$E_i, RQD, WD$
[۲۵]	۳/۵۸	۰/۸۷	۱۱۵	سیستم نو-فازی	$E_i, RQD, WD, UCS$
[۲۶]	۲/۸۶	۰/۹۳۱	۱۵۰	برنامه ریزی ژنتیک	$E_i, RQD, UCS, n, \rho_d, J/m$
[۲۷]	۱/۳۶	۰/۹۴	۱۲۰	سیستم استنتاج نو-فازی	$GSI, RQD, UCS, n, \rho_d, J/m$
[۲۸]	۱/۱۱۷	۰/۸۷	۷۲	منطق فازی	$I_s, \rho, n$
[۲۹]	۲/۱	۰/۷۹۸	۱۸۸	سیستم عصبی-ژنتیک	$E_i, RQD, UCS, \rho$
		۰/۷۲۳		شبکه عصبی	
[۳۲]	-	۰/۶۸۹	۵۰	فازی-عصبی	$E_i, RQD, UCS, RMR$
		۰/۷۳۵		برنامه ریزی ژنتیک	
[۳۳]	۰/۱۹۲۱	۰/۸۱۱	۳۳۳	رگرسیون خطی چند متغیره	$E_i, RMR$
[۳۴]	۴/۴۹	۰/۷۶	۶۰	شبیه سازی مونت کارلو	$E_i, H, UCS, RMR$
	۰/۵۳۶	۰/۹۹۹		شبکه عصبی	
[۳۶]	۰/۵۷۹	۰/۹۹۸	۱۴۶	جنگل تصادفی	$RMR, I_s$
	۱/۵۴	۰/۹۹۸		شبکه همسایگی K	
	۱/۵۷	۰/۹۷		رگرسیون خطی چند متغیره	
	۰/۱۱۶			شبکه عصبی مصنوعی،	
[۳۷]	۰/۱۳۴	-	۶۰	نزدیکترین همسایگی	$E_i, H, UCS, RMR$
	۰/۱۵			جنگل تصادفی	
تحقیق حاضر	۱/۲۷	۰/۹۸۶۹		برنامه ریزی بیان ژن	
	۱/۵۱	۰/۹۷۷۸	۱۰۴	سیستم استنتاج فازی	$H, RQD, W, UCS, I, JRC, FT$
	۴/۴۵	۰/۷۴۴۴		رگرسیون خطی چند متغیره	

#### ۴-۵- تحلیل اهمیت متغیر

فرآیند تحلیل اهمیت متغیر معمولاً برای تعیین تأثیر متغیرهای ورودی مدول بر متغیر خروجی مرتبط با انجام می شود. تعیین تأثیر ورودی های مدول بر خروجی معمولاً به دو صورت سنتی و جدید انجام می شود. در روش سنتی از تغییر یک پارامتر و ثابت نگه داشتن بقیه پارامترها برای تعیین تأثیر آن پارامتر استفاده می شود. در روش های جدید، روابط ریاضی مشخصی برای تعیین اثر پارامترهای ورودی بر پارامتر خروجی مورد استفاده قرار می گیرد [۴۰]. با توجه به اینکه مدول برنامه ریزی بیان ژن در این تحقیق از دو مدول سیستم استنتاج فازی و رگرسیون چند متغیره خطی دقیق تر است (مطابق جدول ۹)، لذا تحلیل اهمیت متغیرها بر روی نتایج

مدل برنامه ریزی بیان ژن انجام می شود. در این تحقیق، آنالیز حساسیت مدول سازی و بررسی اهمیت پارامترهای ورودی بر متغیر خروجی (مدول تغییرشکل پذیری توده سنگ) با استفاده از روش میدان کسینوسی<sup>۸</sup> (CAM) و در محیط نرم افزار Statistica انجام شده است. تأثیر پارامتر ورودی ( $r_{ij}$ ) بر متغیر خروجی (هدف) در این روش با استفاده از رابطه (۹) محاسبه شده و مقادیر اهمیت ورودی ها در بازه ۰ و ۱ محاسبه و سازماندهی می شود. در این روش، مقادیر بالاتر  $r_{ij}$  (مقادیر نزدیکتر به ۱) تأثیر بالاتر متغیر ورودی بر پارامتر خروجی (هدف) را نشان می دهد [۴۰، ۴۶ و ۴۷].

