

نشریهی مهندسی تونل و فضاهای زیرزمینی

Tunneling & Underground Space Engineering (TUSE)

دورهی ۱۲– شمارهی ۱/بهار ۱۴۰٬۹

# استفاده از رگرسیون آماری و شبکه عصبی مصنوعی برای تعیین ارتفاع منطقه رها از تنش در سقف پهنه جبههکار طولانی

# مقاله پژوهشی

محمد رضائی"\*؛ هادی حائری<sup>۲</sup>؛ وهاب سرفرازی<sup>۳</sup>

n.rezaei@uok.ac.ir - دانشیار؛ دانشکدهی مهندسی، گروه مهندسی معدن، دانشگاه کردستان، haerihadi@gmail.com ۲- استادیار؛ بخش مهندسی معدن، مجتمع آموزش عالی زرند، دانشگاه شهید باهنر کرمان، haerihadi ۳- دانشیار؛ گروه مهندسی معدن، دانشگاه صنعتی همدان، vahab.sarfarazi@gmail.com

دریافت دستنوشته: ۱۴۰۳/۰۷/۱۳؛ پذیرش دستنوشته: ۱۴۰۳/۱۲/۰۸

شماره صفحات: ۳۳ تا ۴۸

شناسه ديجيتال (DOI): 10.22044/tuse.2025.15173.1491)

چکیدہ	واژگان کلیدی
ارتفاع منطقه رها از تنش (HDZ) در سقف پهنه جبههکار طولانی پارامتر مهمی در تعیین میزان تنش ناشی از استخراج پهنه و بارهای انتقالی به اطراف آن است. لذا تخمین دقیق HDZ بهمنظور تحلیل تنش در اطراف	معدنکاری جبههکار طولانی منطقه رها از تنش رگرسیون آماری
پهنه، طراحی ایمن سیستم نگهداری ورودیها و پیشبینی نشست سطح زمین، ضروری میباشد. بهمنظور تعیین HDZ در این تحقیق، از دو مدل رگرسیون آماری و شبکه عصبی مصنوعی استفاده و نتایج حاصله با همدیگر و با دادههای واقعی مقایسه شد. برای طراحی و ارزیابی مدلها، از ۱۲۰ سری داده مستخرج از منابع	د رو بیری شبکه عصبی مصنوعی تحلیل اهمیت متغیر

معتبر استفاده گردید. پارامترهای ارتفاع روباره، ضخامت لایه زغال سنگ استخراجی، وزن مخصوص، مدول الاستیسیته، ضریب پواسون، مقاومت فشاری تک محوری و فاکتور حجمی تودهسنگ سقف بهعنوان متغیرهای ورودی برای پیش بینی HDZ در نظر گرفته شد. در فرآیند ارزیابی مدل ها بر اساس داده های واقعی، مقادیر ضریب تصمیم گیری، میانگین خطای مطلق و میانگین خطای نسبی به ترتیب برای مدل آماری برابر با ۲۲٪/۷۲، ۱۹۶۶ متر و ۲۰/۴۳ و برای شبکه عصبی برابر با ۲۰٪/۹۶، ۲۵۲ متر و ۲۵٪/۷ به دست آمد. نتایج فوق نشان دهنده دقت بیش تر و خطای کم تر شبکه عصبی نسبت به مدل آماری و تطابق بهتر خروجی های آن با داده های واقعی است. تحلیل حساسیت نتایج مدل آماری نشان داد که وزن مخصوص و ضریب پواسون توده سنگ به ترتیب با مقدار ضریب استاندارد شدهٔ ۲۰۱۴ و ۲۰/۰ بیش ترین و کمترین تأثیر را بر HDZ دارند. در نهایت، تحلیل اهمیت متغیر نتایج شبکه عصبی نشان داد که ارتفاع روباره و ضریب پواسون به ترتیب با میزان اهمیت ۹۹/۰۰ و ۲۸۹۲۰ دارای بیش ترین و کم ترین تأثیر بر HDZ هستند.

#### ۱– مقدمه

معدنکاری جبهه کار طولانی یکی از رایجترین روشهای مورد استفاده برای استخراج زیرزمینی زغالسنگ است. مقطع عرضی روش معدنکاری جبهه کار طولانی همراه با تونلهای دسترسی و پایههای حایل آن در **شکل ۱،** نشان داده شده

است. استخراج لایه زغالسنگ در یک پهنه با طول و عرض زیاد در این روش باعث حرکت رو به پایین لایههای سقف پهنه استخراجی میشود. بنابراین، این لایهها شکسته شده و در فضای خالی پشت جبهه کار تخریب میشوند. با گذشت زمان، حرکت رو به پایین لایههای سقف به تدریج بهسمت

\* سنندج؛ بلوار پاسداران؛ دانشگاه کردستان؛ دانشکدهی مهندسی، دانشکده مهندسی معدن؛ کدپستی: ۶۶۱۷۷۱۵۱۷۵؛ شمارمی تلفن: ۳۳۶۶۶۶۰-۸۰۷

بالا گسترش می یابد که باعث تغییر شکل، شکست و تخریب بیشتر لایههای آسیب دیده در سقف پهنه می شود. رفتار لایههای سقف پهنه و فرآیند حرکت تدریجی به سمت پایین یکی از مسائل مهم و چالشی در روش جبهه کار طولانی است که توسط محققین مختلف مورد بررسی قرار گرفته است *یکی از مسائل مهم و چالشی در روش جبهه کار طولانی است که توسط محققین مختلف مورد بررسی قرار گرفته است <i>یکی از مسائل مهم و چالشی در روش جبهه کار طولانی است که توسط محققین مختلف مورد بررسی قرار گرفته است <i>یکی از مسائل مهم و چالشی در روش جبهه کار طولانی است Zhang et al., 2013; Shun et al., 2013; Gao et al., 2014; <i>Rezaei et al., 2015; Rezaei, 2018; Mohammadi et al., 2024; Rezaei et al., 2024; Xu Aghababaei, et al., 2024; Rezaei et al., 2024; Xu* شامل مناطق تخریب، شکست و تغییر شکل در سقف پهنه استخراجی تشکیل می شود که به صورت شماتیک در **شکل** *T*. نشان داده شده است.



شکل ۱- مقطع عرضی پهنه استخراجی، تونلهای دسترسی و لنگههای مجاور در روش جبههکار طولانی



در سقف پهنه استخراجی (Mondal, et al., 2020)

نتایج تحقیقات گذشته نشان میدهد که مناطق تخریب و شکست در سقف پهنه استخراجی رها از تنش شده و باعث ایجاد یک منطقه رها از تنش در سقف پهنه میشوند که فشار وارد بر آن به جلو و اطراف جبهه کار منتقل میشود. در این تحقیق، ارتفاع منطقه رها از تنش

(HDZ) بهعنوان معادل ارتفاع ترکیبی مناطق تخریب و شکست در نظر گرفته میشود که به صورت شماتیک در شکل ۳، نشان داده شده است. میزان HDZ نقش مهمی در تعیین دقیق میزان بارهای منتقل شده به جلو جبههکار و اطراف پهنه ایفا میکند. فراتر از ارتفاع منطقه رها از تنش، فشار روباره بهسمت جلو جبههکار، دیوارههای جانبی پهنه، فشار روباره به سمت جلو جبههکار، دیوارههای جانبی پهنه، قونلهای دسترسی مجاور و پایههای حایل انتقال پیدا میکند. بنابراین، برای تعیین مقدار تنش انتقالی از جبههکار طولانی به تونلهای دسترسی و پایههای حایل به منظور طراحی ایمن آنها در طول عملیات معدنکاری، تعیین دقیق HDZ در سقف پهنه جبههکار طولانی ضروری است (Rezaei et al., 2011; Rezaei 2018).



