نشریه ژئومکانیک و ژئوانرژی (ژئومکانیک نفت)
GEOMECHANICS and GEOENERGY JOURNAL (GGJ)

مقاله پژوهشی

مقایسه شبکه عصبی مصنوعی الگوریتم ژنتیک و رگرسیون خطی برای پیش‌بینی مقاومت گسیختگی سنگ تحت تنش سه‌محوره واقعی

محمدرضا مطهری[1*]؛ پدرام عسگری[2]؛ سهیلا اداوی[2]

۱- دانشیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه اراک

۲- کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه اراک

دریافت مقاله: ۱۴۰۵/۰۴/۰۵؛ بازنگری مقاله: ۱۴۰۵/۰۵/۲۹؛ پذیرش مقاله: ۱۴۰۵/۰۶/۱۷

شناسه دیجیتال (DOI): 10.22107/ggj.2026.606507.1276

واژگان کلیدی

مقاومت شکست سنگ، تنش سه‌محوره واقعی، شبکه عصبی مصنوعی، الگوریتم ژنتیک، رگرسیون خطی، تنش اصلی میانی

چکیده

تنش اصلی میانی (σ_2) نقش مهمی در فرآیند شکست سنگ تحت شرایط تنش سه‌محوره واقعی دارد؛ بااین‌حال، این اثر در بسیاری از معیارهای متداول شکست دوبعدی نادیده گرفته می‌شود. در این مقاله، عملکرد شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک (*ANN–GA*) و رگرسیون خطی در پیش‌بینی مقاومت شکست سنگ با استفاده از پایگاه داده‌ای شامل ۲۱۲ آزمایش محوره واقعی بر روی پنج نوع سنگ مورد بررسی و مقایسه قرار گرفت. مدل پیشنهادی شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک با استفاده از تنش‌های اصلی میانی و کمینه (σ_2 و σ_3)، تنش اصلی بیشینه در لحظه شکست (σ_1) را پیش‌بینی می‌کند. عملکرد مدل با استفاده از میانگین مربعات خطای اعتبارسنجی (*MSE*) و اعتبارسنجی متقابل پنج‌تایی ارزیابی شد. همچنین، مدل‌های رگرسیون خطی به‌منظور مقایسه با مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک توسعه یافتند. نتایج نشان داد که این مدل برای تمامی انواع سنگ، خطای اعتبارسنجی پایینی داشته ($MSE < ۰٫۰۰۷$) که از قابلیت تعمیم مناسبی برخوردار است. در مقابل، اگرچه مدل‌های رگرسیون خطی توسعه‌یافته برای هر نوع سنگ به دقت پیش‌بینی قابل‌قبولی دست یافتند ($R^2 \geq ۰٫۹۳$)، مدل رگرسیون خطی یکپارچه عملکرد ضعیف‌تری نشان داد ($R^2 = ۰٫۶۸$). این نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک در مقایسه با رگرسیون خطی متداول، توانایی بیشتری در شناسایی و مدل‌سازی اثر غیرخطی تنش اصلی میانی بر مقاومت شکست سنگ دارد. چارچوب پیشنهادی می‌تواند به‌عنوان ابزاری کارآمد و قابل‌اعتماد برای پیش‌بینی مقاومت شکست سنگ در طراحی و تحلیل حفریات زیرزمینی عمیق، تونل‌ها و پایداری چاه‌های حفاری به کار گرفته شود و در عین حال، نیاز به انجام آزمایش‌های آزمایشگاهی گسترده را کاهش دهد.

پیش‌گفتار

مواد سنگی و سرامیکی عموماً در مقایسه با فلزات، رفتار شکننده‌تری از خود نشان می‌دهند؛ این امر عمدتاً به مقاومت کششی نسبتاً پایین و وجود ریزترک‌ها و ناپیوستگی‌های از پیش موجود در این مواد مربوط می‌شود. این نواقص ذاتی، آغازش و گسترش ترک‌ها را تسهیل کرده و اغلب موجب بروز گسیختگی ناگهانی و شکننده تحت بارگذاری می‌شوند. ازاین‌رو، درک نحوه ایجاد و تمرکز تنش در توده‌های سنگی، برای ارزیابی دقیق مقاومت و سازوکارهای گسیختگی سنگ ضروری است. در محیط‌های زیرزمینی عمیق، توده‌های سنگی تحت تأثیر حالت‌های تنش پیچیده سه‌بعدی قرار دارند و ناپیوستگی‌های ذاتی سنگ نقش قابل‌توجهی در آغازش و گسترش ترک‌ها ایفا می‌کنند. بنابراین، معیارهای قابل‌اعتماد گسیختگی سنگ باید شرایط تنش سه‌محوره واقعی را در نظر بگیرند تا بتوانند رفتار مکانیکی سنگ را تحت شرایط

* آدرس: استان مرکزی، اراک، بلوار کربلا، دانشگاه اراک، دانشکده فنی و مهندسی، گروه مهندسی عمران. شماره تلفن همراه: ۰۹۱۹۵۳۸۶۰۹۰. رایانامه نویسنده مسئول: *M-motahari@araku.ac.ir*

بارگذاری درجا به‌طور واقع‌بینانه توصیف کنند [۱].
مطالعات آزمایشگاهی نشان داده‌اند که تنش اصلی میانی (σ_2) نقش مهمی در گسیختگی سنگ ایفا می‌کند. افزایش σ_2 تغییرشکل را در جهات خاصی محدود کرده، موجب توسعه ریزترک‌ها شده و الگوی گسترش ترک را تغییر می‌دهد. این سازوکارها موجب شکل‌گیری الگوهای مشخصی از گسیختگی، ازجمله پوسته‌پوسته‌شدن (گسیختگی پوست‌پیازی) در نزدیکی مرزهای حفریات و ایجاد ترک‌های موازی در نواحی دورتر از بازشدگی‌های زیرزمینی می‌شوند و در نتیجه، پاسخ ناهمسانگرد توده‌های سنگی را افزایش می‌دهند. اگرچه تأثیر σ_2 بر مقاومت نهایی گسیختگی اغلب در مقایسه با تنش اصلی بزرگ‌تر کمتر است، اما این پارامتر تأثیر قابل‌توجهی بر رفتار تغییرشکلی، تکامل شکستگی‌ها و سازوکارهای گسیختگی دارد. این مشاهدات، محدودیت‌های معیارهای متداول گسیختگی دوبعدی را آشکار کرده و ضرورت لحاظ‌کردن اثرات تنش سه‌بعدی در تحلیل‌های مکانیک سنگ را مورد تأکید قرار می‌دهند [۲،۳].
افزایش روزافزون نیاز به توسعه پروژه‌های زیرزمینی عمیق، ازجمله تونل‌سازی، معدن‌کاری، سامانه‌های زمین‌گرمایی، مهندسی نفت و ذخیره‌سازی کربن، ضرورت پیش‌بینی دقیق مقاومت گسیختگی سنگ تحت شرایط تنش سه‌محوره واقعی را افزایش داده است. برآورد قابل‌اعتماد مقاومت سنگ برای کاربردهایی همچون تحلیل پایداری چاه، طراحی حفریات زیرزمینی، عملیات حفاری، شکست هیدرولیکی و ارزیابی پایداری بلندمدت ساختارهای زمین‌شناسی عمیق، از اهمیت اساسی برخوردار است [۲].
نظریه‌های سنتی گسیختگی سنگ، ازجمله معیار موهر–کولمب، به دلیل سادگی و قابلیت کاربرد عملی، به‌طور گسترده مورد استفاده قرار گرفته‌اند. بااین‌حال، این معیارهای تجربی عموماً تأثیر تنش اصلی میانی را نادیده می‌گیرند و ازاین‌رو نمی‌توانند رفتار پیچیده و غیرخطی سنگ‌ها را تحت بارگذاری سه‌محوره واقعی به‌طور کامل توصیف کنند. اگرچه مکانیک شکست، درک سازوکار آغازش و گسترش ترک در مواد شکننده را به‌طور چشمگیری بهبود بخشیده است، تعیین پارامترهای مرتبط با شکست همچنان به انجام آزمایش‌های آزمایشگاهی گسترده نیاز دارد که کاربردهای عملی آن را پرهزینه و زمان‌بر می‌سازد [۴،۵].
شبکه‌های عصبی مصنوعی (*ANN*) به دلیل توانایی در شناسایی روابط پیچیده و غیرخطی، بدون نیاز به تعریف قبلی روابط ریاضی، در سال‌های اخیر در مهندسی سنگ با استقبال فزاینده‌ای مواجه شده‌اند. قابلیت این شبکه‌ها در یادگیری مستقیم از داده‌های آزمایشگاهی، آن‌ها را به ابزاری مناسب برای پیش‌بینی ویژگی‌های مکانیکی سنگ تبدیل کرده است. بااین‌حال، عملکرد پیش‌بینی شبکه‌های عصبی مصنوعی به‌شدت به معماری شبکه و بهینه‌سازی پارامترهای آن وابسته است. روش‌های بهینه‌سازی فراابتکاری، به‌ویژه الگوریتم‌های ژنتیک (*GA*[۱])، کارایی خود را در بهینه‌سازی ساختار شبکه‌های عصبی مصنوعی و پارامترهای آموزش نشان داده‌اند و از این طریق می‌توانند دقت پیش‌بینی، کارایی همگرایی و استحکام مدل را بهبود بخشند [۶–۸].
در سال‌های اخیر، توجه فزاینده‌ای به بررسی تأثیر تنش اصلی میانی بر رفتار مکانیکی سنگ معطوف شده است. وو[۲] و همکاران (۲۰۲۵) گزارش کردند که σ_2 تأثیری دوگانه بر مقاومت سنگ دارد؛ به‌گونه‌ای که ابتدا موجب افزایش مقاومت گسیختگی شده و پس از عبور از یک سطح بحرانی، باعث کاهش مقاومت می‌شود [۹]. فنگ[۳] و همکاران (۲۰۲۵) تأثیر غیرخطی σ_2 و جهت‌گیری سطوح ساختاری را بر مقاومت و الگوهای گسیختگی ماسه‌سنگ نشان دادند [۱۰]. سان[۴] و همکاران (۲۰۲۴) با استفاده از شبیه‌سازی‌های سه‌بعدی مکانیک شکست نشان دادند که جهت‌گیری σ_2 نقش تعیین‌کننده‌ای در کنترل گسترش ترک و سازوکارهای گسیختگی دارد [۱۱]. وانگ[۵] و همکاران (۲۰۲۳) دریافتند که σ_2 و ویژگی‌های سیمانی‌شدن، تأثیر قابل‌توجهی بر تکامل ترک‌های کششی و برشی دارند [۱۲]. یو[۶] و همکاران (۲۰۲۱) گزارش کردند که افزایش σ_2 موجب افزایش هم مقاومت دینامیکی و هم مدول الاستیک سنگ می‌شود [۱۳]. لیو و