$$r_{ij} = \frac{\sum_{k=1}^m x_{ik} x_{jk}}{\sqrt{\sum_{k=1}^m x_{ik}^2 \sum_{k=1}^m x_{jk}^2}} \quad (9)$$

<sup>8</sup> Cosine amplitude method

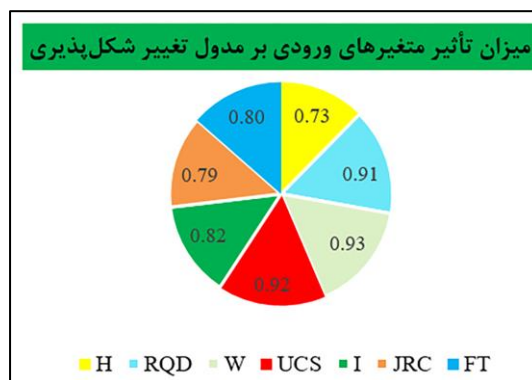
### ۵-۵- مزایا، محدودیت‌ها و مطالعات آتی

در تحقیق حاضر از دو الگوریتم هوش مصنوعی قدرتمند شامل سیستم استنتاج فازی و الگوریتم برنامه‌ریزی بیان ژن به منظور تخمین مدول تغییر شکل پذیری توده سنگ استفاده شده است. مهم‌ترین مزیت و نوآوری این تحقیق، استفاده از الگوریتم‌های جدید هوش مصنوعی با دقت بالا و قابلیت تخمین خوبی است که عملکرد مطلوب و قابلیت تعمیم مناسب آنها هم در بخش‌های قبلی اثبات گردید. همچنین، برای اولین بار در این تحقیق از الگوریتم برنامه‌ریزی بیان ژن برای ارزیابی مدول تغییر شکل پذیری توده سنگ استفاده شده است. علاوه، پارامترهای تأثیرگذاری مانند زاویه تمایل لایه‌بندی، ضریب سختی درزه و میزان پر شدگی درزه در تخمین مدول تغییر شکل پذیری توده سنگ در این تحقیق در نظر گرفته شده است که در تحقیقات قبلی نادیده گرفته شده بود. در نهایت، با توجه به اینکه اندازه‌گیری مستقیم مدول تغییر شکل پذیری توده سنگ به صورت برجا هزینه‌بر و زمان‌بر است، لذا تخمین این پارامتر به صورت غیرمستقیم (موضوع تحقیق حاضر) با دقت بالا و قابلیت تعمیم مناسب می‌تواند به عنوان یک مزیت مهم در نظر گرفته شود. با وجود مزایای فوق، تحقیق حاضر هم مانند هر تحقیق دیگری دارای محدودیت‌هایی است که می‌تواند در تحقیقات آتی مورد مطالعه قرار گیرد.

از جمله محدودیت‌های اصلی تحقیق حاضر می‌توان به تعداد متوسط داده‌ها و تعمیم‌پذیری مدل‌های پیشنهادی اشاره کرد. با این حال، در مطالعات مربوط به مدل‌سازی پارامترهای پیچیده ژئوتکنیکی، داده‌هایی با تعداد حدود ۱۰۰ نمونه و با کیفیت مناسب می‌توانند پایه‌ای قابل‌اتکا برای توسعه مدل‌های پیش‌بینی باشند (همانطور که در بخش ۵-۳ اشاره شد). در این پژوهش، ۱۰۴ نمونه معتبر و بررسی شده مورد استفاده قرار گرفته است که از نظر آماری، برای ارزیابی اولیه و ارائه مدل‌های پیش‌بینی، مقدار قابل قبولی محسوب می‌شود. همچنین، الگوریتم‌های *GEP* و *FIS* برای کاربرد در شرایط با داده‌های نسبتاً محدود طراحی شده‌اند و ساختار آنها به نحوی است که امکان یادگیری روابط پیچیده غیرخطی را حتی با تعداد داده کمتر از ۱۰۴ مورد نیز فراهم می‌آورد. از سوی دیگر، ارزیابی مدل‌ها نشان می‌دهد که مقدار  $R^2$  برای مدل‌های *GEP* و *FIS* به ترتیب برابر با ۰/۹۸۸۹ و ۰/۹۸۲۳ به دست آمده است که بیانگر دقت بالای پیش‌بینی

در رابطه فوق،  $x_{ijk}$  نشان‌دهنده  $k$ امین مقدار ورودی و  $x_{ijk}$  نشان‌دهنده  $k$ امین خروجی مدل به‌ازای همان مقدار ورودی است.