استفاده از یک روش مناسب برای ارزیابی رفتار لایههای سنگ سقف دغدغه اصلی بسیاری از محققین و طراحان استخراج زيرزميني معادن زغالسنگ است. بنابراين، با توجه به اهمیت رفتار لایههای سقف پهنه استخراجی در معدنکاری جبهه کار طولانی و ضرورت تعیین دقیق HDZ در سقف پهنه بهمنظور محاسبه تنشهای انتقالی به اطراف، این مسئله توسط محققين مختلف مورد مطالعه قرار گرفته است Palchik, 2003; Majdi et al., 2012; Wnbing et al., ) 2012; Shabanimashcool & Charlie, 2012; Majdi Rezaei, 2013). نتايج حاصل از مطالعات قبلي نشان میدهد که میزان HDZ به متغیرهای مختلفی مانند ارتفاع (عمق) روباره، ضخامت لايه زغالسنگ استخراجي، عرض پهنه و خصوصیات مقاومتی، فاکتور حجمی و ضخامت نسبی و تعداد لایههای تودهسنگ سقف بستگی دارد. برای تعیین HDZ در سقف پهنه جبهه کار طولانی، روشهای مختلفی وجود دارد که شامل اندازه گیری های برجا و مدل های ریاضی، تجربی، عددی، هوش مصنوعی و آماری است

Rezaei et al., 2015; Rezaei, 2018; Mondal et al., ) 2020; He et al., 2021; Van Dyke et al., 2002; .(Zhang et al., 2022

بر اساس بررسی پیشینه تحقیق، خلاصه نتایج روشهای برجا، تحلیلی، تجربی، عددی، آماری و هوش مصنوعی برای تعیین HDZ در سقف پهنه استخراجی توسط محققین مختلف بهعنوان ضریبی از ضخامت لایه زغالسنگ استخراجی ( $h_s$ ) در جدول ۱، نشان داده شده است. بررسی نتایج مطالعات قبلی نشان میدهد که هر کدام از مدلهای موجود برای تخمین HDZ دارای ضعفهایی بوده و عملکرد آنها بهدلیل پیچیدگی محیط استخراج معدنکاری جبههکار طولانی تا حدودی رضایت بخش نیست. به عنوان مثال، روشهای تجربی را نمیتوان بهطور دقیق برای همه شرایط و معادن مختلف تعميم داد، زيرا معمولاً بر اساس اطلاعات یک مطالعه موردی با ویژگیهای خاص توسعه یافتهاند. همچنین، مدلهای عددی به تعداد زیادی پارامتر ورودی نیاز دارند که ممکن است نیاز به تقریب یا فرضیات متعدد داشته باشند. با وجود دقت بالا، اندازه گیریهای برجا و مدلهای فیزیکی زمانبر و پرهزینه هستند. در نهایت مدلهای تحلیلی با وجود سادگی و ارزان بودن، مبتنی بر مفروضات متعددى هستند كه ممكن است خطاى تخمين HDZ را افزایش دهد (Rezaei, 2018).

جدول ۱- خلاصه نتایج روشهای موجود برای تعیین HDZ بهعنوان ضریبی از ضخامت لایه زغالسنگ استخراجی

منبع	HDZ (×h <sub>s</sub> )	مدل/روش مورد استفاده
	۲-۱۰۰	اندازهگیری برجا
Rezaei et al., 2015	۲-۱۰۵	مدل تجربى
	$r/ \cdot r_{\Delta V/\Lambda}$	مدل تحليلي
	۵/۸–۴۷/۶	مدل عددی
Rezaei 2018	۳/۱–۸۶/۵	مدل هوش مصنوعی
	1./.۲_۴./۹۳	مدل آماری

با توجه به معایب مدلهای قبلی و همچنین در نظر گرفتن تعداد محدودی از پارامترهای مؤثر در مدلسازی HDZ، استفاده از روشهای جایگزین مناسب ضروری بهنظر میرسد. تکنیکهای آماری و سیستمهای هوش مصنوعی

می توانند جایگزین های مناسبی در این زمینه باشند. شبکههای عصبی مصنوعی یکی از پرکاربردترین سیستمهای هوشمند است که میتوان از آن برای مدلسازی مسائل یپچیده استفاده کرد. این شبکهها تاکنون با دقت بالا در زمینههای مختلف مهندسی معدن بهویژه در معدنکاری زیرزمینی زغالسنگ مورد استفاده قرار گرفتهاند Rezaei, 2018; Mulumba, et al, 2023; Mahdevari) Yu et al., 2024). كاربردهای فوق نشان میدهد كه شبکههای عصبی مصنوعی تکنیکهای قدرتمندی در حل مسائل معدنکاری زیرزمینی زغالسنگ هستند که میتواند مسائل چند متغیره را با دقت بالا مدلسازی نماید. برخلاف روشهای موجود، تأثیر اکثر پارامترهای مؤثر را میتوان بهطور همزمان در مدلسازی شبکه عصبی در نظر گرفت. بعلاوه، مهمترین مزیت روشهای هوش مصنوعی از جمله شبکه عصبی نسبت به روشهای عددی و تجربی، قابلیت تعميم آنها به ساير مطالعات موردي است (Rezaei, 2018). بنابراین، در این تحقیق از روش شبکه عصبی مصنوعی برای تعیین HDZ در سقف پهنه جبهه کار طولانی استفاده و خروجی آن با نتایج مدل رگرسیون آماری مورد مقایسه قرار گرفته است.

# ۲- مواد و روشها

# ۲-۱- رگرسیون آماری

رگرسیون آماری یکی از مدلهای موجود در تحلیلهای آماری است که برای تعیین ارتباط بین متغیرهای ورودی و متغیرهای خروجی مورد استفاده قرار میگیرد. در مدل رگرسیون خطی چند متغیره، میتوان تأثیر ذاتی متغیرهای ورودی بر یک یا چند خروجی در یک مسئله خاص و همچنین مؤثرترین پارامتر بر تابع هدف را بهدست آورد. یک مدل رگرسیون خطی چند متغیره برای n تعداد ورودی و یک خروجی معمولاً بهصورت زیر نمایش داده می شود (Ceryan et al., 2012):

- $y = a_0 + a_1 x_1 + a_1 x_1 + \dots + a_n x_n$  (1) So set io, y and the advantage of the adv
- a<sub>1</sub> تا a<sub>n</sub> ضرایب مربوط به متغیرهای ورودی x<sub>1</sub> تا x<sub>n</sub> است که در مجموع مقدار خروجی معادله را رقم میزنند.

#### ۲-۱- شبکه عصبی مصنوعی

شبکههای عصبی مصنوعی را تا حدودی میتوان مدلهای الکترونیکی ساختار عصبی مغز انسان در نظر گرفت. این مدلها جزء سیستمهای هوشمند هستند که با پردازش دادههای تجربی، دانش یا قانون نهفته در دادهها را به ساختار شبکه منتقل میکنند که به دلیل فراگیری قوانین کلی بر اساس دادههای تجربی (عددی)، سیستمهای هوشمند نامیده میشوند. یک شبکه عصبی از تعدادی نرون که در لایههای متوالی قرار گرفتهاند، تشکیل شده است. اساساً در اين شبكهها سه نوع لايه شامل لايه ورودي، لايه(هاي) میانی یا پنهان و لایه خروجی وجود دارد که یک نمونه شماتیک آن در **شکل ۴**، نشان داده شده است. تعداد نرونهای موجود در لایههای ورودی و خروجی بر اساس تعداد متغیرهای ورودی و خروجی سیستم و تعداد لایههای میانی (پنهان) بههمراه تعداد نرونهای موجود در هر لایه با توجه به پیچیدگی مسئله و معمولاً با استفاده از روش سعی و خطا تعیین می گردد (Demuth et al., 1996). شبکه عصبی بر اساس دادههای تجربی، بین ورودیها و خروجی ارتباط برقرار می کند. با وارد کردن دادههای ورودی آموزشی و خروجیهای متناظر با آن، فرآیند یادگیری شبکه عصبی بهوسیله الگوریتمهای آموزش خاص طی شده و جوابهایی توليد مى شود كه اغلب دقيق بوده و با شرايط مساله سازگاری دارد. نتایج حاصل از مدل شبکه عصبی با استفاده از شاخصهای اررزیابی عملکرد مناسب مانند ریشه میانگین مربعات خطا سنجيده شده و با مقادير واقعى متناظر مقايسه می شود. این فرآیند در سیکلهای مختلف به صورت رفت و برگشت تکرار می گردد. در طی فرآیند یادگیری، شبکه به مرور زمان خطاها را سرشکن کرده، رفتار آن بهبود یافته و تطابق خروجی شبکه با خروجی واقعی بیشتر شده و منجر به جواب دقيق و دستيابي به مدل بهينه مي شود ( Menhaj, .(2000; Rezaei, 2020; Rezaei et al., 2024