---

۱ Genetic Algorithm
۲ Wu
۳ Feng
۴ Sun
۵ Wang
۶ Yu

وانگ[۷] (۲۰۲۱) معیار اصلاح‌شده‌ای برای گسیختگی سنگ ارائه کردند که در آن σ_2 لحاظ شده بود و عملکرد آن در مقایسه با معیارهای متداولی مانند موهر–کولمب برتر بود [۱۴]. مطالعات پیشین همچنین نشان داده‌اند که σ_2 بر تراوایی، رفتار تنش–کرنش، تجمع انرژی الاستیک، گسترش ترک و مقاومت سنگ تحت شرایط بارگذاری سه‌محوره واقعی تأثیرگذار است [۱۵–۲۴]. افزون بر این، خانلری و عبدی (۱۳۹۸) نشان دادند که مدل‌های شبکه عصبی مصنوعی در پیش‌بینی ویژگی‌های مکانیکی سنگ، عملکرد بهتری نسبت به روش‌های رگرسیون متداول دارند [۱۷].

با وجود این پیشرفت‌های قابل‌توجه، همچنان چندین چالش مهم باقی مانده است. بیشتر مطالعات موجود در زمینه یادگیری ماشین عمدتاً بر پیش‌بینی ویژگی‌های مکانیکی سنگ تحت شرایط تنش تک‌محوره یا سه‌محوره متداول متمرکز بوده‌اند؛ درحالی‌که مطالعات نسبتاً اندکی به مقاومت گسیختگی سنگ تحت حالت تنش سه‌محوره واقعی پرداخته‌اند که در آن تنش اصلی میانی به‌طور صریح در نظر گرفته می‌شود. علاوه بر این، اگرچه شبکه‌های عصبی مصنوعی و روش‌های آماری متداول به‌صورت مستقل در حوزه مکانیک سنگ مورد استفاده قرار گرفته‌اند، مقایسه جامع میان شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک (*ANN–GA*[۸]) و مدل‌های رگرسیون خطی با استفاده از یک پایگاه داده آزمایشگاهی یکسان از آزمایش‌های سه‌محوره واقعی، همچنان بسیار محدود است. در نتیجه، توانایی نسبی این رویکردها در شناسایی و مدل‌سازی تأثیر غیرخطی تنش اصلی میانی بر مقاومت گسیختگی سنگ تاکنون به‌طور جامع ارزیابی نشده است.

برای پاسخ به خلأ پژوهشی شناسایی‌شده، هدف این مقاله مقایسه عملکرد یک شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک (*ANN–GA*) و مدل‌های رگرسیون خطی در پیش‌بینی تنش اصلی بزرگ‌تر در لحظه گسیختگی (σ_1) تحت شرایط تنش سه‌محوره واقعی است. برای این منظور، از مجموعه‌داده‌ای شامل ۲۱۲ نتیجه آزمایشگاهی مربوط به پنج نوع سنگ استفاده شد و تنش‌های اصلی میانی (σ_2) و کمینه (σ_3) به‌عنوان متغیرهای ورودی در نظر گرفته شدند. علاوه بر توسعه مدل‌های رگرسیونی اختصاصی برای هر نوع سنگ، یک مدل رگرسیون خطی با استفاده از کل مجموعه‌داده نیز تدوین شد تا عملکرد مدل‌سازی اختصاصی و یکپارچه مقایسه شود. عملکرد مدل‌ها با استفاده از شاخص‌های خطای پیش‌بینی و روش‌های اعتبارسنجی مناسب ارزیابی شد. تمرکز اصلی مقاله بر بررسی توانایی نسبی این روش‌ها در بازنمایی رابطه میان تنش‌های اصلی و مقاومت گسیختگی در محدوده داده‌های آزمایشگاهی موجود است؛ بنابراین، معادلات رگرسیون ارائه‌شده به‌عنوان روابط تجربی پیش‌بینی‌کننده تفسیر می‌شوند و ادعای استخراج یک معیار شکست عمومی و مستقل از نوع سنگ مطرح نمی‌شود.

۲. داده‌ها

۱.۲. انتخاب داده‌ها

در مجموع، ۲۱۲ نتیجه آزمایشگاهی سه‌محوره واقعی مربوط به پنج نوع سنگ نماینده شامل ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت *KTB*، گرانیت و دولومیت دونهام، از مطالعات آزمایشگاهی منتشرشده گردآوری شد (جدول ۱) [۲۵]. نمونه‌های سنگ مورد استفاده در مطالعات مرجع، نمونه‌های سنگ سالم با ابعاد ۵ × ۵ × ۵ سانتی‌متر بودند که تحت شرایط زهکشی‌شده آزمایش شدند.

این پایگاه داده دامنه گسترده‌ای از شرایط تنش را پوشش می‌دهد و مجموعه‌داده‌ای نماینده برای ارزیابی مدل‌های پیش‌بینی تحت بارگذاری سه‌محوره واقعی فراهم می‌کند.

جدول ۱. توزیع نمونه‌ها برای انواع سنگ‌های مورد بررسی [۲۵]

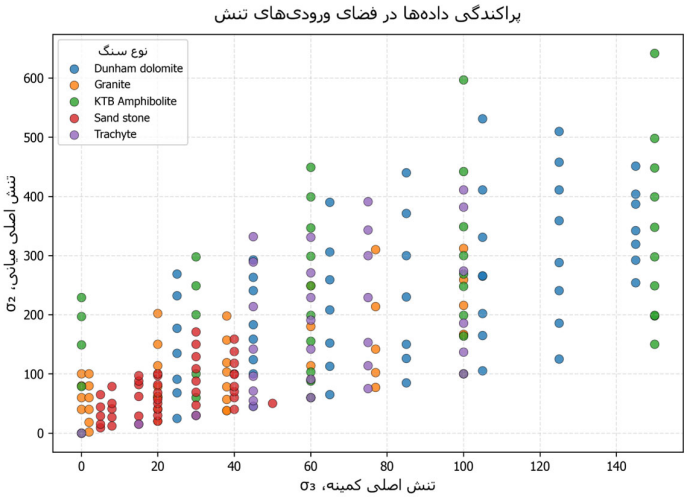
نوع سنگ	تعداد نمونه
ماسه سنگ	۴۴
تراکیت میزوهو	۳۹
آمفیبولیت *KTB*	۴۶
گرانیت	۴۱
دولومیت دونهام	۴۲
مجموع	۲۱۲

در این مقاله، تنش اصلی میانی (σ_2) و تنش اصلی کمینه (σ_3) به‌عنوان متغیرهای ورودی و تنش اصلی بزرگ‌تر در لحظه

