



Predicting Rock Failure Strength Using Deep Learning Technique

Mohammadreza Motahari¹ , Pedram Asgari² 

1. Corresponding Author, Department of Civil Engineering, Faculty of Engineering, Arak University, Arak, Iran. E-mail: m-motahari@araku.ac.ir

2. Department of Civil Engineering, Faculty of Engineering, Arak University, Arak, Iran. E-mail: p.asgari.02@msc.araku.ac.ir

Article Info

ABSTRACT

Article type:
Research Article

Article history:

Received

2026-02-09

Received in revised form

2026-03-31

Accepted

2026-05-09

Available online

2026-06-22

Keywords:

Intermediate Stress,
True Triaxial Test,
Rock Failure Strength,
Deep Learning,
Artificial Neural Network

The failure behavior of rocks under true triaxial stress conditions is significantly influenced by the intermediate principal stress (σ_2). However, in many traditional rock failure criteria, the effect of this stress component is either neglected or treated in a simplified manner. The main objective of this study is to investigate the role of the intermediate principal stress in rock failure strength and to evaluate the capability of deep learning-based approaches for predicting the major principal stress at failure (σ_1) under true triaxial stress conditions. A comprehensive database comprising approximately 500 true triaxial experimental results obtained from five different rock types with distinct mechanical properties was employed. In the proposed model, the intermediate (σ_2) and minor (σ_3) principal stresses, together with the rock type, were considered as input variables, while the major principal stress at failure (σ_1) was defined as the model output. The experimental results indicate that an increase in the intermediate principal stress has a significant strengthening effect on rock failure resistance. Moreover, the deep learning model demonstrates high predictive accuracy and a strong capability in capturing the nonlinear relationships governing rock failure behavior under true triaxial stress conditions. These findings suggest that the proposed model can be regarded as a reliable tool for predicting rock failure strength in geotechnical and mining engineering applications.

Cite this article: Motahari, Mohammadreza., & Asgari, Pedram. (2026). Predicting Rock Failure Strength Using Deep Learning Technique. *Advanced Modeling in Civil Engineering*, 3(1), 114-132.

DOI: 10.22126/amcen.2026.13602.1072



© The Author(s).

DOI: 10.22126/amcen.2026.13602.1072

Publisher: Razi University

Introduction

Rocks exhibit a more brittle behavior compared to metallic materials, and their failure is primarily influenced by inherent microcracks, structural heterogeneity, and the prevailing stress field. Under high-stress conditions, particularly at great depths, the initiation, propagation, and coalescence of cracks play a decisive role in the rock failure mechanism. Therefore, a precise understanding of rock failure behavior is essential for the safe and stable design of underground structures, deep tunnels, storage spaces, and mining projects. As engineering structures extend deeper, in-situ stress conditions become increasingly complex, and the assumption of symmetric stresses is no longer valid. Field measurements indicate that the three principal stresses (σ_1 , σ_2 , σ_3) are generally unequal, and their differences intensify with depth. Under these conditions, rock mechanical behavior and failure strength can significantly differ from results obtained in conventional triaxial tests, highlighting the need for investigations under true triaxial stress conditions. Many traditional rock failure criteria, including the Mohr–Coulomb criterion, neglect the effect of the intermediate principal stress (σ_2) and consider failure solely as a function of maximum and minimum principal stresses. Such simplifications limit the accuracy of predicting rock failure under triaxial stress states. Consequently, data-driven approaches, particularly deep learning methods, have recently emerged as powerful tools for modeling complex, nonlinear relationships in rock mechanics. These approaches enable accurate prediction of the maximum principal stress at failure (σ_1) based on true triaxial test data, offering a robust and reliable means to enhance the safety and performance assessment of underground and geotechnical projects.

Method

In this study, a data-driven deep learning approach was employed to analyze rock failure behavior under true triaxial stress conditions and to predict the major principal stress at failure (σ_1). The dataset consisted of 500 true triaxial test results obtained from five rock types with different mechanical characteristics, in which the three principal stresses σ_1 , σ_2 , and σ_3 were independently applied and measured. These data realistically represent in-situ stress conditions at depth and allow explicit investigation of the role of the intermediate principal stress. Prior to model development, the raw experimental data were systematically preprocessed, including inspection for missing or inconsistent values, removal of unreliable samples, normalization of input and output variables, and random but controlled partitioning into training, validation, and testing subsets. The intermediate principal stress (σ_2) and the minimum principal stress (σ_3) were selected as input variables, while the major principal stress at failure (σ_1) was defined as the model output. The deep learning model was implemented using a Sequential artificial neural network in the TensorFlow/Keras framework. The network architecture consisted of three fully connected hidden layers with ReLU activation functions and a linear output layer. Model training was performed using the Adam optimizer with the mean squared error loss function. Model performance was evaluated using MAE, MSE, and the coefficient of determination (R^2), complemented by graphical analyses to assess the accuracy and stability of the predictions.

Results

This section presents the results of true triaxial experiments and evaluates the performance of the deep learning model in predicting the major principal stress at failure (σ_1) for five different rock types. Scatter plots of σ_1 versus σ_2 , color-coded by σ_3 , indicate a consistent positive and predominantly nonlinear relationship between the intermediate principal stress and rock failure strength across all rock types. Increasing σ_2 leads to a systematic increase in load-bearing capacity, while higher σ_3 levels further enhance this effect through confining pressure. Despite differences in geological origin and strength range, the overall mechanical response under true triaxial stress conditions exhibits a stable and coherent pattern. The predictive performance of the deep learning model was assessed individually for each rock type. The close clustering of predicted values around the one-to-one line in the real versus predicted plots, together with high coefficients of determination, confirms the accuracy and robustness of the model. Although relatively higher prediction errors were observed for rocks with high strength and more complex mechanical behavior, such as KTB amphibolite, the model successfully captured the dominant trends in σ_1 variation and remained reliable from an engineering perspective. Both graphical and numerical comparisons demonstrate that the model effectively incorporates the combined influence of the intermediate and minimum principal stresses in predicting failure strength. Furthermore, the aggregated analysis across all rock types shows that, despite reduced accuracy compared to single-rock models, the global model reproduces the general resistance trend satisfactorily. Overall, the results confirm the strong capability of the proposed deep learning approach to simulate rock failure behavior under realistic true triaxial stress conditions.

Conclusions

This study investigated rock failure behavior under true triaxial stress conditions with a particular focus on the influence of the intermediate principal stress (σ_2), and developed a deep learning-based model to predict the major principal stress at failure (σ_1). Analysis of true triaxial experimental data for different rock types revealed a consistent positive and predominantly nonlinear relationship between σ_2 and σ_1 . The intermediate principal stress plays a significant role in controlling rock strength and that neglecting its effect, as commonly assumed in conventional failure criteria, may lead to inaccurate strength predictions. The experimental observations further showed that increasing the minimum principal stress (σ_3) enhances rock strength through confining pressure and contributes to a more stable mechanical response. Despite differences in lithology, microstructure, and strength range among the studied rocks, a coherent mechanical trend governed by the combined effects of σ_2 and σ_3 was observed under true triaxial loading conditions.

Author Contributions

All authors participated in writing and revising the article.

Conflict of Interest

Authors declared no conflict of interest.



پیش‌بینی مقاومت شکست سنگ با استفاده از روش یادگیری عمیق

محمدرضا مطهری^۱، پدram عسگری^۲

۱. نویسنده مسئول، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه اراک، اراک، ایران. رایانامه: m-motahari@araku.ac.ir

۲. گروه مهندسی عمران، دانشکده مهندسی، دانشگاه اراک، اراک، ایران. رایانامه: p.asgari.02@msc.araku.ac.ir

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۱۱/۲۰

تاریخ بازنگری: ۱۴۰۵/۰۱/۱۱

تاریخ پذیرش: ۱۴۰۵/۰۲/۱۹

تاریخ انتشار: ۱۴۰۵/۰۴/۰۱

کلیدواژه‌ها: تنش میانی، آزمایش سهمحوری واقعی، مقاومت شکست سنگ، یادگیری عمیق، شبکه عصبی مصنوعی

رفتار شکست سنگ‌ها تحت شرایط تنش سهمحوری واقعی به‌طور قابل‌توجهی تحت تأثیر تنش اصلی میانی (σ_2) قرار دارد. با این حال، در بسیاری از معیارهای سنتی شکست سنگ، اثر این مؤلفه تنش نادیده گرفته شده یا به‌صورت ساده‌سازی شده لحاظ می‌شود. هدف اصلی این پژوهش، بررسی نقش تنش اصلی میانی در مقاومت شکست سنگ‌ها و ارزیابی توانایی روش‌های مبتنی بر یادگیری عمیق در پیش‌بینی تنش اصلی بیشینه در لحظه شکست (σ_1) تحت شرایط تنش سهمحوری واقعی است. یک پایگاه داده جامع شامل حدود ۵۰۰ نتیجه آزمایش سهمحوری واقعی مربوط به پنج نوع سنگ با ویژگی‌های مکانیکی متفاوت مورد استفاده قرار گرفت. در مدل پیشنهادی، تنش‌های اصلی میانی (σ_2) و کمینه (σ_3) به‌همراه نوع سنگ به‌عنوان متغیرهای ورودی و تنش اصلی بیشینه در لحظه شکست (σ_1) به‌عنوان خروجی مدل در نظر گرفته شد. نتایج آزمایشگاهی نشان داد که افزایش تنش میانی نقش مؤثری در افزایش مقاومت شکست سنگ‌ها دارد. همچنین نتایج حاصل از مدل یادگیری عمیق بیانگر دقت بالا و توانایی مناسب آن در بازنمایی روابط غیرخطی حاکم بر رفتار شکست سنگ‌ها تحت شرایط تنش سهمحوری واقعی است. این یافته‌ها نشان می‌دهد که مدل ارائه‌شده می‌تواند به‌عنوان ابزاری قابل اعتماد در مسائل مهندسی ژئوتکنیک و معدن مورد استفاده قرار گیرد.

استناد: مطهری، محمدرضا؛ عسگری، پدram. (۱۴۰۵). پیش‌بینی مقاومت شکست سنگ با استفاده از روش یادگیری عمیق. مجله مدل‌سازی پیشرفته

DOI: 10.22126/amcen.2026.13602.1072

در مهندسی عمران، ۳(۱)، ۱۱۴-۱۳۲.



