

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

مقاله پژوهشی

محمد رضائی^{۱*}؛ هادی حائری^۲؛ وهاب سرفرازی^۳

۱- دانشیار؛ دانشکده مهندسی، گروه مهندسی معدن، دانشگاه کردستان، m.rezaei@uok.ac.ir

۲- استادیار؛ بخش مهندسی معدن، مجتمع آموزش عالی زرد، دانشگاه شهید باهنر کرمان، haerihadi@gmail.com

۳- دانشیار؛ گروه مهندسی معدن، دانشگاه صنعتی همدان، vahab.sarfaraizi@gmail.com

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

شماره صفحات: ۱۵۱ تا ۱۶۶

شناسه دیجیتال (DOI): 10.22044/tuse.2025.15173.1491

چکیده

ارتفاع منطقه رها از تنش (HDZ) در سقف پهنه جبهه کار طولانی پارامتر مهمی در تعیین میزان تنش ناشی از استخراج پهنه و بارهای انتقالی به اطراف آن است. لذا تخمین دقیق HDZ به منظور تحلیل تنش در اطراف پهنه، طراحی ایمن سیستم نگهداری ورودی‌ها و پیش‌بینی نشست سطح زمین، ضروری می‌باشد. به منظور 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 معتبر استفاده گردید. پارامترهای ارتفاع روباره، ضخامت لایه زغال‌سنگ استخراجی، وزن مخصوص، مدول الاستیسیته، ضریب پواسون، مقاومت فشاری تک محوری و فاکتور حجمی توده سنگ سقف به عنوان متغیرهای ورودی برای پیش‌بینی HDZ در نظر گرفته شد. در فرآیند ارزیابی مدل‌ها بر اساس داده‌های واقعی، مقادیر ضریب تصمیم‌گیری، میانگین خطای مطلق و میانگین خطای نسبی به ترتیب برای مدل آماری برابر با ۰/۷۷۱/۰۲۲، ۵/۶۶ متر و ۲۰/۴۳٪ و برای شبکه عصبی برابر با ۰/۹۶/۰۰۴، ۲/۵۳ متر و ۷/۳۲٪ به دست آمد. نتایج فوق نشان‌دهنده دقت بیشتر و خطای کمتر شبکه عصبی نسبت به مدل آماری و تطابق بهتر خروجی‌های آن با داده‌های واقعی است. تحلیل حساسیت نتایج مدل آماری نشان داد که وزن مخصوص و ضریب پواسون توده سنگ به ترتیب با مقدار ضریب استاندارد شده ۰/۵۲۴ و ۰/۰۱ بیش‌ترین 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 ۰/۸۷۹ و ۰/۰۸۷۹ دارای بیش‌ترین و کمترین تأثیر بر HDZ هستند.

واژگان کلیدی

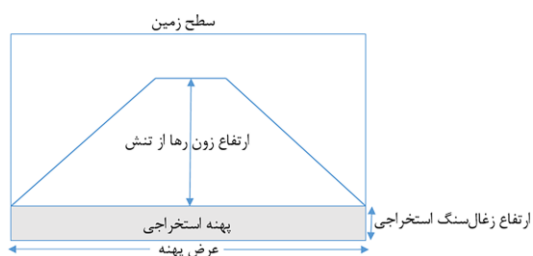
معدنکاری جبهه کار طولانی
منطقه رها از تنش
رگرسیون آماری
شبکه عصبی مصنوعی
تحلیل اهمیت متغیر