#### ۳-۲ پایگاه داده

یکی از مهمترین مراحل تهیه یک مدل شبکه عصبی، جمعآوری دادهها برای آموزش آن است. دادههای مورد نیاز بر حسب نوع مسأله میتواند با روشهایی مانند استفاده از دادهها و آمارهای موجود، انجام آزمایشات، استفاده از نرم

افزارهای مناسب و ... تهیه شود. در این تحقیق، دادههای مورد نیاز برای طراحی مدل رگرسیون چند متغیره آماری و آموزش شبکه عصبی از منابع معتبر ( , ,*Rezaei et al.* آموزش شبکه عصبی از منابع معتبر ( , ,*Rezaei et al.* 2015; *Rezaei*, 2018) گرفته شده است که در بخش مقدمه و **جدول ۱**، بهطور خلاصه به آنها اشاره شد. لازم به ذکر است که در دو منبع فوقالذکر منابع مختلفی بررسی گردیده و دادههای هر کدام از منابع مورد بررسی، گردآوری شده که در نهایت منجر به تهیه یک پایگاه داده قوی شده شده که در نهایت منجر به تهیه یک پایگاه داده قوی شده است. در تحقیق حاضر علاوه بر دادههای جمعآوری شده در دو منبع فوق، نتایج و دادههای آن دو منبع هم به پایگاه داده قبلی اضافه و یک پایگاه داده جدید با ۱۲۰ سری داده تهیه شده است. دادههای مورد استفاده شامل پارامترهای موثر بر مسئله مورد نظر (هفت متغیر ورودی) و پارامتر خروجی (ارتفاع منطقه رها از تنش) است.



شکل ۴- ساختار شبکه عصبی مصنوعی (2021 بنش در با توجه به طبیعت مسئله (منطقه رها از تنش در سقف پهنه جبههکار طولانی) و پراکندگی دادههای جمعآوری شده، پارامترهایی که برای تغذیه و استفاده در مدل سازی شبکه عصبی و رگرسیون چند متغیره در این تحقیق در نظر گرفته شده است، شامل ۷ پارامتر بهعنوان متغیرهای مؤثر بر میزان HDZ (پارامتر خروجی) میباشد. پارامترهای ورودی شامل ارتفاع روباره، ضخامت لایه زغال سنگ استخراجی و وزن مخصوص، مدول الاستیسیته، ضریب پواسون، مقاومت فشاری تک محوری و فاکتور حجمی تودهسنگ سقف میباشد. لازم به ذکر است که در مورد خصوصیات لایههای سقف، مقادیر متوسط پارامترها در نظر گرفته شده است.

همانطور که قبلا اشاره شد، اندازهگیری پارامترهای تاثیرگذار بر ارتفاع منطقه رها از تنش ناشی از روش معدنکاری جبهه کار طولانی بهدلیل محیط پیچیده این روش

بسیار مشکل و پر هزینه است. بههمین دلیل در این تحقیق از دادههای اندازه گیری شده در سایر مقالات معتبر استفاده شده است که طبیعتاً در برگیرنده تمامی پارامترهای تأثير گذار بر ارتفاع منطقه رها از تنش نيست. بهعنوان مثال، با وجود اینکه پارامترهای شیب لایه و ابعاد پهنه استخراجی متغیرهای تأثیر گذاری بر ارتفاع منطقه رها از تنش در سقف پهنه استخراجی هستند اما بهعلت کم بودن تعداد دادههای موجود، در مدلسازی ارتفاع منطقه رها از تنش در این تحقيق ناديده گرفته شدهاند. با اين حال، ضخامت لايه استخراجی (ارتفاع معدنکاری) بهعنوان یکی از پارامترهای ورودی در مدلسازی در نظر گرفته شده است که تأثیر یک بُعد از پهنه استخراجی را بر ارتفاع منطقه رها از تنش منعکس مینماید. از طرف دیگر، تغییرات شیب لایه و ابعاد پهنه استخراجی در دادههای جمع آوری شده هم زیاد نبوده و فاقد شرایط لازم برای استفاده در الگوریتمهای هوشمند (مانند شبکه عصبی مصنوعی) بهعنوان پارامتر ورودی هستند. همانطور که واضح است، اساس الگوریتمهای هوشمند آموزش بر پایه تغییرات گسترده در پارامترهای ورودی و خروجی است که پارامترهای شیب لایه و ابعاد پایه استخراجی فاقد این ویژگی برای استفاده در شبکههای عصبي بهعنوان ورودي در تحقيق حاضر هستند.

برای ساخت مدلهای شبکه عصبی و رگرسیون آماری در این تحقیق، دادههای جمعآوری شده به دو دسته

دادههای آموزش (طراحی) و دادههای آزمون تقسیم بندی شدند. بر این اساس، ۱۰۰ سری از دادهها برای آموزش و طراحی مدلها و ۲۰ سری باقیمانده برای آزمون و ارزیابی آنها در نظر گرفته شد. دادههای آموزش و دادههای آزمون از بین مجموعه دادههای موجود بهصورت تصادفی و با استفاده از روش دستهبندی تقسیمبندی گردید. جدول ۲، پارامترهای ورودی و خروجی همراه با خصوصیات آماری، علائم و واحدهای مربوطه را نشان می دهد. همچنین، تعداد ۱۰ نمونه از دادههای مورد استفاده برای آموزش شبکه عصبی و طراحی مدل آماری در **جدول ۳،** نشان داده شده است. همانطور که در جداول فوق مشاهده می شود، مقدار HDZ در برخی از موارد زیاد است که ناشی از در نظر گرفتن ارتفاع منطقه رها از تنش در دراز مدت و یا منطقه رها از تنش ناشی از استخراج زغال در چندین برش مختلف می باشد. البته از کل ۱۲۰ سری داده جمع آوری شده، ارتفاع منطقه رها از تنش اکثراً زیر ۱۰۰ متر است و صرفاً در پنج مورد مقادیر ارتفاع رها از تنش بزرگتر از ۱۰۰ متر بوده که شامل ۱۱۲، ۱۲۵، ۱۷۷، ۲۱۰ و ۲۴۰ متر میباشد. لازم به ذکر است که بیشتر مقادیر فوق مربوط به مدلسازی عددی و ناشی از در نظر گرفتن تغییرات زیاد پارامترهای مدل و استخراج زغالسنگ در چندین برش مختلف است.