© نویسندگان.

ناشر: دانشگاه رازی.

۱. مقدمه

سنگ‌ها در مقایسه با مواد فلزی رفتار تردتری از خود نشان می‌دهند و شکست آن‌ها عمدتاً تحت تأثیر ریزترک‌های ذاتی، ناهمگنی ساختاری و میدان تنش حاکم رخ می‌دهد. در شرایط تنش بالا و به‌ویژه در اعماق زیاد، آغاز، گسترش و همگرایی ترک‌ها نقش تعیین‌کننده‌ای در مکانیزم شکست سنگ ایفا می‌کند. از این‌رو، شناخت دقیق رفتار شکست سنگ برای طراحی ایمن و پایدار سازه‌های زیرزمینی، تونل‌های عمیق، فضاهای ذخیره‌سازی و پروژه‌های معدنی از اهمیت اساسی برخوردار است [۱].

با افزایش عمق سازه‌های مهندسی، شرایط تنش درجا پیچیده‌تر شده و فرض تنش‌های متقارن دیگر معتبر نیست. اندازه‌گیری‌های میدانی نشان می‌دهد که سه تنش اصلی (σ_1 ، σ_2 و σ_3) معمولاً برابر نبوده و اختلاف میان آن‌ها با افزایش عمق تشدید می‌شود [۲]. در چنین شرایطی، رفتار مکانیکی و مقاومت شکست سنگ‌ها با نتایج حاصل از آزمایش‌های سه‌محوری معمولی تفاوت قابل توجهی دارد و نیاز به بررسی تحت شرایط تنش سه‌محوری واقعی وجود دارد. با وجود این، بسیاری از معیارهای متداول شکست سنگ، از جمله معیار موهر-کولمب، اثر تنش اصلی میانی (σ_2) را نادیده گرفته و شکست را صرفاً تابعی از تنش‌های اصلی بیشینه و کمینه در نظر می‌گیرند [۳-۵]. این ساده‌سازی اگرچه کاربرد مهندسی گسترده‌ای دارد، اما شواهد آزمایشگاهی متعدد نشان می‌دهد که σ_2 نقش مهمی در تعیین مقاومت شکست، الگوی ترک‌خوردگی و مکانیزم گسیختگی سنگ تحت شرایط تنش سه‌محوری ایفا می‌کند. بنابراین، آزمایش‌های سه‌محوری واقعی به‌عنوان ابزاری ضروری برای بازنمایی دقیق رفتار مکانیکی سنگ‌ها در میدان تنش ناهمسانگرد توسعه یافته‌اند.

با این حال، انجام آزمایش‌های سه‌محوری واقعی به دلیل پیچیدگی تجهیزات، هزینه بالا و زمان‌بر بودن، محدودیت‌هایی دارد و توسعه مدل‌های تحلیلی که بتوانند اثر هم‌زمان سه تنش اصلی را به‌درستی لحاظ کنند، همچنان با چالش مواجه است. افزون بر این، ماهیت غیرخطی و ناهمگن سنگ‌ها موجب می‌شود که مدل‌های مبتنی بر

فرضیات تحلیلی ساده، توانایی محدودی در پیش‌بینی دقیق مقاومت شکست داشته باشند [۶].

در سال‌های اخیر، روش‌های داده‌محور و به‌ویژه یادگیری ماشین و یادگیری عمیق به‌عنوان ابزارهایی قدرتمند برای مدل‌سازی روابط پیچیده و غیرخطی در مسائل ژئومکانیکی مورد توجه قرار گرفته‌اند. این روش‌ها با اتکا به داده‌های آزمایشگاهی، قادرند بدون نیاز به ساده‌سازی‌های کلاسیک، الگوهای پنهان میان مؤلفه‌های تنش و پاسخ مکانیکی سنگ را استخراج کنند [۷، ۸]. استفاده از شبکه‌های عصبی عمیق می‌تواند رویکردی مؤثر برای پیش‌بینی مقاومت شکست سنگ تحت شرایط تنش سه‌محوری واقعی فراهم آورد و دقت پیش‌بینی را نسبت به مدل‌های تحلیلی سنتی به‌طور قابل توجهی افزایش دهد.

مطالعات جدید نشان داده‌اند که تنش میانی و ویژگی‌های ساختاری سنگ‌ها نقش کلیدی در مقاومت و رفتار شکست دارند. بین^۱ و همکاران (۲۰۱۵) نشان دادند که مسیر اعمال تنش می‌تواند تا ۲۵ درصد بر مقاومت پیک تأثیر بگذارد [۹] و لی^۲ و همکاران (۲۰۱۶) بر اهمیت تنش میانی و تنش اصلی حداکثر در تغییر شکل و نفوذپذیری سنگ‌ها تأکید کردند [۱۰]. چن و ابو سلیمان^۳ (۲۰۱۷) مدلی نیمه‌تحلیلی برای شبیه‌سازی رفتار غیرخطی پیش و پس از گسیختگی ارائه دادند [۱۱]. روخایار^۴ و همکاران (۲۰۱۷، ۲۰۱۸) اثر تنش متوسط و سه‌محوری واقعی را بر مقاومت بتن و ماسه‌سنگ بررسی کردند [۱۲، ۱۳] و چن^۵ و همکاران (۲۰۱۸) نشان دادند که افزایش ضریب تنش اصلی متوسط، زاویه اصطکاک داخلی و رفتار هیدرولیکی سنگ‌ها را بهبود می‌بخشد [۱۴]. جیانگ^۶ و همکاران (۲۰۱۹) ارتباط مستقیم σ_2 با شکست ناگهانی و ریزش سنگ را آشکار ساختند [۱۵] و گائو^۷ (۲۰۲۰) نشان داد که تغییرات ساختار درونی ماسه‌سنگ بر الگوی تنش-کرنش و رفتار مکانیکی سنگ اثر مستقیم دارد و روش‌های یادگیری عمیق می‌توانند این اثرات را دقیق‌تر پیش‌بینی کنند [۱۶]. ونگ و لیو^۸ (۲۰۲۱) مدلی دقیق برای سنگ‌های نرم ارائه کردند [۱۷]، وی‌یو^۹ و همکاران (۲۰۲۱) نشان دادند که افزایش تنش میانی مقاومت دینامیکی و مدول الاستیک سنگ‌ها را بهبود

⁶ Jiang⁷ Gao⁸ Wang & Lio⁹ Wei You¹ Yin² Li³ Chen & Abousleiman⁴ Rukhaiyar⁵ Chen

کدهای استفاده شده در مدل یادگیری عمیق نیازمند پردازش سریع و خوانش منظم داده‌ها می‌باشند. به همین منظور، با استفاده از نرم افزار اکسل^{۱۵}، داده‌ها در یک فایل به کد یادگیری عمیق الحاق شدند تا علاوه بر نظم بیشتر، سرعت اجرای کد بالاتر رود.

۲-۲. گردآوری داده‌ها و مبانی آزمایشگاهی

در این مقاله، به منظور بررسی رفتار شکست سنگ‌ها تحت شرایط تنش سه‌محوری و توسعه یک مدل داده‌محور قابل اعتماد، از مجموعه‌ای جامع شامل نتایج آزمایش‌های سه‌محوری واقعی استفاده شد. داده‌های مورد استفاده شامل ۵۰۰ نتیجه آزمایش سه‌محوری واقعی [۳، ۲۰ و ۲۴] هستند که بر روی پنج نوع سنگ با ویژگی‌های مکانیکی و ساختاری متفاوت انجام شده‌اند. این مجموعه داده، دامنه وسیعی از شرایط تنشی و پاسخ‌های مکانیکی سنگ‌ها را پوشش می‌دهد و از نظر آماری و فیزیکی، نماینده‌ای مناسب از رفتار واقعی سنگ‌ها تحت بارگذاری سه‌بعدی محسوب می‌شود. تعداد آزمایش‌های سه‌محوری واقعی انجام شده و داده‌های استفاده شده در هر شکل به تفکیک سنگ در جدول (۱) ارائه شده است.

جدول ۱. تعداد داده‌های مورد استفاده در هر شکل

نوع سنگ	تعداد داده‌های مورد نیاز برای آموزش	تعداد داده‌های مورد نیاز برای آزمایش	آزمایش سه‌محوری واقعی
ماسه‌سنگ	۲۹	۳۰	۹۸
تراکیت میزو هو	۲۸	۲۱	۹۲
آمفیبولیت KTB	۲۷	۳۱	۸۹
گرانیت	۳۳	۳۴	۱۱۰
دولومیت دونهام	۳۳	۳۸	۱۱۱
کلیه سنگ‌ها	۱۲۰	-	-

آزمایش‌های سه‌محوری واقعی با هدف شبیه‌سازی دقیق میدان تنش درجا در اعماق زمین انجام می‌شوند، به گونه‌ای که سه تنش اصلی بیشینه (σ_1)، میانی (σ_2) و کمینه (σ_3) به‌طور مستقل و کنترل شده بر نمونه اعمال می‌گردند. این ویژگی، آزمایش سه‌محوری واقعی را از

می‌بخشد [۱۸]، و ونگ^{۱۰} و همکاران (۲۰۲۲) نقش غیرخطی ویژگی‌های ساختاری و نوع سیمان‌شدگی را در رفتار شکست سنگ‌های آواری نشان دادند [۱۹]. مطهری و ادای (۲۰۲۲) در پژوهشی نقش تنش میانی در رفتار گسیختگی پنج نوع سنگ را بررسی کردند [۲۰]. یوان‌سان^{۱۱} و همکاران (۲۰۲۴) و فنگ^{۱۲} و همکاران (۲۰۲۴) تأثیر جهت‌گیری تنش‌ها و زاویه صفحات ساختاری بر مقاومت و الگوی شکست را مورد بررسی قرار دادند [۲۱، ۲۲] و وو^{۱۳} و همکاران (۲۰۲۵) نشان دادند که یادگیری عمیق قادر است رفتار غیرخطی و پیچیده مقاومت شکست سنگ‌های ترک‌دار تحت تنش‌های محصورکننده بالا را با دقت بالا پیش‌بینی کند [۲۳].