[۷] Liu and Wang

[۸] Artificial Neural Network–Genetic Algorithm

گسیختگی (σ_1) به‌عنوان متغیر هدف در نظر گرفته شدند. بنابراین، مدل پیش‌بینی دارای دو ورودی و یک خروجی پیوسته است و هیچ متغیر دیگری به‌عنوان ورودی مستقیم مدل استفاده نشده است. در مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک، برای هر یک از پنج نوع سنگ، شبکه عصبی مستقلی توسعه داده شد؛ ازاین‌رو، نوع سنگ به‌عنوان یک ورودی مستقل به شبکه وارد نشد، بلکه از طریق انتخاب شبکه متناظر با آن لحاظ شد. مقادیر ورودی از نتایج آزمایش‌های سه‌محوره واقعی استخراج شدند و مقادیر اندازه‌گیری‌شده (σ_1) برای آموزش و ارزیابی مدل به کار رفتند. در کل مجموعه‌داده، تنش اصلی میانی (σ_2) در محدوده صفر تا ۶۴۲ مگاپاسکال و تنش اصلی کمینه (σ_3) در محدوده صفر تا ۱۵۰ مگاپاسکال قرار داشت. همان‌طور که در شکل ۱ مشاهده می‌شود، داده‌های آزمایشگاهی در فضای تنش‌های (σ_2) و (σ_3) برای پنج نوع سنگ پراکنده‌اند و دامنه و الگوی توزیع شرایط تنش در میان انواع سنگ متفاوت است. تعداد رکوردها نیز در مجموعه‌داده‌های مربوط به انواع مختلف سنگ یکسان نیست و از ۳۱ رکورد برای تراکیت میزوهو تا ۵۳ رکورد برای دولومیت دونهام متغیر است. این تفاوت و محدودیت نسبی تعداد نمونه‌ها، به‌ویژه برای تراکیت میزوهو، باید هنگام تفسیر نتایج و ارزیابی قابلیت تعمیم مدل‌ها در نظر گرفته شود. برای ارزیابی عملکرد مدل‌ها روی داده‌های خارج از مجموعه آموزش نیز از اعتبارسنجی متقاطع پنج‌بخشی استفاده شد.



شکل ۱. توزیع داده‌های آزمایشگاهی در فضای تنش‌های σ_2 و σ_3 برای پنج نوع سنگ

۲.۲. پیش‌پردازش داده‌ها

پیش از توسعه مدل‌ها، مجموعه‌داده به‌صورت تصادفی درهم‌ریخته شد تا هرگونه سوگیری ناشی از ترتیب داده‌ها حذف شده و تصادفی‌بودن فرایند آموزش بهبود یابد. سپس، تمامی متغیرهای ورودی با استفاده از روش نرمال‌سازی کمینه-بیشینه[۹]، مطابق با رابطه (۱)، به بازه $[0,1]$ تبدیل شدند. نرمال‌سازی داده‌ها از غالب‌شدن متغیرهایی با دامنه عددی بزرگ‌تر بر فرایند یادگیری جلوگیری کرده و موجب بهبود سرعت همگرایی و پایداری الگوریتم آموزش شبکه عصبی مصنوعی می‌شود.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \qquad (۱)$$

۳. مدل ترکیبی ANN–GA

برای پیش‌بینی تنش اصلی بزرگ‌تر در هنگام گسیختگی (σ_1)،

[۹] Min–Max Normalization

از یک شبکه پرسپترون چندلایه پیش‌خور (*MLP*[۱۰]) شامل یک لایه ورودی، سه لایه پنهان و یک لایه خروجی استفاده شد. لایه ورودی از دو نورون متناظر با تنش اصلی میانی (σ_2) و تنش اصلی کمینه (σ_3) تشکیل شد، درحالی‌که لایه خروجی شامل یک نورون بود که مقاومت گسیختگی پیش‌بینی‌شده (σ_1) را نشان می‌داد. تعداد نورون‌های موجود در هر یک از سه لایه پنهان، برای هر نوع سنگ به روش آزمون و خطا تعیین شد و معماری نهایی شبکه‌ها در جدول ۳ ارائه شده است. در تمامی لایه‌های پنهان از توابع فعال‌سازی سیگموید استفاده شد، درحالی‌که برای تولید مقادیر پیوسته در لایه خروجی، تابع فعال‌سازی خطی به‌کار گرفته شد.

به‌منظور رفع مشکل کمینه‌های محلی که معمولاً در فرایند آموزش متداول مبتنی بر پس‌انتشار خطا رخ می‌دهد، از الگوریتم ژنتیک (*GA*) برای بهینه‌سازی وزن‌ها و بایاس‌های اولیه شبکه عصبی مصنوعی استفاده شد. در چارچوب الگوریتم ژنتیک، هر کروموزوم نشان‌دهنده مجموعه کاملی از پارامترهای شبکه است و جمعیت از طریق عملگرهای انتخاب، تقاطع و جهش، تا زمان برآورده‌شدن معیار توقف تکامل می‌یابد. پارامترهای الگوریتم ژنتیک مورد استفاده در این مطالعه در جدول ۲ خلاصه شده‌اند.

پس از اتمام فرایند بهینه‌سازی توسط الگوریتم ژنتیک، وزن‌ها و بایاس‌های بهینه‌شده به‌عنوان راه‌حل اولیه برای آموزش شبکه عصبی مصنوعی مورد استفاده قرار گرفتند. سپس شبکه با استفاده از الگوریتم پس‌انتشار[۱۱] لونبرگ-مارکوارت[۱۲] آموزش داده شد و ۱۵ درصد از داده‌های آموزشی به اعتبارسنجی اختصاص یافت تا قابلیت تعمیم مدل بهبود یافته و خطر بیش‌برازش کاهش یابد.

به‌منظور کاهش وابستگی نتایج به تصادفی‌بودن فرایند جست‌وجو در الگوریتم ژنتیک، فرایند آموزش مدل شبکه عصبی مصنوعی برای هر نوع سنگ در پنج اجرای مستقل انجام شد. نتایج گزارش‌شده در این پژوهش بر اساس میانگین نتایج حاصل از این پنج اجرا ارائه شده‌اند. این رویکرد با هدف کاهش تأثیر تغییرات تصادفی ناشی از مقداردهی اولیه جمعیت و فرایند بهینه‌سازی بر نتایج نهایی اتخاذ شد.

جدول ۲. پارامترهای الگوریتم ژنتیک

پارامتر	مقدار
اندازه جمعیت[۱۳]	۳۰
حداکثر تعداد نسل‌ها[۱۴]	۱۰۰
نخبه‌گرایی[۱۵]	۱۵٪
تقاطع[۱۶]	تک‌نقطه‌ای (۰/۸۰)
جهش[۱۷]	گاوسی (۰/۱۰)
تابع برازندگی[۱۸]	منفیِ میانگین مربعات خطا[۱۹]

۴. ارزیابی عملکرد مدل

عملکرد پیش‌بینی مدل *ANN–GA* با استفاده از میانگین مربعات خطا (*MSE*)، مطابق با رابطه (۲)، ارزیابی شد.

$$MSE = \frac{1}{n}\sum_{i=1}^{n}\left(y_{pred,i} - y_{actual,i}\right)^2 \qquad (۲)$$

که در آن، $y_{actual,i}$ و $y_{pred,i}$ به‌ترتیب بیانگر مقادیر اندازه‌گیری‌شده و پیش‌بینی‌شده تنش اصلی بیشینه در هنگام شکست (σ_1) و n نشان‌دهنده تعداد کل نمونه‌ها است.

به‌منظور ارزیابی استحکام و قابلیت تعمیم مدل توسعه‌یافته *ANN–GA*، اعتبارسنجی متقابل پنج‌تایی با استفاده از کل مجموعه‌داده انجام شد. در این روش، داده‌ها به‌صورت تصادفی به پنج زیرمجموعه تقریباً مساوی تقسیم شدند. در هر تکرار، چهار زیرمجموعه برای آموزش مدل و زیرمجموعه باقی‌مانده برای اعتبارسنجی مورد استفاده قرار گرفت. این فرایند پنج بار تکرار شد، به‌گونه‌ای که هر زیرمجموعه یک‌بار به‌عنوان مجموعه اعتبارسنجی مورد استفاده قرار گرفت و در نهایت، میانگین خطای پیش‌بینی محاسبه شد.