بر اساس روش میدان کسینوسی، مقدار اهمیت هفت متغیر ورودی بر مدول تغییر شکل پذیری توده سنگ محاسبه شده و نتایج حاصله در شکل ۱۹ نشان داده شده است. همان‌طور که مشاهده می‌شود، هوازدگی دارای بیش‌ترین و ارتفاع روباره دارای کم‌ترین تأثیر بر مدول تغییر شکل پذیری توده سنگ هستند. لازم به ذکر است که نتایج آنالیز حساسیت انجام شده محدود به داده‌های مورد استفاده در این تحقیق و ساختگاه سد بختیاری است که ممکن است برای سایر موارد هم صحیح باشد اما قطعیت ندارد. به‌منظور تعمیم نتایج فوق به سایر مطالعات موردی و با به نوعی فرامنطقه‌ای کردن نتایج آنالیز حساسیت، لازم است که داده‌های بیشتری از مناطق و مطالعات موردی مختلف و توده‌سنگ‌های گوناگون در این تحلیل گنجانده شود تا با قاطعیت بیشتری در این زمینه اظهار نظر کرد و بتوان نتایج حاصله را به سایر موارد هم تعمیم داد. در هر صورت، این نتایج بر اساس داده‌های موجود و برای منطقه مورد مطالعه واقعی است و در عمل می‌توان از آن بهره برد ولی برای سایر موارد بایستی با احتیاط مورد استفاده قرار گیرد. با این حال، هدف کلی این تحقیق ارائه یک متدولوژی جدید برای تخمین مدول تغییر شکل پذیری توده سنگ و آنالیز حساسیت پارامترهای تأثیرگذار بر آن است که می‌تواند برای سایر توده‌سنگ‌ها و مطالعات موردی هم به‌روزرسانی و توسعه داده شود تا مورد استفاده قرار گیرد.



شکل ۱۹- میزان تأثیر پارامترهای ورودی بر مدول تغییر شکل پذیری توده سنگ

تک محوری، زاویه تمایل لایه‌بندی، ضریب سختی درزه و میزان پر شدگی به‌عنوان متغیرهای ورودی به‌منظور تخمین مدول تغییرشکل‌پذیری توده‌سنگ (به‌عنوان متغیر خروجی) در نظر گرفته شد. برای ارزیابی مدل‌های فازی و آماری و مقایسه عملکرد آنها، از پنج شاخص ارزیابی عملکرد شامل ریشه میانگین مربعات خطا، میانگین خطای مطلق، واریانس حساب شده، ضریب بازدهی و ضریب تعیین استفاده گردید که مقادیر آنها به‌ترتیب برای مدل برنامه‌ریزی بیان ژن برابر با ۱/۲۷، ۱/۸۵، ۰/۹۹۱۲، ۰/۹۸۸۹ و ۰/۹۸۶۹، برای مدل فازی برابر با ۱/۵۱، ۲/۰۵، ۰/۹۸۷۶، ۰/۹۸۲۳ و ۰/۹۷۷۸ و برای مدل آماری برابر با ۴/۴۵، ۴/۹۷، ۰/۷۶۴۱، ۰/۷۵۶۹ و ۰/۷۴۴۴ به‌دست آمد. نتایج فوق نشان‌دهنده عملکرد بسیار بهتر دو مدل برنامه‌ریزی بیان ژن و سیستم استنتاج فازی نسبت به مدل رگرسیون چند متغیره و تطابق خوب نتایج آنها با داده‌های واقعی است. با این حال، عملکرد مدل برنامه‌ریزی بیان ژن تا حدودی بهتر از مدل سیستم استنتاج فازی است. علاوه، نتایج تحلیل مقایسه‌ای نشان داد که مدل‌های مورد استفاده در این تحقیق دارای همخوانی خوبی با تحقیقات قبلی بوده و در بسیاری از موارد دارای برتری نسبی نسبت به مطالعات مشابه پیشین هستند. در نهایت، نتایج حاصل از تحلیل اهمیت متغیر نشان داد که پارامترهای هوازگی و ارتفاع روباره به‌ترتیب دارای بیش‌ترین و کم‌ترین تأثیر بر مدول تغییرشکل‌پذیری توده‌سنگ می‌باشند. با نظر گرفتن نتایج فوق‌الذکر، می‌توان نتیجه گرفت که مدل‌های بر پایه هوش مصنوعی (برنامه‌ریزی بیان ژن و سیستم استنتاج فازی) دارای عملکرد خوبی در تخمین مدول تغییرشکل‌پذیری توده‌سنگ بوده و می‌توانند با قابلیت اطمینان بالایی در پروژه‌های مکانیک سنگی مورد استفاده قرار گیرند.