۱- مقدمه

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 به سمت

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

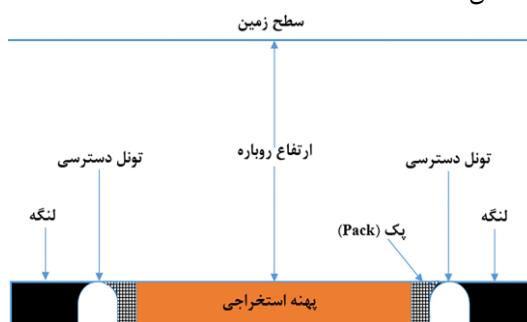
(HDZ) به عنوان معادل ارتفاع ترکیبی مناطق تخریب و شکست در نظر گرفته می‌شود که به صورت شماتیک در شکل ۳، نشان داده شده است. میزان HDZ نقش مهمی در تعیین دقیق میزان بارهای منتقل شده به جلو جبهه کار و اطراف پهنه ایفا می‌کند. فراتر از ارتفاع منطقه رها از تنش، فشار روباره به سمت جلو جبهه کار، دیواره‌های جانبی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




شکل ۳- نمایش شماتیکی منطقه رها از تنش در سقف پهنه استخراجی

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

بالا گسترش می‌یابد که باعث تغییر شکل، شکست و تخریب بیشتر لایه‌های آسیب دیده در سقف پهنه می‌شود. 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 (Zhang et al., 2013; Shun et al., 2013; Gao et al., 2014; Rezaei et al., 2015; Rezaei, 2018; Mohammadi et al., 2016; Abdollahi, et al., 2024; Aghababaei, et al., 2024; Rezaei et al., 2024; Xu et al., 2024). مطابق نتایج تحقیقات فوق، سه منطقه مجزا شامل مناطق تخریب، شکست و تغییر شکل در سقف پهنه استخراجی تشکیل می‌شود که به صورت شماتیک در شکل ۲، نشان داده شده است.



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



شکل ۲- سه منطقه تخریب، شکست و تغییر شکل پیوسته 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

می‌توانند جایگزین‌های مناسبی در این زمینه باشند. شبکه‌های عصبی مصنوعی یکی از پرکاربردترین سیستم‌های هوشمند است که می‌توان از آن برای مدل‌سازی مسائل پیچیده 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). کاربردهای فوق نشان می‌دهد که 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 تعمیم آنها به سایر مطالعات موردی است (Rezaei, 2018). بنابراین، در این تحقیق از روش شبکه عصبی مصنوعی برای تعیین HDZ در سقف پهنه جبهه‌کار 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 می‌شود (Ceryan et al., 2012):

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

که در آن، y متغیر خروجی، a_0 ضریب ثابت معادله و a_1 تا a_n ضرایب مربوط به متغیرهای ورودی x_1 تا x_n است که در مجموع مقدار خروجی معادله را رقم می‌زنند.

(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 رضایت‌بخش نیست. به‌عنوان مثال، روش‌های تجربی را نمی‌توان به‌طور دقیق برای همه شرایط و معادن مختلف تعمیم داد، زیرا 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، اندازه‌گیری‌های برجا و مدل‌های فیزیکی زمان‌بر و پرهزینه هستند. در نهایت مدل‌های تحلیلی با وجود سادگی و ارزان بودن، مبتنی بر مفروضات متعددی هستند که ممکن است خطای تخمین HDZ را افزایش دهد (Rezaei, 2018).


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

منبع	HDZ ($\times h_s$)	مدل / روش مورد استفاده
	۲-۱۰۰	اندازه‌گیری برجا
Rezaei et al., 2015	۲-۱۰۵	مدل تجربی
	۲/۰۲-۵۷/۸	مدل تحلیلی
	۵/۸-۴۷/۶	مدل عددی
Rezaei 2018	۳/۱-۸۶/۵	مدل هوش مصنوعی
	۱۰/۰۲-۴۰/۹۳	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

۲-۱- شبکه عصبی مصنوعی

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., 2018; Rezaei, 2015*) 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 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 مؤثر بر مسئله مورد نظر (هفت متغیر ورودی) و پارامتر خروجی (ارتفاع منطقه رها از تنش) است.