با توجه به این مطالعات، روشن است که بهره‌گیری از روش‌های یادگیری عمیق در تحلیل رفتار شکست سنگ‌ها، به ویژه تحت اثر تنش میانی و ویژگی‌های ساختاری، دقت پیش‌بینی مقاومت شکست را به‌طور قابل توجهی افزایش می‌دهد. این رویکرد نوین، امکان تحلیل دقیق‌تر و ایمن‌تر سازه‌های زیرزمینی و پروژه‌های ژئومکانیکی را فراهم می‌آورد. بر این اساس، هدف مقاله حاضر بررسی نقش تنش اصلی میانی (σ_2) در رفتار شکست سنگ و توسعه یک مدل یادگیری عمیق برای پیش‌بینی تنش اصلی بیشینه در لحظه شکست (σ_1) بر پایه داده‌های آزمایش سه‌محوری واقعی است. استفاده از مجموعه‌ای جامع شامل ۵۰۰ نتیجه آزمایش سه‌محوری واقعی بر روی انواع مختلف سنگ، این امکان را فراهم می‌کند تا رفتار شکست سنگ‌ها تحت میدان تنش واقعی با دقت بالاتری مدل‌سازی شده و گامی مؤثر در جهت بهبود تحلیل پایداری سازه‌های ژئومکانیکی برداشته شود.

۲. روش‌شناسی پژوهش

۲-۱. انتخاب نرم‌افزار و فضای مناسب برای مدل‌سازی

در این مقاله، به دلیل پیچیدگی مدل یادگیری عمیق و نیاز به تحلیل دقیق داده‌ها از نرم افزار پایتون^{۱۴} استفاده شد. پایتون با بهره‌گیری از اجرا سلول به سلول، بستری مناسب برای خطایابی و اجرای بهتر کدها فراهم می‌کند.

¹³ Wu

¹⁴ Python

¹⁵ Excel

¹⁰ Wang

¹¹ Yuan Sun

¹² Feng

مهندسی ژئوتکنیک برخوردار است. تعریف ساختار ورودی-خروجی به این شکل، امکان مدل‌سازی مستقیم رابطه غیرخطی بین مؤلفه‌های تنش و مقاومت شکست سنگ را فراهم می‌سازد و بستر مناسبی برای توسعه مدل‌های داده‌محور با قابلیت تعمیم‌پذیری بالا ایجاد می‌کند.

۴-۲. پیش‌پردازش داده‌ها

پیش از توسعه مدل یادگیری عمیق، داده‌های خام حاصل از آزمایش‌های سه‌محوری واقعی تحت یک فرآیند پیش‌پردازش سیستماتیک قرار گرفتند تا کیفیت، سازگاری و قابلیت استفاده آن‌ها در فرآیند مدل‌سازی افزایش یابد. این مرحله نقش کلیدی در بهبود همگرایی مدل، کاهش خطای پیش‌بینی و جلوگیری از بروز سوگیری‌های عددی ایفا می‌کند.

در گام نخست، داده‌ها از نظر کامل بودن و وجود مقادیر مفقود یا ناسازگار مورد بررسی قرار گرفتند. نمونه‌هایی که دارای اطلاعات ناقص یا مقادیر غیرواقعی تنش بودند، مطابق معیارهای از پیش تعیین‌شده حذف شدند تا پایگاه داده نهایی از نظر فیزیکی و آماری معتبر باقی بماند. این مرحله از پیش‌پردازش در قالب یک رویه محاسباتی پیاده‌سازی شد تا قابلیت بازتولید نتایج تضمین شود.

در ادامه، داده‌ها از نظر دامنه تغییرات بررسی شده و به منظور جلوگیری از غلبه مقادیر بزرگ‌تر تنش بر فرآیند یادگیری شبکه عصبی، عملیات نرمال‌سازی انجام گرفت. در این مقاله، تمامی متغیرهای ورودی و خروجی با استفاده از روش مقیاس‌بندی خطی به بازه بدون بُعد مشخص منتقل شدند. این فرآیند باعث افزایش پایداری عددی الگوریتم آموزش و بهبود سرعت همگرایی مدل شد.

پس از نرمال‌سازی، داده‌ها به مجموعه‌های آموزش و آزمون تقسیم شدند. این تقسیم‌بندی به صورت تصادفی اما کنترل‌شده انجام گرفت تا توزیع آماری متغیرها در هر دو مجموعه حفظ شود. نسبت داده‌های آموزشی و آزمون به گونه‌ای انتخاب شد که هم یادگیری مؤثر مدل و هم ارزیابی مستقل عملکرد آن امکان‌پذیر باشد.

۵-۲. ساختار شبکه عصبی مصنوعی مبتنی بر یادگیری عمیق

پیش به منظور مدل‌سازی رابطه غیرخطی میان مؤلفه‌های تنش سه‌محوری واقعی و مقاومت شکست سنگ، از یک شبکه عصبی مصنوعی مبتنی بر یادگیری عمیق استفاده شد. مدل پیشنهادی با

آزمایش‌های سه‌محوری معمولی متمایز می‌سازد، زیرا در آزمون‌های معمولی، تنش میانی با تنش محصورکننده برابر فرض شده و اثر مستقل آن در نظر گرفته نمی‌شود. در حالی که شواهد آزمایشگاهی و میدانی نشان می‌دهند که تنش اصلی میانی می‌تواند نقش مهمی در تعیین مقاومت شکست، الگوی ترک‌خوردگی و مکانیزم گسیختگی سنگ ایفا کند.

انتخاب داده‌های آزمایشگاهی واقعی، به‌جای داده‌های شبیه‌سازی شده یا مصنوعی، موجب افزایش اعتبار فیزیکی نتایج و قابلیت تعمیم مدل توسعه‌یافته می‌شود. تنوع نوع سنگ‌ها و گستره مقادیر تنش‌های اعمال‌شده در این مجموعه داده، امکان تحلیل رفتار شکست سنگ‌ها را تحت شرایط تنش واقعی و ناهمسانگرد فراهم کرده و بستر مناسبی برای توسعه و ارزیابی مدل‌های پیش‌بینی مبتنی بر یادگیری عمیق ایجاد می‌کند.

۳-۲. تعریف متغیرهای ورودی و خروجی

انتخاب متغیرهای ورودی و خروجی بر اساس اصول مکانیک سنگ، نتایج آزمایش‌های سه‌محوری واقعی و هدف اصلی مطالعه انجام شده است. با توجه به این‌که رفتار شکست سنگ‌ها تحت شرایط تنش سه‌محوری به‌طور مستقیم تابع وضعیت تنش اعمال‌شده است، تنش‌های اصلی به‌عنوان متغیرهای کلیدی در فرآیند مدل‌سازی در نظر گرفته شدند.

متغیرهای ورودی مدل شامل تنش اصلی میانی (σ_2) و تنش اصلی کمینه (σ_3) می‌باشند که هر دو به‌صورت مستقل در آزمایش‌های سه‌محوری واقعی کنترل و اندازه‌گیری شده‌اند. انتخاب این دو مؤلفه تنش به‌عنوان ورودی، با هدف بررسی اثر هم‌زمان تنش محصورکننده و تنش میانی بر رفتار شکست سنگ صورت گرفته است. تنش میانی به‌عنوان یکی از عوامل مؤثر اما کمتر لحاظ‌شده در معیارهای شکست کلاسیک، نقش مهمی در تغییر مقاومت نهایی و مکانیزم گسیختگی سنگ ایفا می‌کند و در این مطالعه به‌صورت صریح وارد فرآیند پیش‌بینی شده است.

متغیر خروجی مدل، تنش اصلی بیشینه در لحظه شکست (σ_1) تعریف شده است که بیانگر مقاومت شکست سنگ تحت شرایط تنش اعمال‌شده می‌باشد. پیش‌بینی دقیق این پارامتر از اهمیت بالایی در تحلیل پایداری سازه‌های سنگی، طراحی حفاریات زیرزمینی و مسائل

جدول ۲. معماری شبکه عصبی مصنوعی یادگیری عمیق و مشخصات آموزش

ویژگی	مشخصات
نوع مدل	شبکه عصبی مصنوعی Sequential در TensorFlow/Kera
ورودی	۲ ویژگی: σ_2 و σ_3 (تنش‌های اصلی میانی و کمینه)
تعداد لایه‌ها	۴ لایه (۳ لایه مخفی + ۱ لایه خروجی)
لایه مخفی ۱	۳۲ Dense نرون، تابع فعال‌سازی ReLU
لایه مخفی ۲	۱۶ Dense نرون، تابع فعال‌سازی ReLU
لایه مخفی ۳	۸ Dense نرون، تابع فعال‌سازی ReLU
لایه خروجی	۱ Dense نرون، بدون تابع فعال‌سازی
تابع خطا	خطای میانگین مربعات
بهینه‌ساز	Adam با نرخ یادگیری ۰.۰۰۵
داده‌های آموزشی	۷۰٪ داده‌ها (X_{train}, y_{train})
داده‌های آزمایشی	۳۰٪ داده‌ها (X_{test}, y_{test})
مقیاس‌دهی داده‌ها	StandardScaler برای هر دو ورودی و خروجی
تعداد دوره	۳۰۰
داده‌های آزمایش	۳۰٪ از داده‌های آموزشی

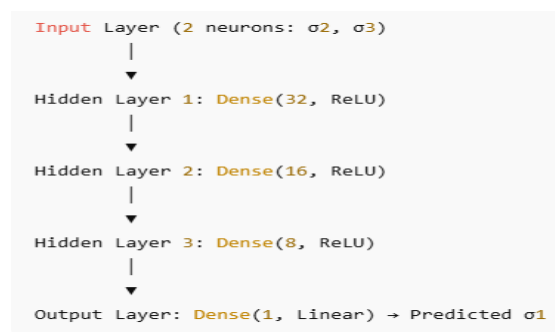
۲-۶. معیارهای ارزیابی عملکرد مدل

پیش به منظور ارزیابی دقت و کارایی مدل یادگیری عمیق پیشنهادی در پیش‌بینی تنش اصلی بیشینه در لحظه شکست (σ_1)، از سه شاخص آماری متداول شامل میانگین خطای مطلق (MAE^{20})، میانگین مربعات خطا (MSE) و ضریب تعیین (R^2) استفاده شد. این معیارها به‌طور گسترده در مسائل رگرسیونی مهندسی برای سنجش میزان انطباق مقادیر پیش‌بینی شده با داده‌های واقعی به کار می‌روند و امکان مقایسه عملکرد مدل‌ها را فراهم می‌کنند. معیار MAE بیانگر میانگین خطای مطلق اختلاف بین مقادیر واقعی و مقادیر پیش‌بینی شده بوده و شاخصی مستقیم از خطای متوسط مدل بدون در نظر گرفتن جهت خطا ارائه می‌دهد. این معیار نسبت به داده‌های پرت حساسیت کمتری دارد و تفسیر آن از دیدگاه مهندسی ساده و قابل فهم است. معیار MSE با مجذور کردن خطاها، به خطاهای بزرگ

بهره‌گیری از چارچوب سکوانشیال^{۱۶} در محیط TensorFlow/Keras پیاده‌سازی گردید که به دلیل سادگی، پایداری عددی و کارایی بالا در مسائل رگرسیونی مهندسی، کاربرد گسترده‌ای دارد.