جدول ۲- مقادیر کمینه و بیشینه متغیرهای ورودی و خروجی در مدلسازی HDZ همراه با خصوصیات آماری، علائم و واحدهای مربوطه

انحراف از معيار	واريانس	بيشينه	كمينه	نماد	پارامتر	نوع داده
۱۱۵/۸۹	13431/00	۶۵۰	۱۳۰	Н	ارتفاع روباره (متر)	
۲/• λ	4/32	22/20	۲ • /۵ •	γ	وزن مخصوص تودهسنگ سقف (کیلو نیوتن بر مترمکعب)	
۵/۵۴	۳۰/۶۹	۱۸/۸۵	1/17	Ε	مدول الاستيسيته تودهسنگ سقف (گيگا پاسكال)	
٠/•۴	•/• •	۰/۳۳	•/١٨	υ	ضریب پواسون تودەسنگ سقف (-)	ورودى
٧/٢۴	57/47	4.196	۴/۷۶	σ	مقاومت فشاری تک محوری تودهسنگ سقف (مگا پاسکال)	
•/\٨	۰/۰۳	١/٧٣	١/•٧	b	فاکتور حجمی تودهسنگ سقف (-)	
$\Delta/\Upsilon \Lambda$	21/12	۶	١/٧	h	ضخامت لایه زغالسنگ استخراجی (متر)	
42/11	۱۸۲۳/۸۱	74.	۱۷/۵	HDZ	ارتفاع منطقه رها از تنش (متر)	خروجى

استفاده از رگرسیون آماری و شبکه عصبی مصنوعی برای تعیین ارتفاع منطقه ...، محمد رضائی و ....، ص ۳۳–۴۸

HDZ (متر)	(متر) <i>h</i>	(-) b	<i>σ</i> (مگاپاسکال)	υ (-)	<i>E</i> (گیگاپاسکال)	γ (کیلو نیوتن بر متر مکعب)	H (متر)	رديف
٧٩	۲/۴۴	۱/۵	18/18	•/YV	18/91	۲۵	13.	١
117	۴/۵	۱/۶۵	٩/٧۴	۰ /۳ ۰	8/48	۲۷	44.	٢
74.	٣	۱/۴	٩/٣٣	•/٢٢	$r/\Delta$	۲۷	۲٩.	٣
177	٣/٨	۱/۵۱	11/87	•/٢٩	1/95	$\Delta \Delta V$	۲۵۰	۴
۲۸	٢	١/٢٨	17/24	•/7۶	٣/٣٨	51/50	٣۴.	۵
۴۳/۵	١/٧	١/۵	$\Delta/\Upsilon$ )	•/74	1/17	74	۲۱۰	۶
٩٧	۶	۱/۶۵	24/2.	۰ /۲ ۱	) Y/Y )	21/14	۶۵۰	٧
۱۹	۴/۵	۱/۲۶	WY/17	٠/١٩	۱۸/۸۵	$\chi \pi/\pi Q$	۵۲۵	٨
۶۵	٣	۱/•Y	۴/۷۶	•/۲٨	٣/٨۶	۲ • /۵ •	188	٩
۱۷/۵	4/20	١/٢	۳۵/۳۵	•/١٨	١٧/٩۵	۲۷	۵۰۰	١٠

جدول ۳- برخی از دادههای مورد استفاده در مدلسازی HDZ

# ۳- مدلسازی ار تفاع *HDZ*

# ۳–۱– مدلسازی با استفاده از رگرسیون آماری

بهمنظور تخمین آماری HDZ در این تحقیق، از مدل رگرسیون خطی چند متغیره استفاده شده است. برای انجام مدلسازی آماری و بررسی ارتباط بین ورودیها و خروجی مدل (ارتفاع منطقه رها از تنش)، ارزیابی تأثیر ورودیها بر خروجی و تعیین یک رابطه خطی بین آنها، از نرمافزار آماری SPSS استفاده شده است. طراحی مدل آماری بر اساس دادههای آموزش که در بخش قبلی به آن اشاره شد انجام گرفته است. خروجی تحلیلهای آماری انجام شده شامل ضریب ثابت، ضرایب بین HDZ و پارامترهای ورودی شامل ارتفاع روباره (H)، وزن مخصوص ( $\gamma$ )، مدول الاستيسيته (E)، ضريب پواسون (v)، مقاومت فشارى تک محوری (م)، فاکتور حجمی (b) و ضخامت لایه زغالسنگ استخراجی (h) در جدول ۴، نشان داده شده است. بر اساس ضرايب فوق، مى توان HDZ را بر اساس مقادير مختلف متغیرهای ورودی تخمین زد. همچنین، ضریب همبستگی کلی حاصل از مدل در جدول ۴، آورده شده است که نشاندهنده دقت نسبتاً بالای مدل آماری در تعیین HDZ است. با توجه به ضرایب استاندارد شده (Beta) بهدست آمده در **جدول ۴،** می توان نتیجه گرفت که دو پارامتر وزن مخصوص لایه های سقف و ضخامت لایه زغال سنگ

استخراجی دارای بیش ترین تأثیر بر HDZ هستند. به طور کلی، هر دو پارامتر تأثیر قابل توجهی بر HDZ دارند ولی تأثیر وزن مخصوص توده سنگ سقف در این تحقیق نسبتاً بیشتر از تأثیر ضخامت لایه زغال سنگ استخراجی است. از طرف دیگر، ضریب پواسون توده سنگ سقف دارای کمترین تأثیر بر HDZ است.

در مورد نتیجه آنالیز حساسیت در مدل آماری دو نکته قابل ذکر است. اول اینکه دادههای جمع آوری شده از منابع مختلف و مربوط به معادن گوناگون است که تنوع و تغییرات پارامترهای ورودی زیاد بوده و میتواند در برخی از موارد جهت گیری تأثیر پارامترهای ورودی بر خروجی را تغییر دهد که ممکن است با نتیجه مورد انتظار در یک مطالعه موردی خاص متمايز باشد. دوم اينكه اين نتيجه حاصل از مدل آماری است و ممکن است تا حدودی متفاوت با نتیجه روشهای تخصصی آنالیز حساسیت باشد. با این حال، وزن مخصوص تودهسنگ سقف نقش مهمی در میزان بار وارده بر سقف پهنه و شکست و تخریب بیشتر لایهها دارد. همچنین، ضخامت لایه زغال استخراجی نقش مهمی در میزان HDZ ایفا کرده و دارای رابطه مستقیم با این پارامتر مى باشد. بنابراين، مى توان نتيجه گرفت كه نتايج مدل آمارى قابل قبول بوده و تا حدودی با واقعیتهای معدنکاری جبهه کار طولانی منطبق است. فصلنامهی علمی مهندسی تونل و فضاهای زیرزمینی؛ دورهی ۱۲؛ شمارهی ۱؛ بهار ۱۴۰۲

مقدار	ضريب استاندارد	· · · · <b>·</b> //=1?	متغير پيشبينى
<u>R</u> مدل	شدہ (Beta)	فابك اطريب	كننده
		-131/984	مقدار ثابت
	-•/•Y۶	-•/• ¥X	Н
	•/524	<b>١</b> •/٧۶٩	γ
	-•/\•٣	-•/V9W	E
•/٨٧٨	• / • 1	11/301	υ
	-•/۲۵۶	-1/583	σ
	-•/•۶۲	-14/737	b
	•/۴۱٧	۰/۷۳۹	h

جدول ۴- خروجی مدل آماری در مدلسازی HDZ

#### ۲-۳ مدلسازی با استفاده از شبکه عصبی

برای دستیابی به شبکه عصبی بهینه بهمنظور پیش بینی HDZ در سقف پهنه جبهه کار طولانی، انواع مختلف شبکههای عصبی با پارامترهای مختلف بر اساس روش سعی و خطا مورد ارزیابی قرار گرفت. بدین منظور، از شاخص جذر متوسط مربعات خطا (RMSE) برای ارزیابی نتیجه شبکههای مختلف استفاده شد که معادله آن در رابطه ۲ نشان داده شده است (Majdi & Rezaei, 2013b). در این نسان داده شده است (Majdi & Rezaei, 2013b). در این راستا، مقدار RMSE برای تمام مدلهای ممکن از جمله مدلهای با یک و دو لایه پنهان و با تعداد نرونهای مختلف، توابع آموزش و انتقال مختلف و تغییر پارامترهای قابل

تنظیم شبکه محاسبه گردید. بر این اساس، مدل با کمترین RMSE بهعنوان مدل شبکه عصبی بهینه برای پیشبینی HDZ انتخاب گردید. نتایج روش سعی و خطا برای برخی از مدلهای شبکه عصبی بهمنظور تعیین HDZ در جدول ۵، نشان داده شده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (A_{imeas} - A_{ipred})^2}$$
(7)

در رابطه شماره (۲)، Aipred Aimeas و n بهترتیب امین مقدار اندازه گیری شده، نامین مقدار پیشبینی شده و تعداد مجموعههای داده هستند.