شکل ۴- ساختار شبکه عصبی مصنوعی (*Liu et al., 2021*)

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 مدل‌سازی 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 زغال‌سنگ 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 قبلاً اشاره شد، اندازه‌گیری پارامترهای تاثیرگذار بر ارتفاع منطقه رها از تنش ناشی از روش معدنکاری جبهه‌کار طولانی به‌دلیل محیط پیچیده این روش

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 این شبکه‌ها سه نوع لایه شامل لایه ورودی، لایه(های) 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 می‌گردد (*Demuth et al., 1996*). شبکه عصبی بر اساس داده‌های تجربی، بین ورودی‌ها و خروجی ارتباط برقرار می‌کند. با وارد کردن داده‌های ورودی آموزشی و خروجی‌های متناظر با آن، فرآیند یادگیری شبکه عصبی به‌وسیله الگوریتم‌های آموزش خاص طی شده و جواب‌هایی تولید می‌شود که اغلب دقیق بوده و با شرایط مساله سازگاری دارد. نتایج حاصل از مدل شبکه عصبی با استفاده از شاخص‌های ارزیابی عملکرد مناسب مانند ریشه میانگین مربعات خطا سنجیده شده و با مقادیر واقعی متناظر مقایسه می‌شود. این فرآیند در سیکل‌های مختلف به‌صورت رفت و برگشت تکرار می‌گردد. 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 دقیق و دستیابی به مدل بهینه می‌شود (*Menhaj, 2000; Rezaei, 2020; Rezaei et al., 2024*).

۲-۳- 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

داده‌های آموزش (طراحی) و داده‌های آزمون تقسیم‌بندی 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 به صورت 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 می‌دهد. 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 می‌شود، 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 می‌باشد. البته از کل ۱۲۰ سری داده جمع‌آوری 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 زغال سنگ در چندین برش مختلف است.

بسیار مشکل و پر هزینه است. به همین دلیل در این تحقیق از داده‌های اندازه‌گیری شده در سایر مقالات معتبر استفاده شده است که طبیعتاً در برگزیده تمامی پارامترهای تأثیرگذار بر ارتفاع منطقه رها از تنش نیست. به عنوان مثال، با وجود اینکه پارامترهای شیب لایه و ابعاد پهنه استخراجی متغیرهای تأثیرگذاری بر ارتفاع منطقه رها از تنش در سقف پهنه استخراجی هستند اما به علت کم بودن تعداد داده‌های موجود، در مدل‌سازی ارتفاع منطقه رها از تنش در این تحقیق نادیده گرفته شده‌اند. با این حال، ضخامت لایه استخراجی (ارتفاع معدنکاری) به عنوان 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 جمع‌آوری شده هم زیاد نبوده و فاقد شرایط لازم برای استفاده در الگوریتم‌های هوشمند (مانند شبکه عصبی مصنوعی) به عنوان 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 عصبی به عنوان ورودی در تحقیق حاضر هستند. برای ساخت مدل‌های شبکه عصبی و رگرسیون آماری در این تحقیق، داده‌های جمع‌آوری شده به دو دسته

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

انحراف از معیار	واریانس	بیشینه	کمینه	نماد	پارامتر	نوع داده
۱۱۵/۸۹	۱۳۴۳۱/۵۰	۶۵۰	۱۳۰	H	ارتفاع روباره (متر)	
۲/۰۸	۴/۳۲	۲۸/۳۵	۲۰/۵۰	γ	وزن مخصوص توده سنگ سقف (کیلو نیوتن بر مترمکعب)	
۵/۵۴	۳۰/۶۹	۱۸/۸۵	۱/۱۲	E	مدول الاستیسیته توده سنگ سقف (گیگا پاسکال)	
۰/۰۴	۰/۰۰	۰/۳۳	۰/۱۸	ν	ضریب پواسون توده سنگ سقف (-)	ورودی
۷/۲۴	۵۲/۴۷	۴۰/۵۴	۴/۷۶	σ	مقاومت فشاری تک محوری توده سنگ سقف (مگا پاسکال)	
۰/۱۸	۰/۰۳	۱/۷۳	۱/۰۷	b	فاکتور حجمی توده سنگ سقف (-)	
۵/۲۸	۲۷/۸۶	۶	۱/۷	h	ضخامت لایه زغال سنگ استخراجی (متر)	
۴۲/۷۱	۱۸۲۳/۸۱	۲۴۰	۱۷/۵	HDZ	ارتفاع منطقه رها از تنش (متر)	خروجی