برای مقایسه، یک مدل رگرسیون خطی چندگانه سه‌بعدی

[۱۰] Multilayer Perceptron
[۱۱] Backpropagation Algorithm
[۱۲] Levenberg–Marquardt
[۱۳] Population Size
[۱۴] Maximum Generations
[۱۵] Elitism
[۱۶] Crossover
[۱۷] Mutation
[۱۸] Fitness Function
[۱۹] MSE- Mean Squared Error

متداول نیز با استفاده از نرم‌افزار اس‌پی‌اس‌اس[۲۰] توسعه داده شد. این مدل، σ_1 را به‌صورت یک تابع خطی از σ_2 و σ_3 و مطابق با رابطه (۳) پیش‌بینی می‌کند.

$$\sigma_1 = a \cdot \sigma_2 + b \cdot \sigma_3 + c \qquad (۳)$$

معادلات رگرسیون به‌صورت جداگانه برای هر نوع سنگ و همچنین برای کل مجموعه‌داده توسعه داده شدند. عملکرد پیش‌بینی مدل‌های رگرسیون با استفاده از ضریب تعیین[۲۱] (R^2)، جذر میانگین مربعات خطا[۲۲] و میانگین خطای مطلق نسبی[۲۳] ارزیابی شد.

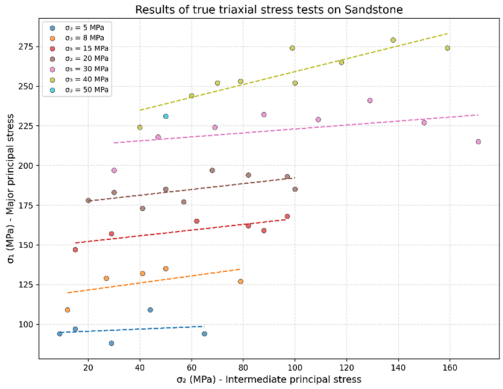
۵. تحلیل و نتایج

۱.۵. تأثیر تنش اصلی میانی بر مقاومت گسیختگی

پایگاه داده آزمایشگاهی شامل ۲۱۲ آزمایش سه‌محوره واقعی انجام‌شده بر روی پنج نوع سنگ، شامل ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت *KTB*، گرانیت و دولومیت دونهام بود. شکل‌های ۲ تا ۶ تغییرات تنش اصلی بزرگ‌تر در هنگام گسیختگی (σ_1) را نسبت به تنش اصلی میانی (σ_2) در سطوح مختلف تنش اصلی کمینه (σ_3) نشان می‌دهند.

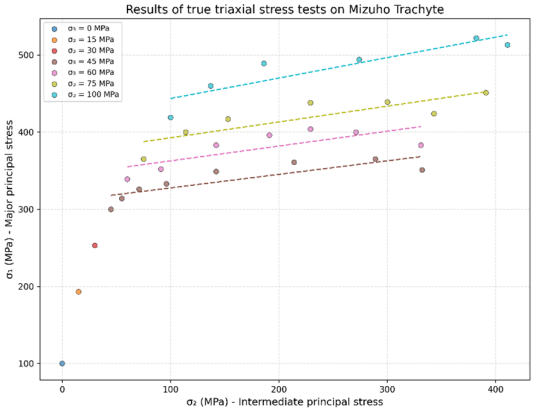
مشاهدات آزمایشگاهی نشان می‌دهند که تأثیر تنش اصلی میانی در انواع سنگ‌های بررسی‌شده متفاوت است. در ماسه‌سنگ و تراکیت میزوهو، مقاومت گسیختگی با افزایش σ_2 تغییرات نسبتاً محدودی نشان می‌دهد، درحالی‌که در آمفیبولیت *KTB*، گرانیت و دولومیت دونهام، افزایش σ_2 با افزایش محسوس‌تر σ_1 همراه است. این تفاوت‌ها به‌وضوح از روندهای مشاهده‌شده در شکل‌های ۲ تا ۶ قابل تشخیص هستند.

شکل ۲ نتایج آزمایش‌های سه‌محوره واقعی انجام‌شده بر روی ماسه‌سنگ را نشان می‌دهد. برای تمامی مقادیر بررسی‌شده σ_3، تنش اصلی بزرگ‌تر در هنگام گسیختگی با افزایش σ_2 تقریباً ثابت باقی می‌ماند که نشان‌دهنده وابستگی محدود مقاومت گسیختگی به تنش اصلی میانی است.



شکل ۲. نتایج آزمایش سه‌محوره واقعی برای ماسه‌سنگ

شکل ۳ نتایج متناظر حاصل از آزمایش‌های انجام‌شده بر روی تراکیت میزوهو را نشان می‌دهد. مقاومت گسیختگی در مقادیر نسبتاً پایین σ_2 اندکی افزایش می‌یابد و سپس به یک سطح تقریباً ثابت نزدیک می‌شود. بنابراین، تأثیر کلی σ_2 در محدوده تنش مورد بررسی نسبتاً محدود باقی می‌ماند.

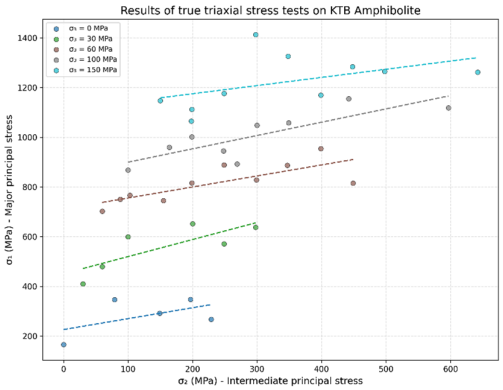


شکل ۳. نتایج آزمایش سه‌محوره واقعی برای تراکیت میزوهو

نتایج به‌دست‌آمده برای آمفیبولیت *KTB* در شکل ۴ ارائه شده است. برخلاف انواع سنگ‌های پیشین، تنش اصلی بزرگ‌تر در هنگام گسیختگی با افزایش تنش اصلی میانی، برای تمامی

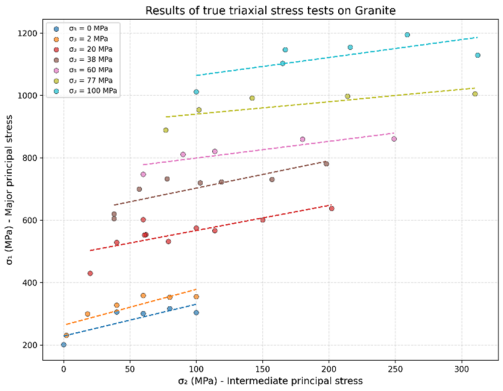
[۲۰] IBM SPSS Statistics
[۲۱] Coefficient of Determination
[۲۲] RMSE- Root Mean Squared Error
[۲۳] MRAE- Mean relative absolute error

مقادیر بررسی‌شده σ_3، به‌طور پیوسته افزایش می‌یابد. این روند مثبت نشان‌دهنده وابستگی قابل‌توجه‌تر σ_1 به σ_2 است.



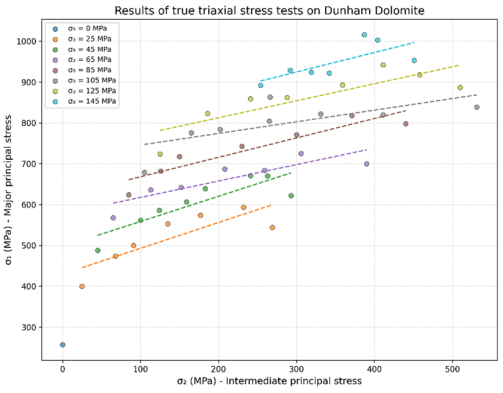
شکل ۴. نتایج آزمایش سه‌محوره واقعی برای آمفیبولیت KTB

شکل ۵ نتایج آزمایشگاهی مربوط به گرانیت را ارائه می‌دهد. مشابه آمفیبولیت، مقاومت گسیختگی به‌طور کلی با افزایش σ_2 افزایش می‌یابد. این افزایش در شرایط تنش محصورکننده بالاتر، آشکارتر است.



شکل ۵. نتایج آزمایش سه‌محوره واقعی برای گرانیت

شکل ۶ رفتار دولومیت دونهام را تحت بارگذاری سه‌محوره واقعی نشان می‌دهد. به‌طور کلی، با افزایش σ_2، مقدار σ_1 نیز افزایش می‌یابد؛ بااین‌حال، در سطوح بالاتر تنش محصورکننده، روند افزایشی آن کمتر محسوس می‌شود و در بالاترین مقادیر σ_2، کاهش جزئی در σ_1 مشاهده می‌شود.



شکل ۶. نتایج آزمایش سه‌محوره واقعی برای دولومیت دونهام

در مجموع، نتایج آزمایشگاهی نشان می‌دهند که حساسیت مقاومت گسیختگی سنگ نسبت به تنش اصلی میانی، در میان لیتولوژی‌های مختلف به‌طور قابل‌توجهی متفاوت است.