ساختار شبکه شامل چهار لایه متشکل از سه لایه مخفی تمام‌متصل^{۱۷} و یک لایه خروجی است. لایه ورودی شبکه شامل دو متغیر تنش اصلی میانی (σ_2) و تنش اصلی کمینه (σ_3) بوده که پس از مقیاس‌دهی استاندارد وارد شبکه می‌شوند. لایه‌های مخفی اول تا سوم به ترتیب شامل ۳۲، ۱۶ و ۸ نورون با تابع فعال‌سازی ReLU هستند. استفاده از تابع ReLU با کاهش مشکل ناپدید شدن گرادینت و افزایش سرعت همگرایی، امکان یادگیری روابط پیچیده و غیرخطی بین تنش‌ها و مقاومت شکست را فراهم می‌کند. لایه خروجی شامل یک نورون با تابع فعال‌سازی خطی بوده که برای پیش‌بینی مقدار پیوسته تنش اصلی بیشینه در لحظه شکست (σ_1) مناسب است.

برای آموزش شبکه، از تابع میانگین مربعات خطا^{۱۸} به‌عنوان معیار بهینه‌سازی استفاده شد و پارامترهای شبکه با الگوریتم Adam و نرخ یادگیری ۰.۰۰۵ به‌روزرسانی گردیدند. داده‌ها به‌صورت تصادفی به ۷۰٪ داده آموزشی و ۳۰٪ داده آزمایشی تقسیم شدند و به‌منظور پایش فرآیند یادگیری و جلوگیری از بیش‌برازش، ۳۰٪ از داده‌های آموزشی به‌عنوان مجموعه اعتبارسنجی در نظر گرفته شد. فرآیند آموزش طی ۳۰۰ دوره^{۱۹} انجام گرفت. جزئیات کامل معماری شبکه عصبی مصنوعی یادگیری عمیق و مشخصات آموزش مدل در جدول (۲) و شماتیک معماری شبکه عصبی مصنوعی در شکل (۱) ارائه شده است.



شکل ۱. شماتیک معماری شبکه عصبی مصنوعی


¹⁹ Epoch²⁰ MAE- Mean absolute error¹⁶ Sequential¹⁷ Dense¹⁸ MSE- Mean squared error

شرایط آزمایش سه‌محوری معمولی ($\sigma_2 = \sigma_3$) و دسته دوم در شرایط آزمایش سه‌محوری واقعی ($\sigma_2 \neq \sigma_3$)، در هر سطح از تنش محصورکننده σ_3 ، چندین آزمایش با مقادیر مختلف σ_2 انجام گرفت تا میانگین σ_1 محاسبه شود. سپس با مقایسه میانگین σ_1 در شرایط $\sigma_2 \neq \sigma_3$ با $\sigma_2 = \sigma_3$ در شرایط $\sigma_2 = \sigma_3$ ، درصد افزایش مقاومت ناشی از حضور تنش میانی برای هر سنگ و هر سطح σ_3 تعیین گردید. روند تغییرات تأثیر تنش میانی بر حسب σ_3 برای هر سنگ تحلیل شده است.

۳. یافته‌های پژوهش

۳-۱. بررسی نتایج آزمایش سه‌محوری واقعی

شکل (۲) نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های ماسه‌سنگ را به‌صورت نمودار پراکندگی تنش اصلی بیشینه (σ_1) بر حسب تنش اصلی میانی (σ_2) با نمایش رنگی تنش اصلی کمینه (σ_3) نشان می‌دهد. توزیع نقاط بیانگر وجود رابطه‌ای مثبت و غیرخطی میان σ_1 و σ_2 است، به‌گونه‌ای که با افزایش تنش میانی، مقاومت شکست ماسه‌سنگ به‌طور فزاینده‌ای افزایش می‌یابد. گرادیان رنگی مرتبط با σ_3 نشان می‌دهد که افزایش تنش محصورکننده موجب انتقال نقاط داده به نواحی با مقادیر بالاتر σ_1 می‌شود که این امر بیانگر نقش تقویت‌کننده فشار همه‌جانبه در بهبود رفتار مقاومتی ماسه‌سنگ است. یکنواختی پراکندگی نقاط و پیوستگی تغییرات رنگ، حاکی از رفتار مکانیکی همگن و پاسخ پایدار ماسه‌سنگ در بازه تنش‌های اعمال‌شده می‌باشد.



شکل ۲. نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های سنگ ماسه

وزن بیشتری اختصاص می‌دهد و از این‌رو برای شناسایی پیش‌بینی‌های با انحراف بالا مناسب است. مقدار کمتر MSE نشان‌دهنده همگرایی بهتر مدل به داده‌های واقعی و کاهش خطاهای شدید در فرآیند پیش‌بینی است. ضریب تعیین R^2 میزان توانایی مدل در توضیح تغییرات داده‌های واقعی را نشان می‌دهد و مقدار آن بین صفر و یک متغیر است. مقادیر بالاتر R^2 بیانگر انطباق بهتر مدل با داده‌های آزمایشگاهی و توانایی بیشتر آن در بازنمایی رفتار غیرخطی شکست‌سنگ تحت شرایط تنش سه‌محوری واقعی است.


در این مقاله، مقادیر MAE، MSE و R^2 بر اساس داده‌های مجموعه آزمایشی محاسبه شدند تا ارزیابی عملکرد مدل مستقل از فرآیند آموزش انجام گیرد.

۲-۷. ارزیابی نموداری نتایج

برای بررسی رفتار شکست سنگ‌ها و ارزیابی عملکرد مدل یادگیری عمیق، ابتدا داده‌های واقعی حاصل از آزمایش‌های سه‌محوری بر روی نمونه‌های هر سنگ تحلیل و نمودارهای پراکندگی σ_1 بر حسب σ_2 و σ_3 رسم شد. این نمودارها نشان‌دهنده رابطه مستقیم بین تنش‌های اصلی و مقاومت شکست هستند و مبنای معتبر برای آموزش مدل فراهم می‌کنند. پس از آموزش شبکه عصبی، نمودارهای مقادیر واقعی مقابل مقادیر پیش‌بینی شده σ_1 برای هر نوع سنگ و همچنین کل مجموعه داده‌ها تهیه شد تا انطباق پیش‌بینی‌های مدل با مقادیر واقعی به صورت تصویری مشخص شود. در این نمودارها، خط ۴۵ درجه به عنوان مرجع نشان‌دهنده پیش‌بینی ایده‌آل در نظر گرفته شده است. در ادامه، نمودارهایی برای مقایسه بهتر مقادیر تنش اصلی بیشینه (σ_1) آزمایش سه‌محوری واقعی و تنش اصلی بیشینه (σ_1) پیش‌بینی شده توسط یادگیری عمیق رسم شده است. هدف از رسم این نمودارها، درک دقت مدل ساخته شده با یادگیری عمیق است.

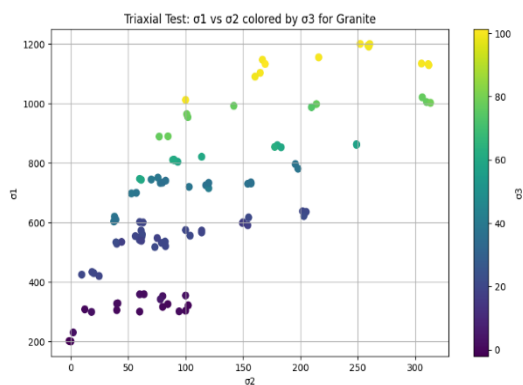
۲-۸. بررسی تأثیر تنش میانی بر تنش بیشینه

برای بررسی تأثیر تنش میانی بر تنش بیشینه سنگ‌ها، داده‌های حاصل از آزمایش‌های سه‌محوری حقیقی بر روی پنج نوع سنگ (ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت KTB، گرانیت و دولومیت دونهام) تحلیل گردید. آزمایش‌ها در دو دسته انجام شد: دسته اول در




شکل ۴. نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های سنگ آمفیبولیت KTB

شکل (۵) نتایج آزمایش‌های سه‌محوری واقعی نمونه‌های گرانیت را به‌صورت نمودار σ_1 بر حسب σ_2 همراه با کد رنگی σ_3 ارائه می‌دهد. برخلاف برخی سنگ‌ها با رفتار کاملاً غیرخطی، رابطه میان σ_1 و σ_2 در گرانیت روندی مثبت و تقریباً خطی را نشان می‌دهد. با افزایش تنش میانی، مقاومت شکست به‌طور سیستماتیک افزایش یافته و این روند در حضور مقادیر بالاتر σ_3 تقویت می‌شود. تجمع نقاط با رنگ‌های تیره‌تر در نواحی با تنش‌های بالاتر نشان‌دهنده نقش مؤثر فشار محصورکننده در افزایش ظرفیت باربری و پایداری مکانیکی گرانیت است. پراکندگی منظم داده‌ها، بیانگر رفتار مقاومتی پایدار و قابلیت اطمینان بالای گرانیت در شرایط تنش سه‌محوری واقعی می‌باشد.