RMSE	تابع آموزش	تابع انتقال	ساختار شبكه	شماره
•/• ١٢١	لونبرگ-ماركوارت	لگاريتم سيگوئيد	Y-1 • - 1	١
•/• 757	گرادیان نزولی	تانژانت سيگوئيد	Y-1 • - 1	٢
٠/٠٠٩٨	گرادیان نزولی	تانژانت سيگوئيد	Υ-Υ-λ-١	٣
•/•• <b>\</b> ۶	لونبرگ-ماركوارت	سيگوئيد	Υ-λ-۲-۱	۴
•/•• • • • •	گرادیان نزولی	تانژانت سيگوئيد	٧-٧-٣-١	۵
• / • • YA	گرادیان نزولی	سيگوئيد	٧-٣-٧-١	۶
•/•• ۴٨	لونبرگ-ماركوارت	سيگوئيد	$V-\Delta-\Delta-1$	٧
•/•• ۵A	لونبرگ-ماركوارت	تانژانت سيگوئيد	$V-\Delta-\Delta-1$	٨
•/••٧۶	لونبرگ-ماركوارت	تانژانت سيگوئيد	٧-۴-۶-۱	٩
•/••۶۴	گرادیان نزولی	سيگوئيد	V-8-4-1	١٠

جدول ۵- خروجی شبکههای عصبی گوناگون با خصوصیات مختلف برای تخمین HDZ

عصبی چند لایه با الگوریتم پسانتشار خطا، ساختار ۱-۵-

همانطور که در **جدول ۵،** مشاهده میشود، شبکه

۵-۷، تابع آموزش لونبرگ-مارک کواردت (TRAINLM) و تابع انتقال لگاریتم سیگموئید (LOGSIG) دارای کمترین میزان RMSE است (سطر ۷). بنابراین، ساختار مذکور به-عنوان مدل شبکه عصبی بهینه برای تعیین HDZ در این تحقیق در نظر گرفته میشود. ساختار شبکه عصبی بهینه در شکل ۵، نشان داده شده است. بهمنظور کنترل عملکرد شبکه در مرحله آموزش، ضریب همبستگی (R) بین مقادیر اندازه گیری شده و پیشبینی شدهٔ HDZ بهعنوان معیار

ارزیابی شبکه عصبی در نظر گرفته می شود. نتایج حاصل از مدل شبکه عصبی بهینه بر حسب ضریب همبستگی برای مراحل مختلف آموزش، اعتبارسنجی و آزمون در **شکل ۶،** نشان داده شده است. همانطور که مشاهده می شود، مقدار *R* نشان داده شده است. همانطور که مشاهده می شود، مقدار نشان دهنده مراحل آموزش، اعتبارسنجی و آزمون بالا است که نشان دهنده دقت بالای مدل شبکه عصبی پیشنهادی می باشد.





شکل ۵- ساختار شبکه عصبی پیشنهادی برای تخمین HDZ

شکل ۶- نتایج مدل شبکه عصبی بهینه پیشنهادی بهمنظور تخمین HDZ

#### ۴- ارزیابی عملکرد روشهای مورد استفاده

برای ارزیابی عملکرد مدلهای پیشنهادی، نتایج حاصل از آنها با مقادیر واقعی (خروجی دادههای آزمون) مقایسه میشود. بدین منظور، از سه شاخص آماری ضریب تصمیم گیری ( $R^2$ )، میانگین خطای مطلق ( $E_a$ ) و میانگین خطای نسبی ( $R^2$ )، میانگین خطای مطلق ( $E_a$ ) و میانگین خطای نسبی ( $R^2$ )، میانگین خطای مطلق ( $E_a$ ) و میانگین حالت کلی، عملکرد یک مدل زمانی ایدهآل است که مقادیر  $E_a$  و R برابر با ۱ یا 1.1. باشد. بنابراین، مقدار بالاتر  $R^2$  و پایین بودن مقادیر  $E_a$  و  $R^2$  نشان دهنده مطلوب بودن مدل و عملکرد قابل قبول آن در تخمین مقدار مطلق ( $E_a$ ) و میانگین خطای نسبی ( $R^2$ )، میانگین خطای مطلق ( $E_a$ ) و میانگین خطای نسبی ( $R^2$ )، میانگین خطای از روابط (R) تا ( $\Delta$ ) محاسبه میشوند (R)، میانگین خطای (Rezaei, 2021; Rezaei & Lappin (2021; Wang et al., 2023)

$$R^{2} = \left[\frac{\sum_{i=1}^{n} (A_{ipred} - \overline{A}_{pred})(A_{imeas} - \overline{A}_{meas})}{\sqrt{\sum_{i=1}^{n} (A_{ipred} - \overline{A}_{pred})^{2} \sum_{i=1}^{n} (A_{imeas} - \overline{A}_{meas})^{2}}}\right]^{2} \quad (\r)$$

$$E_a = \left| A_{imeas} - A_{ipred} \right| \tag{f}$$

$$E_{r} = \left(\frac{\left|A_{imeas} - A_{ipred}\right|}{A_{imeas}}\right) \times 100$$

که در آن، Aimeas نامین مقدار اندازه گیری شده، امین مقدار پیش بینی شده، n تعداد مجموعه های داده و Aimeas و Āipred به ترتیب میانگین مقادیر اندازه-گیری شده (واقعی) و پیش بینی شده است.

شاخصهای فوقالذکر بر اساس ۲۰ سری داده آزمون برای هر دو مدل رگرسیون آماری و شبکه عصبی محاسبه گردید که نتایج حاصله در **جدول ۶،** نشان داده شده است. نتایج بهدست آمده در **جدول ۶،** نشاندهنده دقت بالا و خطای کم هر دو مدل در تخمین HDZ میباشد. با این حال، مدل شبکه عصبی نسبت به مدل آماری دارای دقت بیشتر و خطای کمتری است. جهت ارزیابی بیشتر مدلهای پیشنهادی، ارتباط بین HDZ حاصل از مدلهای رگرسیون آماری و شبکه عصبی با مقادیر واقعی اندازه گیری

شده بهترتیب در **شکل ۷** و **شکل ۸**، نمایش داده شده است. همانطور که در **جدول ۶، شکل ۷** و **شکل ۸**، مشاهده میشود، مقدار ضریب تصمیم گیری حاصل از مدلهای آماری و شبکه عصبی بهترتیب برابر با ۲۷/۲۲ و ۹۶/۰۴ بهدست آمده است که نشان دهنده دقت بالاتر شبکه عصبی نسبت به مدل آماری است.