جدول ۳- برخی از داده‌های مورد استفاده در مدل‌سازی HDZ

ردیف	H (متر)	γ (کیلو نیوتن بر متر مکعب)	E (گیگاپاسکال)	ν (-)	σ (مگاپاسکال)	b (-)	h (متر)	HDZ (متر)
۱	۱۳۰	۲۵	۱۶/۹۱	۰/۲۷	۱۸/۱۳	۱/۵	۲/۴۴	۷۹
۲	۴۴۰	۲۷	۶/۴۶	۰/۳۰	۹/۷۴	۱/۶۵	۴/۵	۱۱۲
۳	۲۹۰	۲۷	۳/۵	۰/۲۲	۹/۲۳	۱/۴	۳	۲۴۰
۴	۲۵۰	۲۵/۵۷	۱/۹۲	۰/۲۹	۱۱/۸۲	۱/۵۱	۳/۸	۱۷۷
۵	۳۴۰	۲۱/۲۵	۳/۳۸	۰/۲۶	۱۲/۸۴	۱/۲۸	۲	۲۸
۶	۲۱۰	۲۴	۱/۱۲	۰/۲۴	۵/۲۱	۱/۵	۱/۷	۴۳/۵
۷	۶۵۰	۲۸/۱۴	۱۷/۷۱	۰/۲۱	۲۴/۲۰	۱/۶۵	۶	۹۷
۸	۵۲۵	۲۸/۳۵	۱۸/۸۵	۰/۱۹	۳۷/۱۲	۱/۲۶	۴/۵	۱۹
۹	۱۶۳	۲۰/۵۰	۳/۸۶	۰/۲۸	۴/۷۶	۱/۰۷	۳	۶۵
۱۰	۵۰۰	۲۷	۱۷/۹۵	۰/۱۸	۳۵/۳۵	۱/۲	۴/۲۵	۱۷/۵

۳- مدل‌سازی ارتفاع HDZ

۳-۱- مدل‌سازی با استفاده از رگرسیون آماری

به منظور 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 (γ)، مدول الاستیسیته (E)، ضریب پواسون (ν)، مقاومت فشاری تک محوری (σ)، فاکتور حجمی (b) و ضخامت لایه زغال‌سنگ استخراجی (h) در جدول ۴، نشان داده شده است. بر اساس ضرایب فوق، می‌توان HDZ را بر اساس مقادیر 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) به دست آمده در جدول ۴، می‌توان نتیجه گرفت که دو پارامتر وزن مخصوص لایه‌های سقف و ضخامت لایه زغال‌سنگ

استخراجی دارای بیش‌ترین تأثیر بر HDZ هستند. به‌طور کلی، هر دو پارامتر تأثیر قابل توجهی بر HDZ دارند ولی تأثیر وزن مخصوص توده‌سنگ سقف در این تحقیق نسبتاً بیشتر از تأثیر ضخامت لایه زغال‌سنگ استخراجی است. از طرف دیگر، ضریب پواسون توده‌سنگ سقف دارای کمترین تأثیر بر HDZ است.

در مورد نتیجه آنالیز حساسیت در مدل آماری دو نکته قابل ذکر است. اول اینکه داده‌های جمع‌آوری شده از منابع مختلف و مربوط به معادن گوناگون است که تنوع و تغییرات پارامترهای ورودی زیاد بوده و می‌تواند در برخی از موارد جهت‌گیری تأثیر پارامترهای ورودی بر خروجی را تغییر دهد که ممکن است با نتیجه مورد انتظار در یک مطالعه موردی خاص متمایز باشد. دوم اینکه این نتیجه 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 زغال‌سنگ استخراجی نقش مهمی در میزان HDZ ایفا کرده و دارای رابطه مستقیم با این پارامتر می‌باشد. بنابراین، می‌توان نتیجه گرفت که نتایج مدل آماری قابل قبول بوده و تا حدودی با واقعیت‌های معدنکاری جبهه کار طولانی منطبق است.