شکل ۵. نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های سنگ گرانیت

شکل (۳) نتایج آزمایش‌های سه‌محوری واقعی بر روی نمونه‌های سنگ تراکیت میزوهو را در قالب نمودار σ_1 بر حسب σ_2 با کد رنگی σ_3 نمایش می‌دهد. مشابه ماسه‌سنگ، رابطه‌ای مثبت و غیرخطی میان تنش اصلی بیشینه و تنش میانی در این سنگ آذرین مشاهده می‌شود. افزایش σ_2 موجب افزایش قابل توجه σ_1 شده و این روند در سطوح بالاتر σ_3 تشدید می‌شود. تمرکز نقاط با رنگ‌های تیره‌تر در نواحی با σ_1 و σ_2 بالاتر نشان می‌دهد که فشار محصورکننده نقش مؤثری در افزایش مقاومت فشاری و تغییر رفتار سنگ به سمت شکل‌پذیری بیشتر ایفا می‌کند. نظم فضایی داده‌ها و گرادیان یکنواخت رنگ‌ها، بیانگر پایداری مکانیکی و قابلیت پیش‌بینی مناسب رفتار شکست تراکیت میزوهو تحت شرایط تنش سه‌محوری واقعی است.



شکل ۳. نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های سنگ تراکیت میزوهو


شکل (۴) توزیع نتایج آزمایش‌های سه‌محوری واقعی انجام‌شده بر روی نمونه‌های آمفیبولیت KTB را به‌صورت نمودار پراکندگی σ_1 در مقابل σ_2 با نمایش رنگی σ_3 نشان می‌دهد. نتایج حاکی از وجود رابطه‌ای مثبت و غیرخطی میان تنش میانی و مقاومت شکست است، به‌گونه‌ای که افزایش σ_2 به افزایش فزاینده σ_1 منجر می‌شود. نقاط با مقادیر بالاتر σ_3 عمدتاً در نواحی با σ_1 و σ_2 بزرگ‌تر متمرکز شده‌اند که بیانگر اثر تقویت‌کننده فشار همه‌جانبه و افزایش ظرفیت تحمل تنش میانی در این سنگ دگرگونی است. یکنواختی پراکندگی داده‌ها، پاسخ مکانیکی پایدار و رفتار قابل‌اعتماد آمفیبولیت KTB را در دامنه وسیعی از شرایط تنش تأیید می‌کند.

مدل و نبود سوگیری سیستماتیک در پیش‌بینی مقاومت شکست برای انواع مختلف سنگ‌ها است.

۲-۳. ارزیابی عملکرد مدل یادگیری عمیق برای هر سنگ

عملکرد مدل یادگیری عمیق در پیش‌بینی تنش اصلی بیشینه (σ_1) برای سنگ‌های ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت KTB، گرانیت و دولومیت دونهام ارزیابی شده و مقادیر واقعی با مقادیر پیش‌بینی شده توسط مدل مقایسه شده‌اند. نمودارهای پراکندگی واقعی در مقابل پیش‌بینی شده، دقت و توانایی مدل در بازسازی رفتار مکانیکی سنگ‌ها را نشان می‌دهند و امکان شناسایی نقاط با انحراف بیشتر را فراهم می‌کنند.

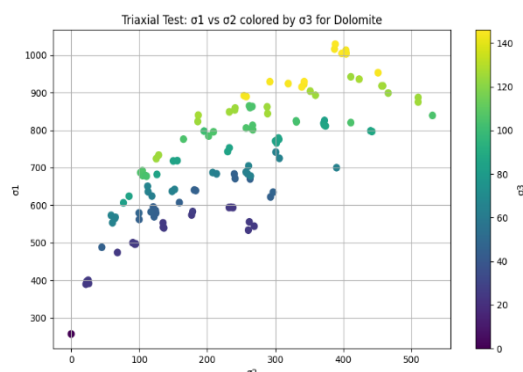
برای ماسه‌سنگ، تمرکز نقاط داده در مجاورت خط برابری، دقت بالای مدل را نشان می‌دهد. میانگین خطای مطلق (۱۲/۶۷) و میانگین مربعات خطا (۲۵۰/۹۶) پایین و ضریب تعیین (۰/۹۰۷) بیش از ۹۰٪ تغییرات σ_1 را تبیین می‌کند. نتایج بیانگر توانایی مدل در بازتولید رفتار مکانیکی یکنواخت این سنگ هستند (شکل ۷، جدول ۳).



شکل ۷. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای سنگ ماسه سنگ

در تراکیت میزوهو، با وجود دامنه وسیع‌تر تنش‌ها، مدل عملکرد مطلوبی ارائه داده است. مقادیر میانگین خطای مطلق ۱۴/۵۱، میانگین مربعات خطا ۳۵۳/۸۲ همراه با ضریب تعیین بالا (۰/۹۶۱) نشان می‌دهند که مدل روابط غیرخطی بین مؤلفه‌های تنش را به خوبی بازنمایی می‌کند (شکل ۸، جدول ۳).

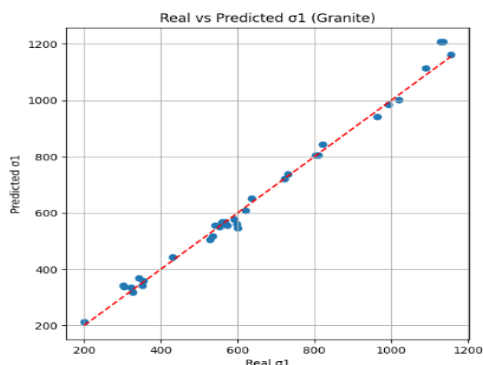
شکل (۶) نتایج آزمایش‌های سه‌محوری واقعی انجام شده بر روی نمونه‌های دولومیت دونهام را به صورت نمودار پراکندگی σ_1 بر حسب σ_2 با نمایش رنگی σ_3 نشان می‌دهد. توزیع نقاط حاکی از وجود رابطه‌ای مثبت و غیرخطی میان تنش میانی و مقاومت شکست است، به گونه‌ای که افزایش σ_2 با افزایش σ_1 همراه می‌باشد. رنگ‌های گرم‌تر که معرف مقادیر بالاتر σ_3 هستند، عمدتاً در نواحی با σ_1 و σ_2 بزرگ‌تر مشاهده می‌شوند که نقش تقویت‌کننده فشار همه‌جانبه در افزایش ظرفیت باربری دولومیت دونهام را تأیید می‌کند. پیوستگی گرادیان رنگ و یکنواختی توزیع نقاط، نشان‌دهنده پاسخ مکانیکی پایدار و رفتار شکست قابل پیش‌بینی این سنگ تحت شرایط تنش سه‌محوری واقعی است.



شکل ۶. نتایج آزمایش‌های سه‌محوری واقعی انجام شده بر روی نمونه‌های سنگ دولومیت دونهام

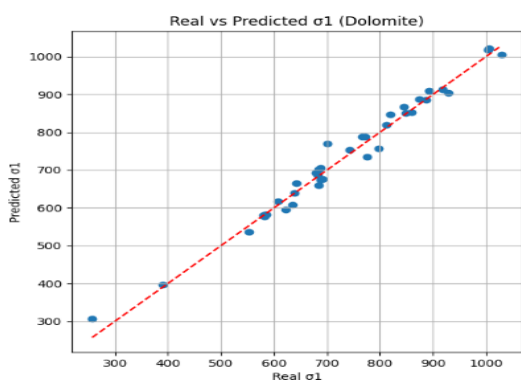
بررسی تطبیقی نتایج آزمایش‌های سه‌محوری واقعی و خروجی‌های مدل یادگیری عمیق برای تمامی سنگ‌ها نشان می‌دهد که با وجود تفاوت در دامنه مقاومت شکست و رفتار مکانیکی، اثر تنش اصلی میانی (σ_2) بر تنش اصلی بیشینه (σ_1) در همه آن‌ها به صورت منسجم قابل مشاهده است. نمودارهای آزمایشگاهی بیانگر افزایش σ_1 با افزایش σ_2 در تمامی سنگ‌ها هستند، اگرچه شدت این وابستگی به ویژگی‌های ذاتی هر سنگ بستگی دارد. تطابق مناسب بین مقادیر واقعی و پیش‌بینی شده σ_1 نشان می‌دهد که مدل توانسته است این روند غیرخطی را در مقیاس چندسنگی به خوبی بازنمایی کند. همچنین توزیع تصادفی باقی‌مانده‌ها حول مقدار صفر حاکی از پایداری

σ_1 و بازتولید رفتار مکانیکی پایدار و همگن این سنگ است (شکل ۱۰، جدول ۳).



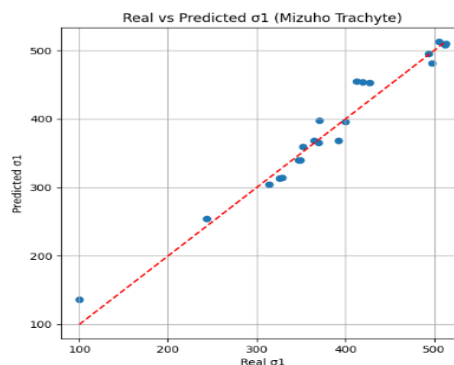
شکل ۱۰. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای سنگ گرانیت

برای دولومیت دونهام نیز مدل عملکرد مناسبی نشان داد. مقدار میانگین خطای مطلق $17/32$ و میانگین مربعات خطا $505/70$ همراه با ضریب تعیین $0/980$ تأیید می‌کنند که مدل تغییرات σ_1 را با دقت بالا پیش‌بینی کرده و اثر همزمان تنش‌های میانی و کمینه در رفتار مقاومتی این سنگ کربناته لحاظ شده است (شکل ۱۱، جدول ۳).