۲.۵. عملکرد مدل ANN–GA

۱.۲.۵. تحلیل میانگین مربعات خطا (MSE)

برای ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک ($ANN–GA$)، از معیار میانگین مربعات خطا در مراحل آموزش و اعتبارسنجی استفاده شد. این معیار میانگین مربعات اختلاف بین مقادیر پیش‌بینی‌شده و مقادیر واقعی تنش اصلی بیشینه در لحظه گسیختگی را اندازه‌گیری می‌کند؛ مقادیر کمتر MSE نشان‌دهنده اختلاف کمتر بین پیش‌بینی‌های مدل و مقادیر واقعی است. معماری شبکه برای هر نوع سنگ به‌صورت جداگانه تعیین شد و تعداد نورون‌های سه لایه پنهان و مقادیر MSE متناظر با هر شبکه در جدول ۳ ارائه شده‌اند.

مقدار MSE اعتبارسنجی برای تراکیت میزوهو برابر با ۰/۰۰۰۱ است که کمترین مقدار در میان شبکه‌های بررسی‌شده محسوب می‌شود. در مقابل، شبکه مربوط به گرانیت با MSE اعتبارسنجی برابر با ۰/۰۰۷ بیشترین مقدار خطا را نشان می‌دهد. مقادیر MSE آموزش نیز از ۰/۰۰۰۰۸ برای تراکیت میزوهو تا ۰/۰۲ برای گرانیت متغیر است. این تفاوت‌ها نشان می‌دهند که میزان خطای پیش‌بینی در

مجموعه‌های مربوط به انواع مختلف سنگ یکسان نیست. با وجود پایین بودن مقادیر *MSE* در برخی شبکه‌ها، این معیار به‌تنهایی برای اثبات قابلیت تعمیم مدل یا برتری آن نسبت به روش رگرسیون خطی کافی نیست. تفسیر نتایج باید با توجه به مقیاس خروجی هنگام محاسبه خطا، نحوه تقسیم داده‌ها به مجموعه‌های آموزشی و اعتبارسنجی و سایر شاخص‌های ارزیابی انجام شود. ازاین‌رو، مقادیر جدول ۳ به‌عنوان شاخصی از خطای آموزش و اعتبارسنجی شبکه‌های منتخب گزارش می‌شوند و مبنای نتیجه‌گیری نهایی درباره عملکرد مقایسه‌ای دو روش، به‌تنهایی قرار نمی‌گیرند.

جدول ۳. معماری شبکه و مقادیر متناظر میانگین مربعات خطا برای هر نوع سنگ

نوع سنگ	تعداد نورون‌های لایه ۱	تعداد نورون‌های لایه ۲	تعداد نورون‌های لایه ۳	*MSE* آموزش	*MSE* اعتبارسنجی
ماسه سنگ	۷	۳	۹	۰/۰۰۰۵	۰/۰۰۲
تراکیت میزوهو	۱۴	۹	۲۰	۰/۰۰۰۰۸	۰/۰۰۰۱
آمفیبولیت *KTB*	۱۳	۱۰	۹	۰/۰۰۰۳	۰/۰۰۰۵
گرانیت	۱۲	۷	۱۶	۰/۰۲	۰/۰۰۷
دولومیت دونهام	۱۸	۱۵	۱۵	۰/۰۰۰۲	۰/۰۰۰۵

۲.۲.۵. اعتبارسنجی متقابل پنج‌تایی

به‌منظور ارزیابی استحکام و قابلیت تعمیم مدل *ANN–GA*، اعتبارسنجی متقابل پنج‌تایی[۲۴] بر روی مجموعه‌داده ترکیبی انجام شد (جدول ۴). اعتبارسنجی متقابل تنها برای مدل *ANN–GA* به‌کار گرفته شد، زیرا هدف اصلی، ارزیابی پایداری الگوریتم یادگیری غیرخطی بود. مدل‌های رگرسیون خطی قطعی بوده و عملکرد آن‌ها با استفاده از شاخص‌های متداول برازش، شامل ضریب تعیین (R^2)، جذر میانگین مربعات خطا (*RMSE*) و میانگین خطای نسبی مطلق (*MRAE*)، ارزیابی شد.

۳.۵. دقت پیش‌بینی مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک

پس از فرایند آموزش، مدل‌های توسعه‌یافته *ANN–GA* برای پیش‌بینی تنش اصلی بزرگ‌تر در هنگام گسیختگی (σ_1) در نمونه‌های آزمایشی نماینده از هر نوع سنگ مورد استفاده قرار گرفتند. مقادیر پیش‌بینی‌شده در جدول ۵ با مقادیر متناظر به‌دست‌آمده از آزمایش مقایسه شده‌اند.

این مقایسه نشان‌دهنده تطابق نزدیک میان مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده برای تمامی انواع سنگ بررسی‌شده است. در بیشتر موارد، تنها انحرافات اندکی مشاهده می‌شود که تأیید می‌کند مدل *ANN–GA* قادر است رابطه غیرخطی میان σ_2، σ_3 و مقاومت گسیختگی متناظر را با موفقیت بازتولید کند.

جدول ۴. نتایج اعتبارسنجی متقابل پنج‌تایی برای مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک

دوره	*MSE*
۱	۰/۰۶۰۷
۲	۰/۰۵۷۶
۳	۰/۰۷۷۹
۴	۰/۰۴۶۳
۵	۰/۰۵۳۴
میانگین ± انحراف معیار	۰/۰۵۹±۰/۰۱۱

[۲۴] Five-Fold Cross-Validation

جدول ۵. مقایسه پیش‌بینی‌های مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک با نتایج آزمایش سه‌محوره واقعی

ماسه سنگ				تراکیت میزوهو				آمفیبولیت *KTB*				گرانیت				دولومیت دونهام			
σ_3 Act	σ_2 Act	σ_1 Act	σ_1 Pre	σ_3 Act	σ_2 Act	σ_1 Act	σ_1 Pre	σ_3 Act	σ_2 Act	σ_1 Act	σ_1 Pre	σ_3 Act	σ_2 Act	σ_1 Act	σ_1 Pre	σ_3 Act	σ_2 Act	σ_1 Act	σ_1 Pre
۵	۴۴	۱۰۹	۱۰۶/۰۲	۵	۱۰	۱۰۰	۱۰۰/۰۰	۲۰	۱۴۹	۲۹۱	۲۹۰/۸۷	۱	۳۵	۲۰۱	۲۰۱/۸۲	۵	۳۰	۲۵۷	۲۵۵/۵۷
۸	۴۱	۱۳۲	۱۳۰/۲۴	۱۵	۱۵	۱۹۳	۱۹۳/۰۱	۳۰	۲۹۸	۶۳۷	۶۴۷/۰۰	۱	۶۰	۳۰۱	۳۰۴/۲۱	۲۵	۹۱	۵۰۰	۴۹۸/۵۸
۸	۵۰	۱۳۵	۱۳۴/۴۳	۴۵	۵۵	۳۱۴	۳۱۴/۰۰	۶۰	۶۰	۷۰۲	۷۰۴/۰۰	۱	۸۰	۳۱۷	۳۱۳/۸۷	۴۵	۴۵	۴۸۸	۴۸۷/۱۶
۸	۷۹	۱۲۷	۱۲۷/۲۷	۴۵	۹۶	۳۳۳	۳۳۳/۰۰	۶۰	۲۹۹	۸۲۸	۸۴۸/۰۰	۲	۴۰	۳۲۸	۳۲۳/۵۱	۶۵	۶۵	۵۶۸	۵۶۷/۰۸
۱۵	۶۲	۱۶۵	۱۶۴/۷۰	۴۵	۳۳۲	۳۵۱	۳۵۱/۰۱	۶۰	۱۹۹	۸۱۶	۷۹۶/۱۲	۲	۱۰۰	۳۵۵	۳۵۸/۱۹	۸۵	۲۳۰	۷۴۳	۷۴۰/۶۵
۱۵	۹۷	۱۶۸	۱۶۷/۸۰	۶۰	۶۰	۳۳۹	۳۳۹/۰۰	۶۰	۳۴۷	۸۸۷	۸۶۹/۴۴	۲۰	۲۰	۴۳۰	۴۳۰/۲۰	۴۵	۱۸۳	۶۳۹	۶۳۰/۸۰
۲۰	۵۰	۱۸۵	۱۸۵/۵۰	۶۰	۱۹۱	۳۹۶	۳۹۶/۷۰	۶۰	۸۸	۷۵۰	۷۲۳/۰۰	۲۰	۶۰	۵۵۴	۵۵۴/۴۴	۶۵	۱۱۳	۶۳۶	۶۲۷/۶۳
۲۰	۶۸	۱۹۷	۱۹۶/۷۷	۶۰	۲۲۹	۴۰۴	۴۰۴/۰۰	۶۰	۱۵۵	۷۴۵	۷۶۸/۰۰	۳۸	۳۸	۶۲۰	۶۱۹/۱۹	۶۵	۲۰۸	۶۸۷	۶۹۲/۴۲
۴۰	۶۰	۲۴۴	۲۴۸/۸۰	۷۵	۷۵	۳۶۵	۳۶۰/۸۳	۱۰۰	۲۴۸	۹۴۵	۹۱۱/۳۹	۶۰	۹۰	۸۱۱	۸۰۷/۴۹	۱۰۵	۱۰۵	۶۷۹	۶۸۹/۱۰

۴.۵. مدل رگرسیون خطی

به‌منظور فراهم‌کردن یک معیار مبنا برای ارزیابی عملکرد پیش‌بینی مدل پیشنهادی *ANN–GA*، مدل‌های رگرسیون خطی چندگانه با استفاده از همان پایگاه داده آزمایشگاهی سه‌محوره واقعی توسعه داده شدند. مدل‌های رگرسیون با استفاده از نرم‌افزارهای اس‌پی‌اس‌اس و راک‌لب[۲۵] تدوین شدند تا رابطه میان تنش اصلی بزرگ‌تر در هنگام گسیختگی (σ_1) و تنش‌های اصلی میانی (σ_2) و کمینه (σ_3) توصیف شود.