جدول ۶- نتایج شاخصهای عملکرد مدلهای رگرسیون آماری و شبکه عصبی بهمنظور پیشبینی HDZ

مدل رگرسیون آماری	مدل شبکه عصبی	شاخص
۷۷/۲۲	٩۶/•۴	(/.) R <sup>2</sup>
۵/۶۶	۲/۵۳	<i>Ea</i> (متر)
۲ • /۴۳	٧/٣٢	(/.) E <sub>r</sub>



سیر کی بعدیر رحی به منظور بررسی انطباق نتایج حاصل از مدل های مورد استفاده با دادههای واقعی، مقایسه بین خروجی حاصل از مدل های رگرسیون آماری و شبکه عصبی با مقادیر واقعی

HDZ بر اساس ۲۰ سری داده آزمون در شکل ۹، جهت نشان داده شده است. با توجه به شکل ۹، میتوان دریافت که نتایج حاصل از شبکه عصبی مصنوعی نسبت به نتایج مدل آماری به مقادیر واقعی ZDH نزدیکتر بوده و خروجی آن تطابق بهتری با دادههای واقعی دارد. با این حال، نتایج مدل آماری هم در خیلی از موارد تطابق بسیار خوبی با دادههای واقعی داشته و فقط در چند مورد تفاوت معنیداری با مقادیر واقعی ZDH دارد.



شکل ۹- مقایسه بین خروجی حاصل از مدلهای رگرسیون آماری و شبکه عصبی با مقادیر واقعی HDZ

به منظور ارزیابی بیشتر مدلهای مورد استفاده، نمودار تیلور نتایج حاصل از دو مدل رگرسیون آماری و شبکه عصبی در شکل ۱۰، نشان داده شده است که در آن، نتایج دو مدل با همدیگر و با مقادیر واقعی HDZ مورد مقایسه قرار گرفته است. همانطور که در شکل ۱۰، مشاهده میشود، نقاط شبیه سازی هر دو مدل نسبتاً نزدیک به نقطه مشاهده شده (داده واقعی) هستند که نشان دهنده شباهت در انحراف استاندارد، همبستگی بالا (ضریب همبستگی ۸۸۷۸/ برای مدل آماری و ۹۶/۰ برای شبکه عصبی) و خطای کم در پیش بینی HDZ است. با این حال، فاصله نقطه شبیه سازی مدل آماری از نقطه مرجع در مقایسه با مدل شبکه عصبی تا حدودی بیش تر است که نشان دهنده عملکرد پایین تر آن میباشد.

خروجیهای نمودار تیلور توسعه و اعتبارسنجی دقیق مدلهای پیشنهادی (بهویژه مدل شبکه عصبی) و کاربرد قابل اعتماد آنها را در تعیین HDZ نشان میدهد.



شکل ۱۰– نمودار تیلور حاصل از مدلهای رگرسیون آماری و شبکه عصبی در تخمین HDZ

بر اساس جدول ۶، شکل ۷، شکل ۸، شکل ۹ و شکل ۱۰، میتوان نتیجه گرفت که خطای حاصل از مدل شبکه عصبی کمتر و دقت آن نسبتاً بالاتر از مدل رگرسیون آماری است. همچنین، نتایج بهدست آمده از مدل شبکه عصبی تطابق بهتری با مقادیر واقعی HDZ دارند. بنابراین، میتوان نتیجه گرفت که مدلهای پیشنهادی در این تحقیق (بهویژه مدل شبکه عصبی) قابلیت خوبی در پیشبینی HDZ دارند و در عمل میتوانند مورد استفاده قرار گیرند. با این حال، تحقیقات بیشتری در زمینه استفاده عملی از این مدلها با قابلیت اطمینان بالا مورد نیاز است. بهعنوان مثال، میتوان افزایش تعداد سریهای داده، قابلیت اطمینان و تعمیم پذیری در استفاده عملی از این مدلها در معدنکاری جبهه کار طولانی را افزایش داد.

# ۵- تحلیل اهمیت متغیر

تحلیل اهمیت متغیر معمولاً برای تعیین تأثیر متغیرهای ورودی مدل بر متغیر خروجی آن انجام میشود. تعیین تأثیر ورودیهای مدل بر خروجی معمولاً به دو صورت سنتی و جدید انجام میشود. در روش سنتی از تغییر یک پارامتر و ثابت نگهداشتن بقیه پارامترها برای تعیین تأثیر آن پارامتر استفاده میشود. در روشهای جدید، روابط ریاضی مشخصی برای تعیین اثر پارامترهای ورودی بر پارامتر خروجی مورد

استفاده قرار می گیرد (Rezaei et al., 2023). با توجه به اینکه مدل شبکه عصبی در این تحقیق از مدل رگرسیون آماری مطابق **جدول ۶**، دقیق تر است، لذا تحلیل اهمیت متغیرها بر روی نتایج مدل شبکه عصبی انجام می شود. در این تحقیق، بررسی اهمیت ورودی ها بر مقدار HDZ با استفاده از نرمافزار Statistica انجام انجام شده است. در محیط نرمافزار فوق، مقادیر اهمیت ورودی ها در بازه • و ۱ محاسبه و سازماندهی می شود. در این روش، هرچه مقدار بهدست آمده برای یک پارامتر بیش تر و به ۱ نزدیک تر باشد نشان دهنده اهمیت بیش تر آن متغیر بر خروجی است. بر این اساس، مقدار اهمیت هفت متغیر ورودی بر ZDH محاسبه شده و در **شکل ۱۱،** نشان داده شده است. همانطور که مشاهده می شود، ارتفاع روباره و ضریب پواسون به ترتیب بیش ترین و کم ترین تأثیر را بر HDZ دارند.

پارامتر ارتفاع یا عمق روباره که بر اساس تحلیل اهمیت متغیر دارای بیشترین تأثیر بر HDZ است، ذاتا نقش مهمی در افزایش میزان بار وارد بر لایههای سقف پهنه استخراجی و شکست و تخریب بیشتر آنها ایفا میکند. با توجه به اینکه دادههای مورد استفاده در این مقاله از منابع گوناگون گرفته شده و مربوط به معادن با شرایط مختلف و تغييرات زياد ارتفاع روباره است لذا بهدست آمدن چنين نتیجهای می تواند قابل قبول باشد. با این حال، این نتیجه ممكن است با نتايج حاصل از يك معدن خاص با شرايط متفاوت، همسو نباشد. از طرف دیگر، ارتفاع روباره به خودی خود پارامتر مهمی در میزان HDZ در سقف پهنه استخراجی است. به طور کلی، HDZ تابعی ذاتی از ارتفاع روباره است که دارای رابطه مستقیم با این پارامتر میباشد. بنابراین، علیرغم وجود متغیرهای تأثیرگذار دیگری همانند ضخامت لایه زغال استخراجی در پارامترهای ورودی مدلسازی، ارتفاع روباره هم ذاتاً پارامتر تعیین کنندهای در میزان HDZ است که می تواند تأیید کننده نتیجه تحلیل اهمیت متغیر در این بخش و نشاندهنده نزدیک بودن نتایج حاصله به واقعیتهای موجود در محیط معدنکاری جبهه کار طولانی باشد. با این حال، تحقیق حاضر نیز همانند اکثر تحقیقات علمی دارای قطعیت کامل نبوده و برای کاربرد عملی با اطمینان بالا، نیاز به اعتبارسنجی بیشتر و ارزیابی آن در مطالعات موردی مختلف دارد.