جدول ۴- خروجی مدل آماری در مدل‌سازی HDZ

مقدار مدل R	ضریب استاندارد شده (Beta)	ثابت/ضریب	متغیر پیش‌بینی کننده
	-----	-۱۳۸/۹۶۴	مقدار ثابت
	-۰/۰۷۶	-۰/۰۲۸	H
	۰/۵۲۴	۱۰/۷۶۹	γ
۰/۸۷۸	-۰/۱۰۳	-۰/۷۹۳	E
	۰/۰۱	۱۱/۳۰۱	v
	-۰/۲۵۶	-۱/۵۶۳	σ
	-۰/۰۶۲	-۱۴/۷۳۷	b
	۰/۴۱۷	۰/۷۳۹	h

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.

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

در رابطه شماره (۲)، A_{imeas} ، A_{ipred} و n به‌ترتیب آامین مقدار اندازه‌گیری شده، آامین مقدار پیش‌بینی شده و تعداد مجموعه‌های داده هستند.

۳-۲- مدل‌سازی با استفاده از شبکه عصبی

برای دستیابی به شبکه عصبی بهینه به‌منظور پیش‌بینی HDZ در سقف پهنه جبهه‌کار 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 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

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

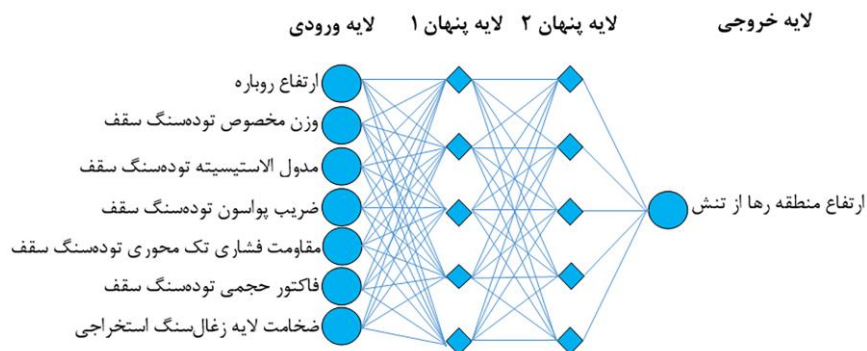
شماره	ساختار شبکه	تابع انتقال	تابع آموزش	RMSE
۱	۷-۱۰-۱	لگاریتم سیگنویید	لونیبرگ-مارکوارت	۰/۰۱۲۱
۲	۷-۱۰-۱	تانژانت سیگنویید	گرادیان نزولی	۰/۰۲۶۷
۳	۷-۲-۸-۱	تانژانت سیگنویید	گرادیان نزولی	۰/۰۰۹۸
۴	۷-۸-۲-۱	سیگنویید	لونیبرگ-مارکوارت	۰/۰۰۸۶
۵	۷-۷-۳-۱	تانژانت سیگنویید	گرادیان نزولی	۰/۰۰۸۲
۶	۷-۳-۷-۱	سیگنویید	گرادیان نزولی	۰/۰۰۷۸
۷	۷-۵-۵-۱	سیگنویید	لونیبرگ-مارکوارت	۰/۰۰۴۸
۸	۷-۵-۵-۱	تانژانت سیگنویید	لونیبرگ-مارکوارت	۰/۰۰۵۸
۹	۷-۴-۶-۱	تانژانت سیگنویید	لونیبرگ-مارکوارت	۰/۰۰۷۶
۱۰	۷-۶-۴-۱	سیگنویید	گرادیان نزولی	۰/۰۰۶۴