## ۷- سپاس‌گزاری

نویسنده از مدیریت و پرسنل محترم پروژه سد و نیروگاه بختیاری برای همکاری در تهیه و جمع‌آوری داده‌های مورد نیاز تحقیق صمیمانه تقدیر و تشکر می‌نماید.

آن‌ها می‌باشد. در مقابل، مدل  $MLR$  تنها ضریب تعیین ۰/۷۴۴۴ را نتیجه داده است که از توان پایین آن در شبیه‌سازی روابط غیرخطی حکایت دارد. بنابراین، انتخاب الگوریتم‌های هوش مصنوعی برای پیش‌بینی مدول تغییرشکل‌پذیری توده‌سنگ، صرفاً به‌دلیل «تعداد داده‌ها» نبوده، بلکه ناشی از نیاز به دقت و قابلیت مدل‌سازی پیچیدگی‌های موجود در داده‌هاست. علاوه بر این، افزایش حجم داده‌ها در این حوزه، مانند بسیاری از مسائل ژئوتکنیکی، معمولاً با چالش‌های قابل توجهی از جمله زمان‌بر بودن، هزینه بالا و محدودیت‌های عملیاتی همراه است. در چنین شرایطی، بهره‌گیری از مدل‌های هوش مصنوعی پیشرفته و دقیق، راهکاری مؤثر برای دستیابی به نتایج قابل اعتماد، کاهش خطای پیش‌بینی و بهینه‌سازی طراحی‌ها محسوب می‌شود. این امر در نهایت به صرفه‌جویی در هزینه‌های اجرایی پروژه منجر خواهد شد. با در نظر گرفتن مجموعه دلایل فوق، به‌نظر می‌رسد که استفاده از مدل‌های هوش مصنوعی در این تحقیق کاملاً موجه، هدفمند و مبتنی بر ملاحظات علمی و عملی بوده و توضیحات ارائه شده فوق دیدگاه کلی پژوهش را شفاف‌تر نموده و ضرورت به‌کارگیری این روش‌ها را به‌درستی تبیین می‌کند. با این حال، انجام مطالعات بیشتر در آینده با استفاده از الگوریتم‌های هوش مصنوعی پیشرفته به‌ویژه مدل‌های ترکیبی با در نظر گرفتن پارامترهای تأثیرگذار بیشتر و افزایش تعداد سری‌های داده مورد استفاده در مدل‌سازی می‌تواند محدودیت‌های احتمالی تحقیق حاضر را پوشش دهد.

## ۶- نتیجه‌گیری

در این تحقیق از سه مدل برنامه‌ریزی بیان ژن، سیستم استنتاج فازی و رگرسیون خطی چند متغیره برای تعیین مدول تغییرشکل‌پذیری توده‌سنگ استفاده گردید. برای طراحی و ارزیابی مدل‌های فوق‌الذکر، ابتدا داده‌های مورد نیاز مربوط به ساختگاه سد بختیاری جمع‌آوری گردید. بر اساس پایگاه داده تهیه شده، هفت پارامتر تأثیرگذار شامل ارتفاع روباره، شاخص کیفیت توده‌سنگ، هوازگی، مقاومت فشاری

## ۸- منابع

- [1] Rezaei, M., Asadizadeh, M., Majdi, A., & Hossaini, M.F. (2015). Prediction of representative deformation modulus of longwall panel roof rock strata using Mamdani fuzzy system. *International Journal of Mining Science and Technology*, 25, 23–30. DOI:10.1016/j.ijmst.2014.11.007.