#### ۶- نتیجهگیری

در این تحقیق از مدلهای رگرسیون آماری چند متغیره و شبکه عصبی مصنوعی برای تعیین HDZ در سقف پهنه جبهه کار طولانی زغالسنگ استفاده شد. بر اساس مدلسازی انجام شده و تحلیلهای صورت گرفته، نتایج زیر حاصل گردید:

- بر اساس نتایج ارزیابی عملکرد مدلهای پیشنهادی با استفاده از شاخصهای آماری، اثبات گردید که شبکه عصبی دارای دقت بیشتر و خطای کمتر از مدل آماری HDZ بوده و خروجیهای حاصل از آن تطابق بهتری با واقعی دارد.
- نمودار تیلور نتایج حاصل از دو مدل آماری و شبکه عصبی نشان داد که خروجی هر دو مدل تطابق خوبی با دادههای واقعی دارد. همچنین، شباهت در انحراف استاندارد و همبستگی بالای حاصل از دو مدل، عملکرد مناسب آنها بهویژه شبکه عصبی را اثبات نمود.
- ۰ نتایج مدل آماری نشان داد که ۲ دارای بیشترین تأثیر و ۲ دارای کمترین تأثیر بر HDZ است.
- م تحلیل اهمیت متغیر نتایج حاصل از شبکه عصبی نشان داد که متغیرهای H و v بهترتیب بیشترین و کمترین تأثیر را بر HDZ دارند.
- مهم ترین مزیت تحقیق فعلی نسبت به مطالعات قبلی،

استفاده از رگرسیون آماری و شبکه عصبی مصنوعی برای تعیین ارتفاع منطقه ...، محمد رضائی و ....، ص ۳۳–۴۸

طولانی، این پژوهش نیز همانند اکثر پژوهشهای علمی دارای قطعیت کامل نبوده و برای کاربرد عملی با اطمینان بالا نیاز به اعتبارسنجی بیشتر نتایج حاصله و ارزیابی آن در مطالعات موردی مختلف دارد. همچنین، در نظر گرفتن پارامترهای ورودی و تأثیرگذار بیشتر در مدلسازی *HDZ* و افزایش تعداد دادههای مورد استفاده به قابلیت اطمینان و تعمیم پذیری بیشتر مدل و استفاده عملی از آن کمک می نماید. بعلاوه، می توان از الگوریتمهای هوشمند جدید به ویژه الگوریتمهای ترکیبی برای تخمین *HDZ* استفاده و نتایج حاصل از آنها را با نتایج تحقیق فعلی و سایر تحقیقات مشابه مقاسه نمود. در نظر گرفتن پارمترهای ورودی بیشتر و در نظر گرفتن تأثیر همزمان آنها بهمنظور تخمین HDZ است. همچنین، تعداد ۱۲۰ داده مربوط به مطالعات موردی گوناگون با شرایط مختلف مورد استفاده قرار گرفته است که میتواند باعث تعمیم پذیری بیشتر مدل پیشنهادی نسبت به مدلهای مشابه قبلی شود.

 نتایج فوق نشان میدهد که مدل شبکه عصبی مصنوعی پیشنهادی در این تحقیق دارای قابلیت بالایی در تخمین HDZ است و میتواند بخشی از دغدههای موجود در این زمینه را پوشش دهد. با این حال، علیرغم نزدیک بودن نتایج حاصل از این تحقیق به واقعیتهای موجود در محیط معدنکاری جبههکار

#### ۷- مراجع

- Abdollahi, M. S., Najafi, M., Yarahmadi Bafghi, A., & Rafiee, R. (2024). A New method for stability analysis of chain pillar in longwall mining by using Coulmann graphical method. *Journal of Mining and Environment*, 15(4), 1461–1476. Retrieved from https://doi.org/10.22044/jme.2024.13754.2548
- Aghababaei, S., Jalalifar, H., Hosseini, A., Chinaei, F., & Najafi, M. (2024). Prediction of Roof Failure in Pre-driven Entries and Selecting a Suitable Type of Recovery Room Method in Longwall Mining. *Journal of Mining and Environment*, 15(1), 223–237. Retrieved from https://doi.org/10.22044/jme.2023.12787.2321
- 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. Retrieved from https://doi.org/10.1080/19386362.2019.1596610
- Ceryan, N., Okkan, U., & Kesimal, A. (2012). Prediction of unconfined compressive strength of carbonate rocks using artificial neural networks. *Environmental Earth Sciences*, 68(3), 807–819. Retrieved from https://doi.org/10.1007/s12665-012-1783-z
- Demuth, H., Beal, M., & Hagan, M. (1996). Neural network toolbox 5 user's guide. Natick, MA: The Math Work, Inc.
- Gao, F., Stead, D., & Coggan, J. (2014). Evaluation of coal longwall caving characteristics using an innovative UDEC Trigon approach. *Computers and Geotechnics*, 55, 448–460. Retrieved from https://doi.org/10.1016/j.compgeo.2013.09.020
- He, C., Lu, W., Zha, W., & Wang, F. (2021). A geomechanical method for predicting the height of a water-flowing fractured zone in a layered overburden of longwall coal mining. *International Journal of Rock Mechanics & Mining Sciences*, 143, 104798. Retrieved from

https://doi.org/10.1016/j.ijrmms.2021.104798

- Liu, S., Chang, R., Zuo, J., Webber, R. J., Xiong, F., & Dong, Na. (2021). Application of Artificial Neural Networks in Construction Management: Current Status and Future Directions. *Applied Sciences*, 11, 9616. Retrieved from https://doi.org/10.3390/app11209616
- Mahdevari, S., Shahriar, K., Sharifzadeh, M., & Tannant, D. D. (2017) Stability prediction of gate roadways in longwall mining using artificial neural networks. *Neural Computing & Applications*, 28(11), 3537–3555. Retrieved from https://doi.org/10.1007/s00521-016-2263-2
- Majdi, A., Hassani, F. P., & Yousef Nasiri, M. (2012). Prediction of the height of destressed zone above the mined panel roof in longwall coal mining. *International Journal of Coal Geology*, 62, 62–72. Retrieved from https://doi.org/10.1016/j.coal.2012.04.005
- Majdi, A., & Rezaei, M. (2013a). Application of artificial neural networks for predicting the height of destressed zone above the mined panel in longwall coal mining. 47th U.S. rock mechanics/geomechanics symposium, (pp. 1665–1673). San Francisco, California, USA.
- Majdi, A., & Rezaei, M. (2013b). Prediction of unconfined compressive strength of rock surrounding a roadway using artificial neural network. *Neural Computing & Applications*, 23(2), 381–389. Retrieved from https://doi.org/10.1007/s00521-012-0925-2
- Menhaj, M. B. (2000). Fundamentals of neural networks. Amirkabir University of Technology publication, 1st ed., 1st Vol.
- Mohammadi, H., Ebrahimi Farsangi, M. A., Jalalifar, H., Ahmadi, A. R., & Javaheri, A. (2016). Extension of excavation damaged zone due to longwall working effect. *Journal of Mining and Environment*, 7(1), 13–24. Retrieved from https://doi.org/10.22044/jme.2016.369
- Mondal, D., Roy, P. N. S., & Kumar, M. (2020). Monitoring the strata behavior in the Destressed Zone of a shallow Indian longwall panel with hard sandstone cover using Mine-Microseismicity and Borehole Televiewer data. *Engineering Geology*, 271, 105593. Retrieved from https://doi.org/10.1016/j.enggeo.2020.105593
- Mulumba, D. M., Liu, J., Hao, J., Zheng, Y., & Liu, H (2023). Application of an Optimized PSO-BP Neural Network to the Assessment and Prediction of Underground Coal Mine Safety Risk Factors. *Applied Sciences*, 13, 5317. Retrieved from https://doi.org/10.3390/app13095317
- Palchik, V. 2003. Formation of fractured zones in overburden due to longwall mining. *Environmental Geology*, 44(1), 28–38. Retrieved from https://doi.org/10.1007/s00254-002-0732-7
- Rezaei, M. (2018). Development of an intelligent model to estimate the height of caving–fracturing zone over the longwall gobs. Neural Computing & Applications, 30(7), 2145–2158. Retrieved from https://doi.org/10.1007/s00521-016-2809-3
- Rezaei, M. (2019). Forecasting the stress concentration coefficient around the mined panel using soft computing methodology. Engineering with Computers, 35, 451–466. Retrieved from https://doi.org/10.1007/s00366-018-0608-4
- 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. Retrieved from https://doi.org/10.1080/19386362.2017.1397873

استفاده از رگرسیون آماری و شبکه عصبی مصنوعی برای تعیین ارتفاع منطقه ...، محمد رضائی و ....، ص ۳۳–۴۸