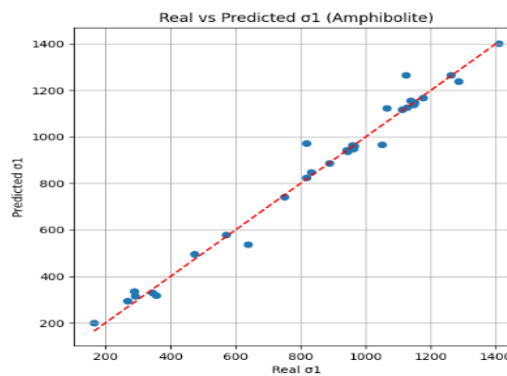
شکل ۱۱. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای سنگ دولومیت دونهام

تحلیل تجمیعی شامل تمام سنگ‌ها نشان می‌دهد که مدل یادگیری عمیق توانایی مناسبی در بازنمایی رفتار کلی مقاومت سنگ‌ها تحت شرایط تنش سه‌محوری واقعی دارد. ضریب تعیین کلی $0/648$ بیانگر آن است که بخش قابل توجهی از تغییرات σ_1 توسط متغیرهای ورودی



شکل ۸. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای سنگ تراکیت میزوهو

برای آمفیبولیت KTB، خطاهای پیش‌بینی افزایش یافته‌اند (میانگین خطای مطلق $29/82$ و میانگین مربعات خطا $2443/26$)، اما ضریب تعیین بسیار بالای مدل ($0/979$) نشان می‌دهد که بخش عمده تغییرات σ_1 توسط مدل تبیین می‌شود. افزایش خطا ناشی از مقاومت بالا و پیچیدگی رفتار مکانیکی این سنگ دگرگونی است، با این حال عملکرد کلی مدل همچنان از دیدگاه مهندسی قابل اعتماد ارزیابی می‌شود (شکل ۹، جدول ۳).



شکل ۹. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای سنگ آمفیبولیت KTB


در گرانیت، مدل بهترین عملکرد خود را نشان داده است. مقدار میانگین خطای مطلق $19/48$ و میانگین مربعات خطا $735/88$ همراه با ضریب تعیین $0/990$ بیانگر توانایی بالای مدل در پیش‌بینی دقیق

۳-۳. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست

برای بررسی دقت و صحت مدل یادگیری عمیق، مقادیر پیش‌بینی شده توسط شبکه عصبی برای تنش اصلی بیشینه (σ_1) با داده‌های آزمایش سه‌محوری واقعی مقایسه شدند. تحلیل شامل دو جنبه بود، اول مقایسه بصری مقادیر واقعی و پیش‌بینی شده در قالب نمودارهای تطبیقی و دوم مقایسه عددی با استفاده از جداول شامل مقادیر آزمایشگاهی و پیش‌بینی مدل.

۳-۳-۱. سنگ ماسه سنگ

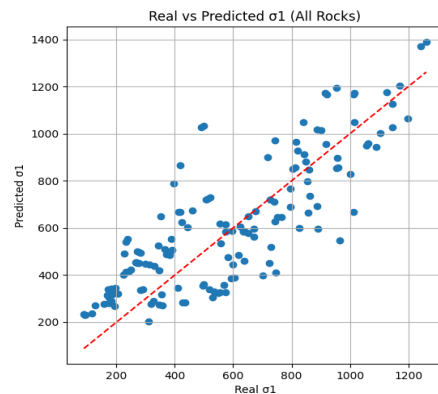
نمودار تطبیقی مقادیر واقعی و پیش‌بینی شده σ_1 برای نمونه‌های ماسه‌سنگ در شکل (۱۳) ارائه شده است. پیش‌بینی شده توسط مدل با داده‌های واقعی هم‌پوشانی قابل توجهی دارند و اختلاف‌ها اندک هستند. بیش‌ترین اختلاف جزئی در نمونه‌های ۳ و ۱۲ مشاهده شد که ناشی از ناهمگنی ذاتی سنگ یا پراکندگی طبیعی داده‌هاست.



شکل ۱۳. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست (σ_1) برای سنگ ماسه‌سنگ

مقایسه عددی این سنگ در جدول (۴) نشان می‌دهد که مدل پیش‌بینی‌های مناسبی ارائه داده و روند تغییرات σ_1 را نسبت به σ_2 و σ_3 به خوبی بازتولید کرده است. این تحلیل همخوانی بصری و عددی مدل را تأیید می‌کند و نشان می‌دهد که شبکه عصبی قادر است رفتار مکانیکی یکنواخت ماسه‌سنگ را با دقت قابل اعتماد شبیه‌سازی کند.

شامل σ_2 ، σ_3 و نوع سنگ تبیین می‌شود. کاهش دقت نسبت به مدل‌های مجزای هر سنگ طبیعی است و ناشی از تنوع ذاتی رفتار مکانیکی و دامنه مقاومتی متفاوت بین سنگ‌هاست، با این حال روند کلی تغییرات مقاومت به خوبی بازتولید شده و مدل یک برآورد عمومی قابل اعتماد برای کاربردهای مهندسی ارائه می‌دهد (شکل ۱۲، جدول ۳).



شکل ۱۲. نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده تنش اصلی بیشینه (σ_1) برای تمام سنگ‌ها

به‌طور کلی، مقایسه مقادیر واقعی و پیش‌بینی شده σ_1 نشان می‌دهد که مدل یادگیری عمیق هم برای سنگ‌های منفرد با رفتار مکانیکی یکنواخت و مقاومتی متفاوت دقت بالا دارد و هم قادر است رفتار کلی مجموعه‌ای از سنگ‌ها را تحت شرایط تنش سه‌محوری واقعی پیش‌بینی کند. این نتایج تأیید می‌کنند که مدل توسعه‌یافته یک ابزار معتبر و کاربردی برای تحلیل و شبیه‌سازی رفتار مکانیکی سنگ‌ها در مهندسی ژئوتکنیک و معدن است.

جدول ۳. نتایج ارزیابی عملکرد مدل

نوع سنگ	MSE	MAE	R^2
ماسه سنگ	۲۵۰/۹۶	۱۲/۶۷	۰/۹۰۷
تراکیت‌میزوهو	۳۵۳/۸۲	۱۴/۵۱	۰/۹۶۱
آمفیبولیت KTB	۲۴۴۳/۲۶	۲۹/۸۲	۰/۹۷۹
گرانیت	۷۳۵/۸۸	۱۹/۴۸	۰/۹۹۵
دولومیت‌دونهام	۵۰۵/۷۰	۱۷/۳۲	۰/۹۸
کلیه سنگ‌ها	۳۱۴۶۳/۵۴	۱۴۵/۸۶	۰/۶۵۲

بیانگر عملکرد پایدار و قابل اعتماد مدل در پیش‌بینی مقاومت فشاری تراکیت میزوهو هستند.

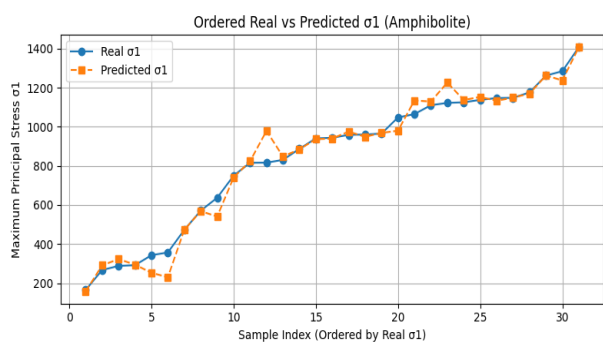
جدول ۵. مقایسه تنش اصلی بیشینه (σ_1) واقعی و پیش‌بینی شده در سنگ

تراکیت میزوهو

تنش اصلی حداقل	تنش اصلی میانی	تنش اصلی حداکثر آزمایش	تنش اصلی حداکثر شبکه عصبی مصنوعی
۱۵	۱۵	۱۹۳	۱۹۴
۳۰	۳۰	۲۵۳	۲۵۰
۴۵	۵۵	۳۱۴	۳۰۵
۴۵	۹۶	۳۳۳	۳۲۷
۴۵	۳۳۲	۳۵۱	۳۶۷
۶۰	۶۰	۳۳۹	۳۳۹
۶۰	۱۹۱	۳۹۶	۳۳۷
۶۰	۲۲۹	۴۰۴	۴۰۳
۷۵	۷۵	۳۶۵	۳۸۲

۳-۳-۳. سنگ آمفیبولیت KTB

نمودار مقایسه‌ای برای آمفیبولیت KTB در شکل (۱۵) ارائه شده است. با توجه به مقاومت بالای این سنگ، خطوط مربوط به مقادیر پیش‌بینی شده و واقعی تقریباً بر یکدیگر منطبق هستند.



شکل ۱۵. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست (σ_1) برای سنگ

آمفیبولیت KTB

مقایسه عددی در جدول (۶) نشان می‌دهد که مدل توانسته است بخش عمده تغییرات σ_1 را پیش‌بینی کند، هرچند در نمونه‌هایی با مقاومت بسیار بالا، اختلاف نسبی کمی مشاهده می‌شود. این تحلیل

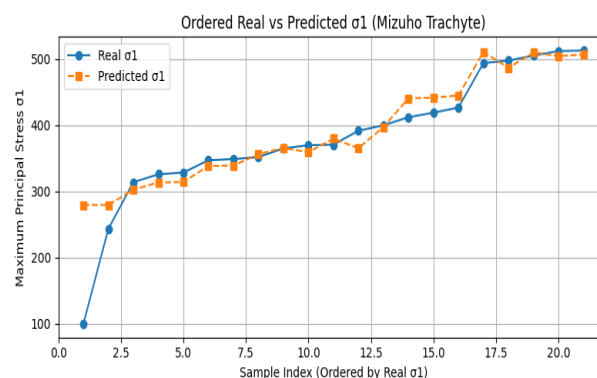
جدول ۴. مقایسه تنش اصلی بیشینه (σ_1) واقعی و پیش‌بینی شده در سنگ ماسه

سنگ

تنش اصلی حداقل	تنش اصلی میانی	تنش اصلی حداکثر آزمایش	تنش اصلی حداکثر شبکه عصبی مصنوعی
۵	۴۴	۱۰۹	۱۱۷
۸	۴۱	۱۳۲	۱۲۸
۸	۵۰	۱۳۵	۱۲۹
۸	۷۹	۱۲۷	۱۳۹
۱۵	۶۲	۱۶۵	۱۵۹
۱۵	۹۷	۱۶۸	۱۶۵
۲۰	۵۰	۱۸۵	۱۸۴
۲۰	۶۸	۱۹۷	۱۸۷
۴۰	۶۰	۲۴۴	۲۴۵

۲-۳-۳. سنگ تراکیت میزوهو

برای تراکیت میزوهو، نمودار تطبیقی در شکل (۱۴) نشان می‌دهد که پیش‌بینی‌های مدل با مقادیر واقعی تطابق خوبی دارند. نقاط داده حول خط واقعی متمرکز هستند و اختلاف‌ها اندک است، هرچند در نمونه‌های ۲ و ۱۴ اختلاف جزئی مشاهده شد.