تحلیل رگرسیون بر اساس پارامترهای بدون‌بُعد تعریف‌شده در روابط (۴) تا (۷) انجام شد که متعاقباً برای تدوین مدل رگرسیون سه‌بعدی پیشنهادی مورد استفاده قرار گرفتند

بر اساس این پارامترها، معادلات رگرسیون به‌صورت جداگانه برای هر نوع سنگ استخراج شدند. معیارهای رگرسیون مربوط به ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت *KTB*، گرانیت و دولومیت دونهام، به‌ترتیب در روابط (۸) تا (۱۲) ارائه شده‌اند.

$$q = \frac{1+\sin\varphi}{1-\sin\varphi} \quad (۴)$$

$$\sigma_1^* = \frac{\sigma_1}{\sigma_c} \quad (۵)$$

$$\sigma_2^* = \frac{\sigma_2}{\sigma_c} \quad (۶)$$

$$\sigma_3^* = \frac{\sigma_3}{\sigma_c} \quad (۷)$$

$$\sigma_1^* = 12.25 + 0.29\sigma_2^* + 1.6q\sigma_3^* \quad (۸)$$

$$\sigma_1^* = 23.78 + 0.23\sigma_2^* + 0.93q\sigma_3^* \quad (۹)$$

$$\sigma_1^* = 36.09 + 0.48\sigma_2^* + 1.02q\sigma_3^* \quad (۱۰)$$

$$\sigma_1^* = 27.51 + 0.65\sigma_2^* + 1.4q\sigma_3^* \quad (۱۱)$$

$$\sigma_1^* = 23.42 + 0.45\sigma_2^* + 0.93q\sigma_3^* \quad (۱۲)$$

علاوه بر مدل‌های اختصاصی هر نوع سنگ، یک معادله رگرسیون یکپارچه نیز با استفاده از مجموعه‌داده کامل، شامل تمامی انواع سنگ بررسی‌شده، توسعه داده شد. مدل رگرسیون حاصل در رابطه (۱۳) ارائه شده است. فرم کلی مدل رگرسیون خطی مورد استفاده برای پیش‌بینی تنش اصلی بزرگ‌تر در لحظه گسیختگی، مطابق رابطه (۱۴)، به‌صورت زیر بیان می‌شود.

$$\sigma_1^* = 20.34 + 0.41\sigma_2^* + 1.14q\sigma_3^* \quad (۱۳)$$

$$\sigma_1^* = a + b.\sigma_2^* + c.q\sigma_3^* \quad (۱۴)$$

ضرایب رگرسیون به‌دست‌آمده برای هر نوع سنگ و همچنین برای مجموعه‌داده ترکیبی، در جدول ۶ خلاصه شده‌اند.

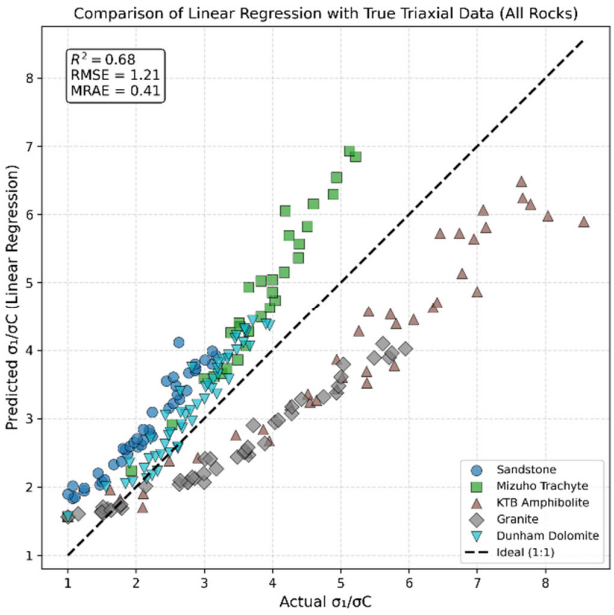
جدول ۶. ضرایب رگرسیون خطی برای انواع سنگ مورد بررسی

نوع سنگ	*a*	*b*	*c*	R^2
ماسه سنگ	۱۲/۲۵	۰/۲۹	۱/۶۰	۰/۹۴
تراکیت میزوهو	۲۳/۷۸	۰/۲۳	۰/۹۳	۰/۹۴
آمفیبولیت *KTB*	۳۶/۰۹	۰/۴۸	۱/۰۲	۰/۹۳
گرانیت	۲۷/۵۱	۰/۶۵	۱/۴۰	۰/۹۶
دولومیت دونهام	۲۳/۴۲	۰/۴۵	۰/۹۳	۰/۹۴
کل داده‌ها	۲۰/۳۴	۰/۴۱	۱/۱۴	۰/۶۸

[۲۵] RockLab

همان‌طور که در جدول ۶ نشان داده شده است، مدل‌های رگرسیون مجزا برای هر نوع سنگ، مقادیر ضریب تعیین (R^2) را در بازه ۰/۹۳ تا ۰/۹۶ به دست آوردند که بیانگر تطابق رضایت‌بخش مدل‌ها با داده‌های آزمایشگاهی مربوط به هر نوع سنگ است. در مقابل، مدل رگرسیونی توسعه‌یافته با استفاده از مجموعه‌داده ترکیبی، ضریب تعیین پایین‌تری برابر با ۰/۶۸ به دست آورد که نشان‌دهنده تغییرپذیری بیشتر ناشی از مدل‌سازی انواع مختلف لیتولوژی با استفاده از یک معادله خطی واحد است.

شکل ۷ مقادیر پیش‌بینی‌شده حاصل از مدل رگرسیون خطی یکپارچه را با مقادیر آزمایشگاهی متناظر برای تمامی انواع سنگ بررسی‌شده مقایسه می‌کند. نمودار پراکنش، میزان تطابق کلی میان مقاومت‌های گسیختگی پیش‌بینی‌شده و اندازه‌گیری‌شده را نشان داده و تفاوت در دقت پیش‌بینی مدل را در سراسر مجموعه‌داده کامل برجسته می‌کند.



شکل ۷. مقایسه پیش‌بینی‌های رگرسیون خطی با نتایج آزمایش‌های سه‌محوره واقعی

۵.۵. بحث

نتایج آزمایشگاهی نشان می‌دهند که تأثیر تنش اصلی میانی (σ_2) بر مقاومت گسیختگی سنگ، به‌شدت به نوع سنگ وابسته است. داده‌های حاصل از آزمایش‌های سه‌محوره واقعی نشان می‌دهند که ماسه‌سنگ و تراکیت میزوهو با افزایش σ_2، تغییرات نسبتاً محدودی در مقاومت گسیختگی نشان می‌دهند، درحالی‌که آمفیبولیت *KTB*، گرانیت و دولومیت دونهام، به‌طور کلی واکنش قوی‌تری از خود نشان می‌دهند. این مشاهدات بیانگر آن است که تأثیر تنش اصلی میانی را نمی‌توان برای تمامی لیتولوژی‌ها با یک روند واحد نمایش داد.

در عوض، میزان تأثیر این تنش به نوع سنگ و ویژگی‌های مکانیکی متناظر آن تحت شرایط بارگذاری سه‌محوره واقعی وابسته است.