- 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. Retrieved from https://doi.org/10.1007/s00366-019-00900-3
- Rezaei, M., Ahmadi, S. R., Hoang, N., & Jahed Armaghani, D., (2024a). Improved determination of the S-wave velocity of rocks in dry and saturated conditions: Application of machine-learning algorithms. *Transportation Geotechnics*, 49, 101371. Retrieved from https://doi.org/10.1016/j.trgeo.2024.101371
- Rezaei, M., Habibi, H., & Asadizadeh, M. (2024b). Determination of the stress concentration factor adjacent an extracted underground coal panel using the CART and MARS algorithms. *Earth Science Informatics*, 17(6). 5733–5750. Retrieved from https://doi.org/10.1007/s12145-024-01476-3
- Rezaei, M., Hossaini, M. F., & Majdi, A. (2015a). A time-independent energy model to determine the height of destressed zone above the mined panel in longwall coal mining. *Tunnelling* and Underground Space Technology, 4, 81–92. Retrieved from https://doi.org/10.1016/j.tust.2015.01.001
- Rezaei, M., Hossaini, M. F., & Majdi, A. (2015b). Determination of longwall mining-induced stress using the strain energy method. *Rock Mechanics and Rock Engineering*, 48(6), 2421–2433. Retrieved from https://doi.org/10.1007/s00603-014-0704-8
- Rezaei, M., Hossaini, M. F., & Majdi, A. (2015c). Development of a time-dependent energy model to calculate the mining-induced stress over gates and pillars. *Journal of Rock Mechanics and Geotechnical Engineering*, 7(3), 306–317. Retrieved from https://doi.org/10.1016/j.jrmge.2015.01.001
- 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. Retrieved from https://doi.org/10.22059/ijmge.2017.62147
- Rezaei, M., Majdi, A., Hossaini, M. F., & Najmoddini, I. (2018). Study the roof behavior over the longwall gob in long-term condition. *Journal of Geology and Mining Research*, 10(2), 15–27. Retrieved from https://doi.org/10.5897/JGMR2017.0284
- 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. Retrieved from https://doi.org/10.1016/j.simpat.2023.102844
- Shabanimashcool, M., & Charlie, C. L. (2012). Numerical modelling of longwall mining and stability analysis of the gates in a coal mine. *International Journal of Rock Mechanics and Mining Sciences*, 51, 24–34. Retrieved from https://doi.org/10.1016/j.ijrmms.2012.02.002
- Shun, L., Xuehua, L., Yanxin, M., & Chengjun, L. (2013). Time-domain characteristics of overlying strata failure under condition of longwall ascending mining. *International Journal of Mining Science and Technology*, 23, 207–211. Retrieved from https://doi.org/10.1016/j.ijmst.2013.04.018
- Van Dyke, M. A., Zhang, P., Dougherty, H., Su, D., & Kim, B. H. (2022). Identifying Longwall-Induced Fracture Zone Height Through Core Drilling. Mining, Metallurgy & Exploration, 39, 1345– 1355. Retrieved from https://doi.org/10.1007/s42461-022-00622-z

- Wang, Y., Rezaei, M., Abdullah, R. A., & Hasanipanah, M. (2023). Developing Two Hybrid Algorithms for Predicting the Elastic Modulus of Intact Rocks. Sustainability, 15, 4230. Retrieved from https://doi.org/10.3390/su15054230
- Wenbing, G., Youfeng, Z., & Quanlin, H., 2012. Fractured zone height of longwall mining and its effects on the overburden aquifers. *International Journal of Mining Science and Technology*, 22(5), 603–606. Retrieved from https://doi.org/10.1016/j.ijmst.2012.08.001
- Xu, C., Zhou, K., Xiong, X., Gao, F., & Zhou, J. (2024). Research on height prediction of waterconducting fracture zone in coal mining based on intelligent algorithm combined with extreme. Expert Systems With Applications, 249, 123669. Retrieved from https://doi.org/10.1016/j.eswa.2024.123669
- Yu, B., Wang, B. & Zhang, Y. (2024). Application of artificial intelligence in coal mine ultra-deep roadway engineering—a review. Artificial Intelligence Review, 57, 262. Retrieved from https://doi.org/10.1007/s10462-024-10898-w
- Zhang, B., Liang, Y., Sun, H., Wang, K., Zou, Q., & Dai J. (2022). Evolution of mining-induced fractured zone height above a mined panel in longwall coal mining. *Arabian Journal of Geosciences*, 15, 476. Retrieved from https://doi.org/10.1007/s12517-022-09768-y
- Zhang, Y., Tu, S., Bai, Q., & Li, J. (2013). Overburden fracture evolution laws and water-controlling technologies in mining very thick coal seam under water-rich roof. *International Journal of Mining Science and Technology*, 23(5), 693–700. Retrieved from https://doi.org/10.1016/j.ijmst.2013.08.013



Volume 12-Issue 1\Spring 2023

(TUSE)

نشریهی مهندسی تونل و فضاهای زیرزمینی

# Using the statistical regression and artificial neural network to determine the height of destressed zone above the longwall panel roof

M. Rezaei1\*; H. Haeri2; V. Sarfarazi3

1- Associate Professor; Department of Mining Engineering, Faculty of Engineering, University of Kurdistan,

m.rezaei@uok.ac.ir

2- Assistant Professor, Department of Mining Engineering, Higher Education Complex of Zarand, Shahid Bahonar University of Kerman, Kerman, Iran, haerihadi@gmail.com

3- Associate Professor; Mining Engineering Faculty, Hamedan University of Technology, sarfarazi@hut.ac.ir

Received: 4 Oct 2024; Accepted: 26 Feb 2025 DOI: 10.22044/tuse.2025.15173.1491

Keywords	Extended Abstract
Longwall mining	<b>Summary</b>
Height of destressed zone	To determine the height of destressed zone ( <i>HDZ</i> ) in this study, multivariate
Statistical regression	linear regression ( <i>MLR</i> ) and artificial neural network ( <i>ANN</i> ) models have
Artificial neural network	been used and the obtained results have been compared with each other and
Variable importance analysis	with real data. Models outputs have been evaluated using performance

evaluation indices and their outputs have been compared with real datasets in a Taylor diagram and a column chart. Results show that the *ANN* model has more accuracy and less error than the *MLR* model, and its output has a better match with real datasets. Finally, variable importance analysis of *ANN* model results has proven that overburden depth and Poisson's ratio are most the least effective variables on the *HDZ*.

#### Introduction

Due to a significant coal seam extraction in longwall mining, the roof layers are fractured, caved, and a destressed zone is formed at the panel roof. Accurately determining the height of this zone is very important in the estimation of transfer stresses to the surrounding structures. There are several methods in the literature to predict the *HDZ*, i.e., insitu measurement and physical, empirical, numerical, analytical, intelligent and statistical modeling. To cover the weaknesses of available methods, the *HDZ* is predicted using *MLR* and *ANN* models in this research.

#### **Methodology and Approaches**

The *MLR* and *ANN* models are used to predict the *HDZ* in this study. To develop these models, 120 datasets have been collected from literatures and have randomly been divided into training (100 series) and testing (20 series) datasets. Based on the training datasets, the optimal *MLR* and *ANN* models have been developed to predict *HDZ*. Finally, the developed models have been evaluated and verified using the testing datasets.

#### **Results and Conclusions**

To develop the optimal *MLR* and *ANN* models for determining *HDZ*, thier performances have been evaluated during the training and testing phases using performance evaluation indices, and statistical diagrams and charts. The results have shown that *ANN* model has the higher accuracy compared to the *MLR* model. Moreover, variable importance analysis has confirmed that overburden depth has the most and Poisson's ratio has the least effect on the *HDZ*. These results prove that the proposed *ANN* has a good ability in *HDZ* estimation and can be applied in practice with an acceptable reliability.