شکل ۱۴. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست (σ_1) برای سنگ

تراکیت میزوهو

مقادیر عددی در جدول (۵) نشان می‌دهد که مدل توانسته روند تغییرات σ_1 را با توجه به σ_2 و σ_3 به خوبی دنبال کند. این نتایج


جدول عددی مربوط به این سنگ (جدول ۷) تأیید می‌کند که مدل توانسته روند تغییرات σ_1 را با دقت بسیار بالا شبیه‌سازی کند و رفتار مکانیکی پایدار و همگن گرانیث را بازتولید نماید.

جدول ۷. مقایسه تنش اصلی بیشینه (σ_1) واقعی و پیش‌بینی شده در سنگ گرانیث

تنش اصلی حداقل	تنش اصلی میانی	تنش اصلی حداکثر آزمایش	تنش اصلی حداکثر شبکه عصبی مصنوعی
۰	۰	۲۰۱	۲۳۴
۰	۸۰	۳۱۷	۳۲۶
۲	۴۰	۳۲۸	۳۵۳
۲	۱۰۰	۳۵۵	۳۷۳
۲۰	۲۰	۴۳۰	۴۶۵
۲۰	۶۰	۵۵۴	۵۸۹
۳۸	۳۸	۶۲۰	۶۱۹
۶۰	۹۰	۸۱۱	۸۰۶
۶۰	۱۱۴	۸۲۱	۸۲۷

۳-۳-۵. سنگ دولومیت دونهام

برای دولومیت دونهام، نمودار تطبیقی در شکل (۱۷) ارائه شده است. نقاط پیش‌بینی شده با داده‌های واقعی هم‌پوشانی قابل توجهی دارند و اختلاف‌ها تنها در نمونه‌هایی با تنش بالاتر مشاهده شد.



شکل ۱۷. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست (σ_1) برای سنگ دولومیت دونهام


تأیید می‌کند که شبکه عصبی توسعه‌یافته قادر به شبیه‌سازی رفتار مکانیکی پیچیده و مقاوم این سنگ دگرگونی است.

جدول ۶. مقایسه تنش اصلی بیشینه (σ_1) واقعی و پیش‌بینی شده در سنگ آمفیبولیت KTB

تنش اصلی حداقل	تنش اصلی میانی	تنش اصلی حداکثر آزمایش	تنش اصلی حداکثر شبکه عصبی مصنوعی
۰	۱۴۹	۲۹۱	۳۰۴
۳۰	۲۹۸	۶۳۷	۶۴۴
۶۰	۶۰	۷۰۲	۶۹۶
۶۰	۲۹۹	۸۲۸	۸۲۷
۶۰	۱۹۹	۸۱۶	۸۳۵
۶۰	۳۴۷	۸۸۷	۹۱۹
۶۰	۱۵۵	۷۴۵	۷۹۶
۱۰۰	۲۴۸	۹۴۵	۹۴۴
۱۰۰	۲۶۹	۸۹۲	۸۹۵

۳-۳-۴. سنگ گرانیث

در سنگ گرانیث، نمودار تطبیقی در شکل (۱۶) نشان‌دهنده تطابق نزدیک مقادیر پیش‌بینی شده با داده‌های واقعی است. حتی در نمونه‌هایی با مقاومت بالا، اختلاف‌ها اندک و قابل قبول هستند.



شکل ۱۶. مقایسه مقادیر واقعی و پیش‌بینی شده مقاومت شکست (σ_1) برای سنگ گرانیث

جدول ۹. میانگین درصد تاثیر تنش میانی بر σ_1 با برای ماسه سنگ

σ_3	آزمایش‌های انجام شده با $\sigma_2 = \sigma_3$	آزمایش‌های انجام شده با $\sigma_2 \neq \sigma_3$	میانگین درصد تاثیر تنش میانی بر σ_1
۱۵	۱	۵	٪۱۰/۳۴
۲۰	۱	۸	٪۳/۹۹
۳۰	۱	۷	٪۱۵
۴۰	۱	۸	٪۱۷/۹۶

در تراکیت میزوهو (جدول ۱۰)، میانگین با افزایش σ_3 از ۴۵ به ۱۰۰ کیلوپاسکال، روندی ملایم اما صعودی دارد. این مقدار از ٪۱۸/۷ ($\sigma_3=45$) به ٪۲۰/۱ ($\sigma_3=100$) می‌رسد. پراکندگی کم این اعداد (حدود ۱۸ تا ۲۰٪) حاکی از آن است که در این سنگ، تأثیر σ_2 بر افزایش مقدار σ_1 مشاهده می‌شود.

جدول ۱۰. میانگین درصد تاثیر تنش میانی بر σ_1 برای تراکیت میزوهو

σ_3	آزمایش‌های انجام شده با $\sigma_2 = \sigma_3$	آزمایش‌های انجام شده با $\sigma_2 \neq \sigma_3$	میانگین درصد تاثیر تنش میانی بر σ_1
۴۵	۱	۷	٪۱۸/۷
۶۰	۱	۶	٪۱۸/۸
۷۵	۱	۶	٪۱۹/۵
۱۰۰	۱	۵	٪۲۰/۱

این در آمفیبولیت KTB (جدول ۱۱)، رفتار متفاوت‌تری مشاهده می‌شود. در $\sigma_3=30$ کیلوپاسکال، میانگین تأثیر به حداکثر مقدار ٪۴۳/۳ می‌رسد که نشان‌دهنده حساسیت زیاد این سنگ به تنش میانی در محدوده تنش‌های پایین است. با افزایش σ_3 به ۱۵۰ کیلوپاسکال تأثیر تنش میانی به ٪۷/۳ می‌رسد.

جدول عددی این سنگ (جدول ۸) نشان می‌دهد که مدل توانسته اثر هم‌زمان تنش‌های میانی و کمینه را در مقاومت فشاری این سنگ کربناته لحاظ کند و تغییرات σ_1 را به دقت پیش‌بینی نماید.

جدول ۸. مقایسه تنش اصلی بیشینه (σ_1) واقعی و پیش‌بینی‌شده در سنگ

دولومیت دونهام

تنش اصلی حدافل	تنش اصلی میانی	تنش اصلی حداکثر آزمایش	تنش اصلی حداکثر شبکه عصبی مصنوعی
۰	۰	۲۵۷	۳۱۹
۲۵	۹۱	۵۰۰	۴۸۰
۴۵	۴۵	۴۸۸	۴۸۹
۶۵	۶۵	۵۶۸	۵۶۷
۸۵	۲۳۰	۷۴۳	۷۵۰
۴۵	۱۸۳	۶۳۹	۶۴۳
۶۵	۱۱۳	۶۳۶	۶۲۲
۶۵	۲۰۸	۶۸۷	۷۱۶
۱۰۵	۱۰۵	۶۷۹	۶۷۵

۳-۴. تأثیر تنش میانی بر σ_1 در سنگ‌های مختلف

به منظور کمی‌سازی تأثیر تنش میانی (σ_2) بر تنش بیشینه در شرایط تنش حقیقی ($\sigma_2 \neq \sigma_3$)، میانگین درصد افزایش σ_1 نسبت به حالت متعارف $\sigma_2 = \sigma_3$ برای هر سطح از تنش محصورکننده σ_3 محاسبه گردید. نتایج این محاسبات برای پنج نوع سنگ شامل ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت KTB، گرانیت و دولومیت دونهام در جداول ۹ تا ۱۳ ارائه شده است.

جدول ۹ نتایج مربوط به ماسه‌سنگ را نشان می‌دهد. میانگین تأثیر تنش میانی در $\sigma_3=15$ کیلوپاسکال برابر ٪۱۰/۳۴ است. با افزایش σ_3 به ۲۰ کیلوپاسکال، این مقدار به ٪۳/۹۹ کاهش می‌یابد. در $\sigma_3=40$ کیلوپاسکال به ٪۱۷/۹۶ افزایش می‌یابد.

بنابراین در ماسه‌سنگ، حداکثر تأثیر σ_2 در $\sigma_3=40$ کیلوپاسکال مشاهده می‌شود. هرچند مقادیر مطلق تأثیر نسبت به سنگ‌های دیگر کمتر است (حداکثر حدود ٪۱۸)، اما وجود این تأثیر ممکن است ناشی از جنس و ساختار سنگ باشد.

جدول ۱۳. میانگین درصد تاثیر تنش میانی بر σ_1 با برای دولومیت دونهام

σ_3	آزمایش‌های انجام شده با $\sigma_2 = \sigma_3$	آزمایش‌های انجام شده با $\sigma_2 \neq \sigma_3$	میانگین درصد تاثیر تنش میانی بر σ_1
۲۵	۱	۶	٪۳۵
۴۵	۱	۷	٪۲۷/۵
۶۵	۱	۶	٪۱۹/۵
۸۵	۱	۶	٪۲۱/۲
۱۰۵	۱	۷	٪۲۰/۱
۱۲۵	۱	۷	٪۲۲

نتایج این آزمایش‌ها نشان می‌دهد که حداکثر تاثیر تنش میانی در محدوده تنش‌های محصورکننده کمتر از ۳۰ کیلوپاسکال رخ می‌دهد و می‌تواند تا بیش از ۵۰٪ افزایش مقاومت را موجب شود.

۴. نتیجه‌گیری

در این مقاله، رفتار مقاومت شکست سنگ‌ها تحت شرایط تنش سه‌محوری واقعی با تمرکز ویژه بر نقش تنش اصلی میانی (σ_2) مورد بررسی قرار گرفت و یک مدل مبتنی بر یادگیری عمیق برای پیش‌بینی تنش اصلی بیشینه (σ_1) توسعه داده شد. با بررسی‌های انجام شده در این مقاله، نتایج زیر قابل استنباط است:

(۱) در تمامی سنگ‌های مورد مطالعه شامل ماسه‌سنگ، تراکیت میزوهو، آمفیبولیت KTB، گرانیت و دولومیت دونهام، رابطه‌ای غیرخطی میان σ_1 و σ_2 وجود دارد. این یافته به‌طور روشن بیانگر آن است که تنش میانی نقش مؤثری در افزایش مقاومت شکست سنگ‌ها ایفا می‌کند و نادیده گرفتن آن می‌تواند منجر به برآورد غیرواقعی مقاومت سنگ گردد.