نتایج تحلیل‌های پیش‌بینی نیز نشان می‌دهند که مدل *ANN–GA* قادر است رابطه غیرخطی میان تنش‌های اصلی را به‌طور مؤثر بازتولید کند. این مدل برای انواع سنگ‌های بررسی‌شده مقادیر *MSE* پایینی به دست آورد و در طول پنج زیرمجموعه فرایند اعتبارسنجی متقابل، عملکرد نسبتاً پایداری از خود نشان داد. در مقابل، مدل‌های رگرسیون خطی هنگامی که به‌صورت جداگانه برای هر نوع سنگ توسعه داده شدند، برازش مطلوبی با داده‌های آزمایشگاهی ارائه کردند.

بااین‌حال، مدل رگرسیون یکپارچه که تمامی انواع سنگ را در قالب یک معادله واحد ترکیب می‌کرد، ضریب تعیین به‌مراتب پایین‌تری برابر با ۰/۶۸ به دست آورد. این تفاوت نشان می‌دهد که یک رابطه خطی واحد ممکن است برای نمایش رفتار مکانیکی لیتولوژی‌های مختلف در دامنه شرایط تنشی مورد بررسی کافی نباشد، درحالی‌که مدل *ANN–GA* انعطاف‌پذیری بیشتری برای شناسایی و بازنمایی الگوهای غیرخطی موجود در داده‌های آزمایشگاهی فراهم می‌کند.

لازم به ذکر است که روش‌های ارزیابی به‌کاررفته برای مدل‌های *ANN–GA* و رگرسیون خطی یکسان نبودند. برای مدل *ANN–GA*، اعتبارسنجی متقابل پنج‌تایی به‌منظور ارزیابی پایداری و قابلیت تعمیم فرایند یادگیری غیرخطی آن انجام شد. در مقابل، مدل‌های رگرسیون خطی با استفاده از شاخص‌های متداول ارزیابی عملکرد رگرسیون، شامل R^2، *RMSE* و *MRAE*، ارزیابی شدند. بنابراین، شاخص‌های عملکرد گزارش‌شده نباید به‌عنوان یک مقایسه آماری کاملاً هم‌ارز تفسیر شوند. بااین‌حال، هر دو رویکرد با استفاده از یک پایگاه داده آزمایشگاهی یکسان و متغیرهای ورودی یکسان (σ_2 و σ_3) توسعه داده شدند و از این طریق، مبنایی سازگار برای مقایسه رفتار مدل‌سازی آن‌ها تحت شرایط تنش سه‌محوره واقعی فراهم شد.

از دیدگاه مهندسی، مدل پیشنهادی *ANN–GA* می‌تواند یک رویکرد داده‌محور کاربردی برای برآورد مقاومت گسیختگی سنگ تحت شرایط تنش سه‌محوره واقعی با استفاده از تنش‌های اصلی میانی و کمینه به‌عنوان متغیرهای ورودی فراهم کند. چنین پیش‌بینی‌هایی می‌توانند در طراحی مقدماتی و ارزیابی پایداری تونل‌های عمیق، حفریات زیرزمینی، پروژه‌های معدنی و کاربردهای مهندسی نفت، که در آن‌ها شرایط تنش سه‌بعدی اهمیت دارد، مفید باشند. بااین‌حال، قابلیت کاربرد مدل پیشنهادی به اندازه و ترکیب پایگاه داده آزمایشگاهی موجود محدود است؛ این پایگاه داده شامل ۲۱۲ آزمایش آزمایشگاهی مربوط به پنج نوع سنگ است. مطالعات آینده باید انواع سنگ بیشتری، دامنه‌های تنشی گسترده‌تر و مجموعه‌داده‌های آزمایشگاهی مستقل را دربرگیرند تا استحکام و قابلیت تعمیم چارچوب پیشنهادی برای پیش‌بینی، با اطمینان بیشتری ارزیابی شود.

۶. نتیجه‌گیری

در این مطالعه، عملکرد یک شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک (*ANN–GA*) با مدل‌های رگرسیون خطی چندگانه، به‌منظور پیش‌بینی تنش اصلی بزرگ‌تر در هنگام گسیختگی (σ_1) تحت شرایط تنش سه‌محوره واقعی، مقایسه شد. بر اساس مشاهدات آزمایشگاهی و ارزیابی مدل‌ها، نتایج و جمع‌بندی‌های زیر به دست آمد:

۱. تأثیر تنش اصلی میانی (σ_2) بر مقاومت گسیختگی سنگ به‌شدت به نوع سنگ وابسته بود. ماسه‌سنگ و تراکیت میزوهو حساسیت نسبتاً کمی نسبت به تغییرات σ_2 نشان دادند، درحالی‌که آمفیبولیت *KTB*، گرانیت و دولومیت دونهام، به‌طور کلی واکنش بیشتری نسبت به افزایش σ_2 از خود نشان دادند. این یافته‌ها اهمیت درنظرگرفتن σ_2 را در ارزیابی گسیختگی سنگ تحت شرایط تنش سه‌محوره واقعی برجسته می‌کنند.

۲. مدل *ANN–GA* توانست رابطه غیرخطی میان تنش‌های اصلی را به‌طور مؤثر بازنمایی کند و برای انواع سنگ‌های بررسی‌شده، مقادیر *MSE* پایینی به دست آورد. این مدل همچنین در طول پنج زیرمجموعه فرایند اعتبارسنجی متقابل، عملکرد نسبتاً پایداری نشان داد که بیانگر ظرفیت بالقوه آن برای نمایش روابط غیرخطی مرتبط با گسیختگی سنگ تحت شرایط تنش سه‌بعدی است.

۳. مدل‌های رگرسیون خطی چندگانه اختصاصی هر نوع سنگ، برازش مطلوبی با داده‌های آزمایشگاهی ارائه کردند و مقادیر ضریب تعیین آن‌ها در بازه ۰/۹۳ تا ۰/۹۶ قرار داشت. بااین‌حال، مدل رگرسیون یکپارچه توسعه‌یافته با استفاده از مجموعه‌داده ترکیبی، ضریب تعیین به‌مراتب پایین‌تری برابر با ۰/۶۸ به دست آورد. این نتیجه نشان می‌دهد که یک رابطه خطی واحد ممکن است برای نمایش رفتار مکانیکی انواع مختلف سنگ در محدوده شرایط تنش سه‌محوره واقعی مورد بررسی کافی نباشد.

۴. در چارچوب ارزیابی اتخاذشده در این مطالعه، مدل *ANN–GA* انعطاف‌پذیری بیشتری نسبت به مدل‌های رگرسیون خطی در بازنمایی روابط غیرخطی میان تنش‌های اصلی نشان داد. بااین‌حال، رگرسیون خطی به دلیل سادگی، شفافیت و سهولت پیاده‌سازی، همچنان برای کاربردهای اختصاصی هر نوع سنگ مفید است.

۵. چارچوب پیشنهادی پیش‌بینی می‌تواند در طراحی حفریات زیرزمینی، مهندسی تونل، پروژه‌های معدنی، مهندسی نفت و سایر کاربردهای ژئوتکنیکی مرتبط با شرایط تنش سه‌بعدی مورد استفاده قرار گیرد. بااین‌حال، قابلیت کاربرد آن به اندازه و ترکیب پایگاه داده آزمایشگاهی موجود محدود است؛ این پایگاه داده شامل ۲۱۲ آزمایش آزمایشگاهی مربوط به پنج نوع سنگ است. مطالعات آینده باید انواع سنگ بیشتری و دامنه‌های تنشی گسترده‌تر برای اعتبارسنجی را دربرگیرند تا استحکام، قابلیت تعمیم و کاربردپذیری عملی چارچوب پیشنهادی با دقت بیشتری ارزیابی شود.

۷. سپاس‌گزاری

نویسندگان مقاله از آزمایشگاه مکانیک سنگ دانشگاه اراک به جهت فراهم نمودن امکانات، تجهیزات و فضای آزمایشگاهی مورد نیاز این پژوهش، صمیمانه تشکر و قدردانی می نمایند. این پژوهش از هیچ‌گونه حمایت مالی یا کمک‌هزینه پژوهشی اختصاصی برخوردار نبوده است.