- [2] Aksoy, C. O., Geniş, M., Aldaş, G. U., Özacar, V., Özer, S. C., & Yılmaz, Ö. (2012). A comparative study of the determination of rock mass deformation modulus by using different empirical approaches. *Engineering Geology*, 131–132, 19–28. DOI:10.1016/j.enggeo.2012.01.009.
- [3] 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*, 32, 245–250. DOI:10.1016/j.tust.2012.07.004.
- [4] Sridevi, J., & Sitharam, T. G. (2003). Characterization of strength and deformation of jointed Rock Mass based on statistical analysis. *International Journal of Geomechanics*, 3(1), 43–54. DOI:10.1061/(ASCE)1532-3641(2003)3:1(43).
- [5] Bieniawski, Z. T. (1973). Engineering classification of rock masses. *Transaction of the South African Institution of Civil Engineers*, 15(12), 335–44.
- [6] Barton, N., Lien, R., & Lunde, J. (1974). Engineering classification of rockmasses for the design of tunnel support. *Rock Mechanics*, 6(4), 189–236. DOI:10.1007/BF01239496
- [7] Palmstrom, A., & Singh, R. (2001). The deformation modulus of rock masses: comparisons between in situ tests and indirect estimates. *Tunnelling and Underground Space Technology*, 16, 115–31. DOI:10.1016/S0886-7798(01)00038-4.
- [8] Nejati, H. R., Ghazvinian, A., Moosavi, S. A., & Sarfarazi, V. (2014). On the use of the RMR system for estimation of rock mass deformation modulus. *Bulletin of Engineering Geology and the Environment*, 73, 531–540. <https://doi.org/10.1007/s10064-013-0522-3>.
- [9] Zhang, L., Einstein, & H. H. (2004). Using RQD to estimate the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Sciences*, 41, 337–41. DOI:10.1016/S1365-1609(03)00100-X.
- [10] Verman, M., Singh, Viladkar, B. M. N., & Jethwa, J. L. (2005). Effect of Tunnel Depth on Modulus of Deformation of Rock Mass. *Rock Mechanics and Rock Engineering*, 30(3), 121–127. DOI:10.1007/BF01047388.
- [11] Beiki, M., Bashiri, A., & Majdi, A. (2010). Genetic programming approach for estimating the deformation modulus of rock mass using sensitivity analysis by neural network. *International Journal of Rock Mechanics and Mining Sciences*, 47(7), 1091–10103. DOI:10.1016/j.ijrmms.2010.07.007.
- [12] Majdi, A., & Beiki, M. (2010). Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Science*, 47(2), 246–253. DOI:10.1016/j.ijrmms.2009.09.011.
- [۱۳] کریم دوست، س.، مهرنهاد، ح.، نجاتی، ح. ر. (۱۳۹۶). ارائه مدل تجربی جدید برای تخمین مدول دگرشکل‌پذیری توده سنگ (مطالعه موردی: سد خرسان). *مجله انجمن زمین‌شناسی مهندسی ایران*، جلد دهم، شماره ۳ و ۴، صفحه ۴۳ تا ۵۳.
- [14] Majdi, A., & Rezaei, M. (2013). Application of artificial neural networks for predicting the height of destressed zone above the mined panel in longwall coal mining. 47th US rock mechanics/geomechanics symposium, ARMA-2013-605, San Francisco, California, USA. ISBN: 978-0-9894844-0-4.
- [15] Rezaei, M., Hossaini, M. F., Majdi, A., & Najmoddini, I. (2017). Determination of the height of destressed zone above the mined panel: An ANN model. *International Journal of Mining and Geo-*