(۲) تحلیل نتایج آزمایشگاهی همچنین نشان می‌دهند که افزایش تنش اصلی کمینه (σ_3) از طریق اعمال فشار محصورکننده، اثر تقویت‌کننده‌ای بر ظرفیت باربری سنگ‌ها دارد و سبب افزایش شکل‌پذیری سنگ می‌شود. با وجود تفاوت‌های ذاتی در بافت، منشأ زمین‌شناسی و دامنه مقاومتی سنگ‌ها، الگوی کلی تاثیر

جدول ۱۱. میانگین درصد تاثیر تنش میانی بر σ_1 با برای آمفیبولیت KTB

σ_3	آزمایش‌های انجام شده با $\sigma_2 = \sigma_3$	آزمایش‌های انجام شده با $\sigma_2 \neq \sigma_3$	میانگین درصد تاثیر تنش میانی بر σ_1
۳۰	۱	۵	٪۴۳/۳
۷۵	۱	۹	٪۱۷/۹
۱۰۰	۱	۸	٪۱۷/۷
۱۵۰	۱	۹	٪۷/۳

جدول ۱۲ نتایج مربوط به گرانیت را نشان می‌دهد. میانگین تاثیر تنش میانی در $\sigma_3=2$ کیلوپاسکال برابر ۴۶/۸٪ است. در $\sigma_3=20$ و ۳۸ کیلوپاسکال به ترتیب به ۳۳/۱٪ و ۱۸/۳٪ می‌رسد و سپس در محدوده $\sigma_3=60$ تا ۱۰۰ کیلوپاسکال در حدود ۱۱٪ تا ۱۳٪ تثبیت می‌شود.

جدول ۱۲. میانگین درصد تاثیر تنش میانی بر σ_1 با برای گرانیت

σ_3	آزمایش‌های انجام شده با $\sigma_2 = \sigma_3$	آزمایش‌های انجام شده با $\sigma_2 \neq \sigma_3$	میانگین درصد تاثیر تنش میانی بر σ_1
۲	۱	۵	٪۴۶/۸
۲۰	۱	۹	٪۳۳/۱
۳۸	۱	۷	٪۱۸/۳
۶۰	۱	۴	٪۱۲/۲
۷۷	۱	۴	٪۱۱/۱
۱۰۰	۱	۵	٪۱۳/۲

در دولومیت دونهام (جدول ۱۳)، داده‌ها نشان می‌دهد که میانگین تاثیر تنش میانی در $\sigma_3=25$ کیلوپاسکال برابر ۳۵٪ بوده و سپس با افزایش σ_3 روند کاهشی ملایمی دارد. وجود نوسان‌هایی بین ۱۹ تا ۲۲٪ در تنش‌های بالاتر از ۶۵ کیلوپاسکال ممکن است ناشی از پراکندگی ذاتی داده‌ها یا ناهمگنی نمونه‌ها باشد.

- engineering practice," in Proc. Int. Symp. on Rock Joints, Loen, Norway, 1990, pp. 603-610.
- [6] F. D. Patton, "Multiple modes of shear failure in rock," in Proc. 1st Congr. Int. Soc. Rock Mech., Lisbon, Portugal, 1966, vol. 1, pp. 509-513.
- [7] N. R. Barton, "Review of a new shear strength criterion for rock joints," Eng. Geol. Journal, vol. 7, no. 4, pp. 287-332, 1973.
- [8] E. Hoek and E. T. Brown, Underground Excavations in Rock. London, UK: Instn Min. Metall, 1980.
- [9] G. Yin, M. Li, J. G. Wang, J. Xu, and W. Li, "Mechanical behavior and permeability evolution of gas infiltrated coals during protective layer mining," Int. J. Rock Mech. Min. Sci., vol. 80, pp. 292-301, 2015.
- [10] M. Li, G. Yin, J. Xu, W. Li, Z. Song, and C. Jiang, "A novel true triaxial apparatus to study the geomechanical and fluid flow aspects of energy exploitations in geological formations," Rock Mech. Rock Eng., vol. 49, pp. 4647-4659, 2016.
- [11] S. L. Chen and Y. N. Abousleiman, "Wellbore stability analysis using strain hardening and/or softening plasticity models," Int. J. Rock Mech. Min. Sci., vol. 93, pp. 260-268, 2017.
- [12] S. Rukhaiyar and N. K. Samadhiya, "Strength behaviour of sandstone subjected to polyaxial state of stress," Int. J. Min. Sci. Technol., vol. 27, pp. 889-897, 2017.
- [13] S. Rukhaiyar, G. Sajwan, and N. K. Samadhiya, "Strength behavior of plain cement concrete subjected to true triaxial compression," Can. J. Civ. Eng., vol. 45, pp. 179-196, 2018.
- [14] Y. Chen, J. Xu, S. Peng, F. Yan, and C. Fan, "A Gas-Solid-Liquid Coupling Model of Coal Seams and the Optimization of Gas Drainage Boreholes," Energies, vol. 11, p. 560, 2018.
- [15] B. Jiang, S. Gu, L. Wang, G. Zhang, and W. Li, "Strain burst process of marble in tunnel-excavation-induced stress path considering intermediate principal stress," J. Rock Mech. Geotech. Eng., 2019.
- [16] H. Gao, D. Zhang, J. Lu, G. Yin, and M. Wu, "Experimental study on influence of intermediate principal stress on the permeability of sandstone," Rock Mech. Rock Eng., 2020.
- [17] Z. Wang and Q. Liu, "Failure criterion for soft rocks considering intermediate principal stress," Int. J. Rock Mech. Min. Sci., 2021.
- هم‌زمان σ_1 و σ_2 بر σ_3 در همه نمونه‌ها مشاهده شد که بیانگر وجود یک روند مکانیکی منسجم تحت شرایط تنش سه‌محوری واقعی است.
- (۳) مدل یادگیری عمیق توسعه‌یافته می‌تواند این روابط پیچیده و غیرخطی مقاومت شکست سنگ بر اساس تنش‌های همه‌جانبه آزمایش سه‌محوری را با دقت بالا بازنمایی کند. ارزیابی عملکرد مدل برای هر سنگ به صورت جداگانه نشان داد که مقادیر پیش‌بینی شده σ_1 تطابق مناسبی با داده‌های آزمایشگاهی دارد و R^2 بالا، دقت و پایداری مدل را تأیید می‌کنند. اگرچه در سنگ‌های با مقاومت بالا و رفتار مکانیکی پیچیده‌تر مانند آمفیبولیت KTB میزان خطا افزایش نسبی داشت، اما مدل یادگیری عمیق توسعه‌یافته با تقریب قابل قبولی تغییرات σ_1 را به درستی پیش‌بینی نمود.
- (۴) تحلیل تنش میانی (σ_2) تأثیر قابل توجهی بر مقاومت بیشینه (σ_1) نوع سنگ مورد بررسی دارد، ولی این تأثیر به سطح تنش کمینه (σ_3) و نوع سنگ وابسته است. بیشترین تأثیر در σ_3 کمتر از ۳۰ کیلوپاسکال مشاهده می‌شود.

منابع

- [1] H. Yu, A. D. T. Faras Al Balushi, and H. Wang, "Machine learning for rock mechanics problems; an insight," Frontiers, vol. 17, 2022.
- [2] Z. Zheng, R. L. Pengzhi Pan, J. Qi, G. Su, and H. Zheng, "Shear failure behaviors and degradation mechanical model of rock mass under true triaxial multi-level loading and unloading shear tests," Elsevier, vol. 24, 2024.
- [3] H. Xie, J. L. Cunbao Li, M. Li, and M. Gao, "Experimental study on the mechanical and failure behaviors of deep rock subjected to true triaxial stress: A review," Elsevier, 2022.
- [4] H. Li, L. P. Zhenjiang You, and D. Smeulders, "Stress-dependent instantaneous cohesion and friction angle for the Mohr-Coulomb criterion," Elsevier, vol. 16, 2024.
- [5] N. R. Barton and S. C. Bandis, "Review of predictive capabilities of JRC-JCS model in

- [18] W. You, F. Dai, Y. Liu, H. Du, and R. Jiang, "Investigation of the influence of intermediate principal stress on the dynamic responses of rocks subjected to true triaxial stress state," *Rock Mech. Rock Eng.*, 2021.
- [19] F. Wang, X. T. Feng, Y. Zhou, and X. Yu, "Experimental study on failure evolution mechanism of clastic rock considering cementation and intermediate principal stress," *Rock Mech. Rock Eng.*, 2022.
- [۲۰] م. مطهری و س. اداوی، «مقایسه عملکرد شبکه عصبی مصنوعی و رگرسیون خطی در مدل‌سازی و پیش‌بینی تنش میانی شکست سنگ»، پایان‌نامه کارشناسی ارشد، دانشگاه اراک، اراک، ایران، ۱۴۰۱.
- [21] Y. Sun, F. Fei, L. N. Y. Wong, and J. Choo, "Intermediate principal stress effects on the 3D cracking behavior of flawed rocks under true triaxial compression," *J. Geophys. Res. Solid Earth*, 2024.
- [22] F. Feng, Z. Xie, S. Chen, D. Li, S. Peng, and T. Zhang, "True triaxial unloading test on the mechanical behaviors of sandstone: Effects of the intermediate principal stress and structural plane," *Rock Mech. Rock Eng.*, 2024.
- [23] Z. Wu, Y. Zheng, B. Deng, and S. Deng, "Influence of intermediate principal stress on rock strength: insights from closed crack evolution under true triaxial compression," *Int. J. Rock Mech. Min. Sci.*, 2025.
- [۲۴] سیاه منصور، اصغر و جلالی‌فر، حسین، «پیش‌بینی مکانیزم گسیختگی سنگ در شرایط سه بعدی بالا با استفاده از روش‌های تجربی و رگرسیون خطی»، روش‌های تحلیلی و عددی در مهندسی معدن، شماره ۲۲، بهار ۱۳۹۹، صفحه ۴۹-۵۸.