۸. نمادگذاری

جدول ۷. فهرست نمادها

نماد	واحد	تعریف / توضیح
MRAE	—	میانگین خطای نسبی مطلق
MSE	—	میانگین مربعات خطا
RMSE	—	جذر میانگین مربعات خطا
R^2	—	ضریب تعیین
a, b, c	—	ضرایب رگرسیون
n	—	تعداد مشاهدات
q	—	پارامتر بدون‌بُعد (رابطه (۴))
x	—	متغیر اصلی
x_{min}	—	حداقل مقدار متغیر
x_{max}	—	حداکثر مقدار متغیر
x_{norm}	—	متغیر نرمال‌شده
y_{actual}	—	مقدار اندازه‌گیری‌شده تنش اصلی بیشینه در هنگام گسیختگی
y_{pred}	MPa	مقدار پیش‌بینی‌شده تنش اصلی بیشینه در هنگام گسیختگی
φ	°	زاویه اصطکاک داخلی
σ_1	MPa	تنش اصلی بیشینه
σ_2	MPa	تنش اصلی میانی
σ_3	MPa	تنش اصلی کمینه
σ_c	MPa	مقاومت فشاری تک‌محوره سنگ
σ_1^*	—	تنش اصلی بیشینه نرمال‌شده
σ_2^*	—	تنش اصلی میانی نرمال‌شده
σ_3^*	—	تنش اصلی کمینه نرمال‌شده

۹. مراجع

[۱] مومیوند، حسن، معدنی، سیده هدی، حاجی زاده، فرنوش و محمدی، میرعلی. (۱۳۹۵). بررسی پارامتر های معیار شکستِ رامامورتی و هوک و همکارانِ سنگ آهک یکپارچه تا به شدت درزه دار فاقد مواد پرکننده و دارای سطوح صاف. نشریه مهندسی معدن، ۱۱(۳۳)، ۳۳-۴۸. https://dor.isc.ac/dor/20.1001.1.17357616.1395.11.33.4.6

[۲] سیاه منصوری, اصغر و جلالی فر, حسین . (۱۳۹۹). پیش‌بینی مکانیزم گسیختگی سنگ در شرایط تنش سه‌بُعدی بالا با استفاده از روش‌های تجربی و رگرسیون خطی. روش های تحلیلی و عددی در مهندسی معدن, ۱۰(۲۲), ۴۹-۵۸. https://doi.org/10.29252/anm.2019.1366

[3] Cai, M. (2008). Influence of intermediate principal stress on rock fracturing and strength near excavation boundaries: Insight from numerical modeling. International Journal of Rock Mechanics and Mining Sciences, 45(5), 763–772. https://doi.org/10.1016/j.ijrmms.2007.07.026

[۴] آیت اللهی، مجیدرضا و باقری فرد، سارا،۱۳۸۳،چقرمگی شکست موادسنگی وسرامیکی تحت بارگذاری مرکب - بررسی نمونه های آزمایشی،کنفرانس مهندسی معدن ایران،تهران، https://civilica.com/doc/8153

[5] Patton, F.D. (1966). Multiple modes of shear failure in rock. In Proceedings of the 1st Congress of the International Society for Rock Mechanics, Vol. 1 (pp. 509–513), Lisbon, Portugal.

[6] Lu, P., Chen, S., & Zheng, Y. (2012). Artificial intelligence in civil engineering. Mathematical Problems in Engineering, 2012, 145974, 22 pages, 2012. https://doi.org/10.1155/2012/145974

[۷] محمدرضا گلابی، علی محمد آخوندعلی، فریدون رادمنش، (۱۳۹۲). مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاه های منتخب استان خوزستان، فصلنامه

تحقیقات کاربردی علوم جغرافیایی، ۱۳(۳۰)، ۱۵۱-۱۶۹ . magiran.com/p1210249

[۸] کلات جاری، وحیدرضا و طالب پور، محمدحسین. (۱۳۹۷). الگوریتم ترکیبی فراابتکاری برای طراحی بهینه ی سازه‌های اسکلت فلزی. مجله ی مهندسی عمران شریف، ۳۴.۲(۲.۲)، ۴۵-۵۷ . https://doi.org/10.24200/j30.2018.1369

[9] Wu, Z., Zheng, Y., Deng, B., & Deng, S. (2025). Influence of intermediate principal stress on rock strength: Insights from closed crack evolution under true triaxial compression. Theoretical and Applied Fracture Mechanics, 136, 104786. https://doi.org/10.1016/j.tafmec.2024.104786

[10] Feng, F., Xie, Z., Chen, S., Li, D., Peng, S., & Zhang, T. (2025). True triaxial unloading test on the mechanical behaviors of sandstone: Effects of the intermediate principal stress and structural plane. Journal of Rock Mechanics and Geotechnical Engineering, 17(4), 2208–2226. https://doi.org/10.1016/j.jrmge.2024.04.005

[11] Sun, Y., Fei, F., Wong, L.N.Y., et al. (2024). Intermediate principal stress effects on the 3D cracking behavior of flawed rocks under true triaxial compression. Rock Mechanics and Rock Engineering, 57, 4607–4634. https://doi.org/10.1007/s00603-024-03777-x

[12] Wang, F., Feng, X.-T., Zhou, Y., & Yu, X. (2023). Experimental study on failure evolution mechanism of clastic rock considering cementation and intermediate principal stress. Journal of Rock Mechanics and Geotechnical Engineering, 15(7), 1636–1650. https://doi.org/10.1016/j.jrmge.2022.10.009

[13] You, W., Dai, F., Liu, Y., Du, H., & Jiang, R. (2021). Investigation of the influence of intermediate principal stress on the dynamic responses of rocks subjected to true triaxial stress state. Rock Mechanics and Rock Engineering, 54, 4213–4234. https://doi.org/10.1007/s00603-021-02488-2

[14] Wang, Z., & Liu, Q. (2021). Failure criterion for soft rocks considering intermediate principal stress. International Journal of Rock Mechanics and Mining Sciences, 147, 104910. https://doi.org/10.1016/j.ijrmms.2021.104910

[15] Gao, H., Zhang, D., Lu, J., Yin, G., & Wu, M. (2020). Experimental study on influence of intermediate principal stress on the permeability of sandstone. Rock Mechanics and Rock Engineering, 53, 4125–4141. https://doi.org/10.1007/s11242-020-01500-2

[16] Jiang, B., Gu, S., Wang, L., Zhang, G., & Li, W. (2019). Strainburst process of marble in tunnel-excavation-induced stress path considering intermediate principal stress. Journal of Central South University, 26, 984-999. https://doi.org/10.1007/S11771-019-4065-Z

[۱۷] عبدی, یاسین, و خانلری, غلامرضا. (۱۳۹۸). تخمین ویژگی‌های مکانیکی ماسه‌سنگ ها با استفاده از آزمایش سرعت موج و چکش‌اشمیت. یافته‌های نوین زمین‌شناسی کاربردی, ۱۳(۲۵), ۳۳-۴۷ . https://doi.org/10.22084/nfag.2018.16623.1322

[18] Chen, Y., Xu, J., Peng, S., Yan, F., & Fan, C. (2018). A Gas–Solid–Liquid Coupling Model of Coal Seams and the Optimization of Gas Drainage Boreholes. Energies, 11(3), 560. https://doi.org/10.3390/en11030560

[19] Rukhaiyar, S., Sajwan, G., & Samadhiya, N.K. (2018). Strength behavior of plain cement concrete subjected to true triaxial compression. Canadian Journal of Civil Engineering, 45, 179–196. https://doi.org/10.1139/cjce-2017-0114

[20] Rukhaiyar, S., & Samadhiya, N.K. (2017). Strength behaviour of sandstone subjected to polyaxial state of stress. International Journal of Mining Science and Technology, 27(6), 889–897. https://doi.org/10.1016/j.ijmst.2017.06.022

[۲۱] صالح زاده، حسین و جورابچی، علیرضا و حسنلوراد، محمود،۱۳۸۸،بررسی رفتار برشی ماسه-های کربناته به کمک شبکه عصبی مصنوعی،هشتمین کنگره بین المللی مهندسی عمران،شیراز، https://civilica.com/doc/62399

[22] Li, M., Yin, G., Xu, J., Li, W., Song, Z., & Jiang, C. (2016). A novel true triaxial apparatus to study the geomechanical and fluid flow aspects of energy exploitations in geological formations. Rock Mechanics and Rock Engineering, 49, 4647–4659. https://doi.org/10.1007/s00603-016-1060-7

[23] Yin, G., Li, M., Wang, J.G., Xu, J., & Li, W. (2015). Mechanical behavior and permeability evolution of gas infiltrated coals during protective layer mining. International Journal of Rock Mechanics and Mining Sciences, 80, 292–301. https://doi.org/10.1016/j.ijrmms.2015.08.022

[۲۴] هاشمی, مینا و حاجی عزیزی, محمد . (۱۴۰۲). مقایسه تاثیرمدل‌سازی دو بعدی و سه بعدی بر پاسخ لرزه‌ای تونل در توده سنگ‌های درزه‌دار به روش شبه استاتیک. روش های تحلیلی و عددی در مهندسی معدن, ۱۳(۳۶), ۶۱-۷۸. https://doi.org/10.22034/anm.2023.18536.1557

[۲۵] مطهری, محمدرضا, و عسگری, پدرام. (۱۴۰۵). پیش‌بینی مقاومت شکست سنگ با استفاده از روش یادگیری عمیق. مدل‌سازی پیشرفته در مهندسی عمران, ۳(۲), ۱-۱۹. https://doi.org/10.22126/amcen.2026.13602.1072