- Engineering*, 51(1), 1–7. DOI:10.22059/ijmge.2017.62147.
- [16] Rezaei, M. (2018). Indirect measurement of the elastic modulus of intact rocks using the Mamdani fuzzy inference system. *Measurement*, 129, 319–331. DOI:10.1016/j.measurement.2018.07.047.
- [17] Rezaei, M. (2020). Feasibility of novel techniques to predict the elastic modulus of rocks based on the laboratory data. *International Journal of Geotechnical Engineering*, 14(1), 25–34. DOI:10.1080/19386362.2017.1397873.
- [18] Rajabi, M., Rahmancejad, R., & Rezaei, M. (2021). Studying the deformation and stability of rock mass surrounding the power station caverns using NA and GEP models. *Structural Engineering and Mechanics*, 79(1), 35–50. DOI:10.12989/sem.2021.79.1.035.
- [19] Wang, Y., Rezaei, M., Abdullah, R. A., & Hasanipanah, M. (2023). Developing Two Hybrid Algorithms for Predicting the Elastic Modulus of Intact Rocks. *Sustainability*, 15(5), 4230. DOI:10.3390/su15054230.
- [20] Rezaei, M., Ahmadi, S. R., Hoang, N., & Jahed Armaghani, D. (2024). Improved determination of the S-wave velocity of rocks in dry and saturated conditions: Application of machine-learning algorithms. *Transportation Geotechnics*, 49, 101371. DOI:10.1016/j.trgeo.2024.101371.
- [21] Ding, X., Hasanipanah, M., & Rezaei, M. (2025). Assessment of mechanical properties of rock using deep learning approaches. *Measurement*, 250, 117180. DOI:10.1016/j.measurement.2025.117180.
- [22] Rezaei, M., & Rajabi, M. (2021). Assessment of plastic zones surrounding the power station cavern using numerical, fuzzy and statistical models. *Engineering with Computers*, 37(2), 1499–1518. DOI:10.1007/s00366-019-00900-3.
- [23] Asadizadeh, M., & Rezaei, M. (2021). Surveying the mechanical response of non-persistent jointed slabs subjected to compressive axial loading utilising GEP approach. *International Journal of Geotechnical Engineering*, 15(10), 1312–1324. DOI:10.1080/19386362.2019.1596610.
- [24] Kayabasi, A., Gokceoglu, C., & Ercanoglu, M. (2003). Estimating the deformation modulus of rock masses: a comparative study. *International Journal of Rock Mechanics & Mining Sciences*, 40(1) 55–63. [https://doi.org/10.1016/S1365-1609\(02\)00112-0](https://doi.org/10.1016/S1365-1609(02)00112-0).
- [25] Gokceoglu, C., Yesilnacar, E., Sonmez, H., & Kayabasi, A. (2004). A neuro-fuzzy model for modulus of deformation of jointed rock masses. *Computers and Geotechnics*, 31(5), 375–383. <https://doi.org/10.1016/j.compgeo.2004.05.001>.
- [26] Beiki, M., Bashari, A., & Majdi, A. (2010). Genetic programming approach for estimating the deformation modulus of rock mass using sensitivity analysis by neural network. *International Journal of Rock Mechanics & Mining Sciences*, 47(7), 1091–1103. <https://doi.org/10.1016/j.ijrmms.2010.07.007>.
- [27] Bashari, A., Beiki, M., & Talebinejad, A. (2011). Estimation of deformation modulus of rock masses by using fuzzy clustering-based modeling. *International Journal of Rock Mechanics & Mining Sciences*, 48(8), 1224–1234. <https://doi.org/10.1016/j.ijrmms.2011.09.017>.
- [۲۸] کیانیپور، م.، سیاری، م.، ارومیه‌ای، ا. (۱۳۹۱). برآورد مقاومت تراکمی تک‌محوری و مدول تغییر شکل‌پذیری شیل‌های سازند شمشک با استفاده از الگوریتم منطق فازی. *فصلنامه علمی علوم زمین*، دوره ۲۱، شماره ۸۳، صفحه ۱۰۳ تا ۱۱۰.