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

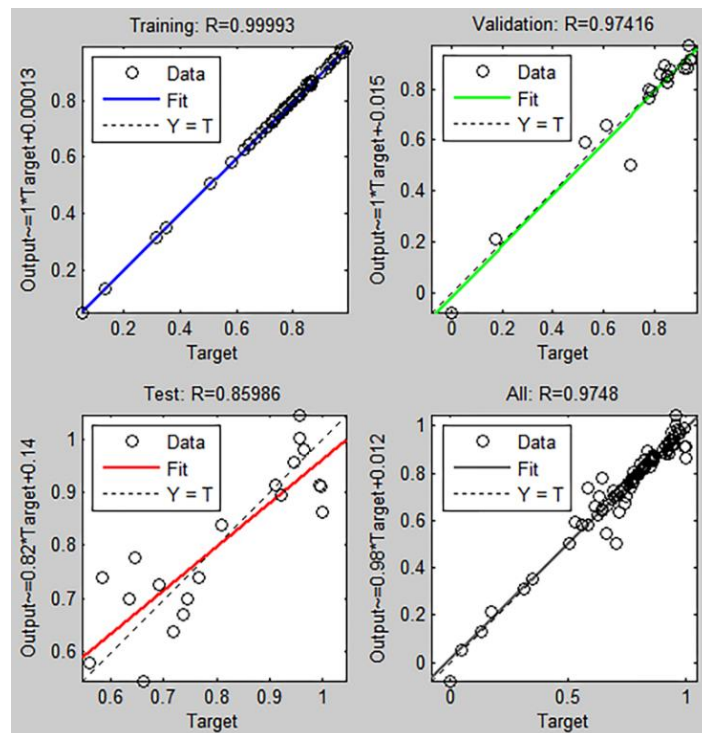
همانطور که در جدول ۵، مشاهده می‌شود، شبکه

ارزیابی شبکه عصبی در نظر گرفته می‌شود. 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 می‌شود، مقدار R حاصله در مراحل آموزش، اعتبارسنجی و آزمون بالا است که نشان‌دهنده دقت بالای مدل شبکه عصبی پیشنهادی می‌باشد.

۷-۵، تابع آموزش لونیگ-مارک کوادرت ($TRAINLM$) 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. به منظور کنترل عملکرد شبکه در مرحله آموزش، ضریب همبستگی (R) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده HDZ به‌عنوان معیار



شکل ۵- ساختار شبکه عصبی پیشنهادی برای تخمین HDZ




شکل ۶- نتایج مدل شبکه عصبی بهینه پیشنهادی به منظور تخمین HDZ

شده به ترتیب در شکل ۷ و شکل ۸، نمایش داده شده است. همانطور که در جدول ۶، شکل ۷ و شکل ۸، مشاهده می‌شود، مقدار ضریب تصمیم‌گیری حاصل از مدل‌های آماری و شبکه عصبی به ترتیب برابر با ۷۷/۲۲ و ۹۶/۰۴ به دست آمده است که نشان‌دهنده دقت بالاتر شبکه عصبی نسبت به مدل آماری است.


جدول ۶- نتایج شاخص‌های عملکرد مدل‌های رگرسیون

آماری و شبکه عصبی به منظور پیش‌بینی HDZ

شاخص	مدل شبکه عصبی	مدل رگرسیون آماری
R^2 (%)	۹۶/۰۴	۷۷/۲۲
E_a (متر)	۲/۵۳	۵/۶۶
E_r (%)	۷/۳۲	۲۰/۴۳



شکل ۷- مقایسه HDZ حاصل از مدل رگرسیون آماری با مقادیر واقعی



شکل ۸- مقایسه HDZ حاصل از مدل شبکه عصبی مصنوعی با مقادیر واقعی

به منظور بررسی انطباق نتایج حاصل از مدل‌های مورد استفاده با داده‌های واقعی، مقایسه بین خروجی حاصل از مدل‌های رگرسیون آماری و شبکه عصبی با مقادیر واقعی