- [29] علی‌آبادیان، ز.، شریف‌زاده، م. (۱۳۹۱). تخمین مدول تغییرشکل‌پذیری سنگ آهک آسماری با استفاده از سیستم عصبی-ژنتیک. *مجله انجمن زمین‌شناسی مهندسی ایران*، دوره ۵، شماره ۱ و ۲، صفحه ۹۳ تا ۱۰۰.
- [30] قاسمی، س. م.، غلام‌نژاد، ج. (۱۳۹۲). ارائه یک مدل شبکه عصبی جهت تخمین مدول تغییرشکل‌پذیری توده‌سنگ. *اولین کنفرانس ملی ژئوتکنیک ایران*، دانشگاه محقق اردبیلی، اردبیل، ایران.
- [31] Feng, X., & Jimenez, R. (2015). Estimation of deformation modulus of rock masses based on Bayesian model selection and Bayesian updating approach. *Engineering Geology*, 199, 19–27. <https://doi.org/10.1016/j.enggeo.2015.10.002>.
- [32] Alemdag, S., Gurocak, Z., Cevik, A., Cabalar, A. F., Gokceoglu, C. (2016). Modeling deformation modulus of a stratified sedimentary rock mass using neural network, fuzzy inference and genetic programming. *Engineering Geology*, 203, 70–82. <https://doi.org/10.1016/j.enggeo.2015.12.002>.
- [33] اصلان زاده، م.، حسینی، م. (۱۳۹۶). پیش‌بینی مدول تغییرشکل‌پذیری توده‌سنگ‌های جنوب غربی ایران با استفاده از رگرسیون خطی چند متغیره. *نشریه علمی-پژوهشی مکانیک سنگ*، دوره ۱، شماره ۱، صفحه ۸۹ تا ۹۶.
- [34] Fattahi, H., Varmazyari, Z., Babanouri, N. (2019). Feasibility of Monte Carlo simulation for predicting deformation modulus of rock mass. *Tunnelling and Underground Space Technology*, 89, 151–156. <https://doi.org/10.1016/j.tust.2019.03.024>.
- [35] Aladejare, A. E., & Idris, M. A. (2020). Performance analysis of empirical models for predicting rock mass deformation modulus using regression and Bayesian methods. *Journal of Rock Mechanics and Geotechnical Engineering*, 12, 1263e1271. <https://doi.org/10.1016/j.jrmge.2020.03.007>.
- [36] Hussain, S., Muhammad Khan, N., Emad, M. Z., Najji, A. M., Cao, K., Gao, Q., Rehman, Z. U., Raza, S., Cui, R., Salman, M., & Alarifi, S. S. (2022). An Appropriate Model for the Prediction of Rock Mass Deformation Modulus among Various Artificial Intelligence Models. *Sustainability*, 14, 15225. <https://doi.org/10.3390/su142215225>.
- [37] فتاحی، ه.، جیریایی شراهی، ف. (۱۴۰۲). استفاده از روش‌های مختلف هوشمند در نرم‌افزار Orange برای تخمین مدول تغییر شکل‌پذیری توده‌سنگ. *مجله انجمن زمین‌شناسی مهندسی ایران*، جلد شانزدهم، شماره ۲، صفحه ۴۷ تا ۶۰.
- [38] Asadizadeh, M., & Hossaini, M. F. (2016). Predicting rock mass deformation modulus by artificial intelligence approach based on dilatometer tests. *Arabian Journal of Geosciences*. 9, 96. DOI:10.1007/s12517-015-2189-5.
- [39] Bakhtyari Joint Venture consultant (2008). Geology report (Stage II studies). Tehran: Iran Water and Power Resources Development Co (IWPC) Authority.
- [40] Rezaei, M., Monjezi, M., Matinpoor, F., Mohammadi Bolbanabad, S., & Habibi, H. (2023). Simulation of induced flyrock due to open-pit blasting using the PCA-CART hybrid modelling. *Simulation Modelling Practice and Theory*, 129, 102844. DOI:10.1016/j.simpat.2023.102844.
- [41] Ferreira, C. (2001). Gene Expression Programming: A New Adaptive Algorithm for Solving Problems. *Complex Systems*, 13(2), 87–129. DOI:10.48550/arXiv.cs/0102027.
- [42] Lopes, H. S. & Weinert, W. R. (2004). Egipsys: An enhanced gene expression programming approach for symbolic regression problems. *International Journal of Applied Mathematics and Computer*

- Science*, 14(3), 375–384.
- [43] Zadeh, L. A. (1965). Fuzzy sets. *Information Control*, 8, 338–53. DOI:10.1016/S0019-9958(65)90241-X.
- [44] Rezaei, M., Monjezi, M., & Yzdian Varjani, A. (2011). Development of a fuzzy model to predict flyrock in surface mining. *Safety Science*, 49(2), 298-305. DOI:10.1016/j.ssci.2010.09.004.
- [45] Rezaei, M., & Rajabi, M. (2018). Vertical displacement estimation in roof and floor of an underground powerhouse cavern. *Engineering Failure Analysis*, 90, 290–309. DOI:10.1016/j.engfailanal.2018.03.010.
- [46] Rezaei, M. (2018). Development of an intelligent model to estimate the height of caving–fracturing zone over the longwall gobs. *Neural Computing & Applications*, 30, 2145–2158. DOI:10.1007/s00521-016-2809-3.
- [47] Rezaei, M. (2019). Forecasting the stress concentration coefficient around the mined panel using soft computing methodology. *Engineering with Computers*, 35, 451–466. DOI:10.1007/s00366-018-0608-4.



## Estimating the rock mass deformation modulus using the statistical and artificial intelligence models

Mohammad Rezaei<sup>1</sup>

1- Associate Professor, Department of Mining Engineering, Faculty of Engineering, University of Kurdistan, Sanandaj, Iran.

Received: 07. July. 2024    Accepted: 21. September. 2024

(\*Corresponding author: m.rezaei@uok.ac.ir)

### Keywords

**Rock Mass Deformation Modulus**  
**Bakhtiari Dam**  
**Gene Expression Programming**  
**Fuzzy Inference System**  
**Multiple Linear Regression**

### Final English Extended Abstract

In this study, two artificial intelligence models—Gene Expression Programming (GEP) and the Fuzzy Inference System (FIS)—along with the conventional statistical method of Multiple Linear Regression (MLR), are employed to estimate the deformation modulus ( $E_m$ ) of rock mass. The results demonstrate the clear superiority of GEP and FIS models over MLR. However, the GEP exhibits slightly better predictive performance than FIS model in estimating  $E_m$ . Furthermore, slightly superiorities of this study compared to the previous similar research were proved based on the comparative analysis. Finally, variable

importance analysis indicates that weathering and overburden is the most influential factor in  $E_m$  modeling, while overburden height has the least effect.

### Introduction

The deformation modulus is a critical parameter that characterizes the mechanical behavior of rock masses and plays an essential role in various rock engineering applications, including surface and underground structures. Conventional methods for estimating  $E_m$  typically involve laboratory testing, in-situ load tests, and empirical equations. However, due to the inherent difficulties and limitations associated with in-situ methods, researchers have increasingly turned to predictive modeling techniques based on rock mass characteristics. To enhance predictive accuracy and overcome the limitations of traditional methods, intelligent modeling approaches have gained prominence. Accordingly, this study investigates the use of GEP, FIS, and MLR techniques to estimate  $E_m$  to cover the limitations of the traditional methods and improve the accuracy of AI-based methods.

### Methodology and Approaches

This study utilizes GEP, FIS and MLR models to predict the  $E_m$ . A total of 104 data records from the Bakhtiari dam site were collected and randomly divided into training (84 records) and testing (20 records) datasets. Optimal models for each method were developed using the training data, and their predictive capabilities were assessed using the testing data. The models' performance was evaluated using standard statistical indices, and comparative analyses were conducted among the models and against measured values and previous similar studies. Finally, variable importance analysis was performed to determine the relative influence of each input parameter on  $E_m$ .

### Results and Conclusions

Attempts were made on both the training and testing datasets to develop optimal versions of the GEP, FIS, and MLR models for estimating  $E_m$ . To achieve this, models' performances are evaluated during both the training and testing phases using performance evaluation indices. The results demonstrate that the GEP and FIS algorithms outperform the MLR model in terms of accuracy. Meanwhile, the GEP algorithm provided more accurate outputs than the FIS model. Based on the comparative analysis, slightly dominances of this research were found compared to the prior studies. Finally, the variable importance analysis revealed that weathering has the highest influence on  $E_m$ , while overburden height has the least effect.