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 تصمیم‌گیری (R^2)، میانگین خطای مطلق (E_a) و میانگین خطای نسبی (E_r) در این تحقیق استفاده شده است. در حالت کلی، عملکرد یک مدل زمانی ایده‌آل است که مقادیر E_a و E_r برابر با صفر و R^2 برابر با ۱ یا ۱۰۰٪ باشد. بنابراین، مقدار بالاتر R^2 و پایین بودن مقادیر E_a و E_r نشان‌دهنده مطلوب بودن مدل و عملکرد قابل قبول آن در تخمین مقدار HDZ است. ضریب تصمیم‌گیری (R^2)، میانگین خطای مطلق (E_a) و میانگین خطای نسبی (E_r) به ترتیب با استفاده از روابط (۳) تا (۵) محاسبه می‌شوند (Asadizadeh & Rezaei, 2021; Rajabi et al., 2021; Rezaei & Rajabi, 2021; Wang et al., 2023).

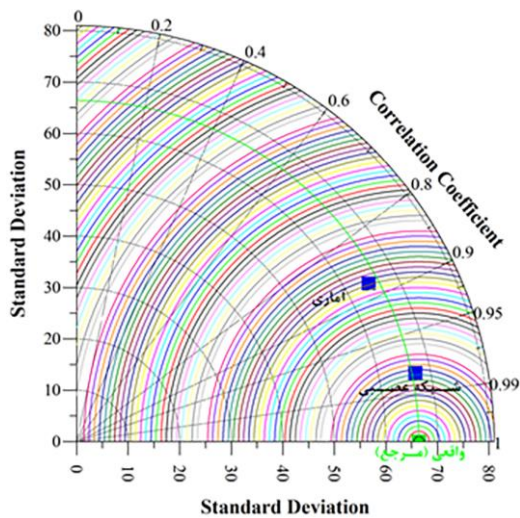
$$R^2 = \frac{\left[\sum_{i=1}^n (A_{ipred} - \bar{A}_{pred})(A_{imeas} - \bar{A}_{meas}) \right]^2}{\left[\sum_{i=1}^n (A_{ipred} - \bar{A}_{pred})^2 \sum_{i=1}^n (A_{imeas} - \bar{A}_{meas})^2 \right]} \quad (3)$$

$$E_a = |A_{imeas} - A_{ipred}| \quad (4)$$

$$E_r = \left(\frac{|A_{imeas} - A_{ipred}|}{A_{imeas}} \right) \times 100 \quad (5)$$

که در آن، A_{imeas} نامین مقدار اندازه‌گیری شده، A_{ipred} نامین مقدار پیش‌بینی شده، n تعداد مجموعه‌های داده و \bar{A}_{imeas} و \bar{A}_{ipred} به ترتیب میانگین مقادیر اندازه‌گیری شده (واقعی) و پیش‌بینی 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 به دست 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 اندازه‌گیری




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 با در نظر گرفتن پارامترهای ورودی بیشتر در مدل‌سازی و افزایش تعداد سری‌های داده، قابلیت اطمینان و تعمیم‌پذیری در استفاده عملی از این مدل‌ها در معدنکاری جبهه‌کار 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


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 HDZ 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 HDZ 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 شبیه‌سازی هر دو مدل نسبتاً نزدیک به نقطه مشاهده شده (داده واقعی) هستند که نشان‌دهنده شباهت در انحراف استاندارد، همبستگی بالا (ضریب همبستگی ۰/۸۷۸۷ برای مدل آماری و ۰/۹۶ برای شبکه عصبی) و خطای کم در پیش‌بینی HDZ است. با این حال، فاصله نقطه شبیه‌سازی مدل آماری از نقطه مرجع در مقایسه با مدل شبکه عصبی تا حدودی بیشتر است که نشان‌دهنده عملکرد پایین‌تر 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 ۱۱- مقادیر اهمیت متغیرهای ورودی در مدل‌سازی HDZ با استفاده از شبکه عصبی

۶- نتیجه‌گیری

در این تحقیق از مدل‌های رگرسیون آماری چند متغیره و شبکه عصبی مصنوعی برای تعیین HDZ در سقف پهنه جبهه‌کار 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 بوده و خروجی‌های حاصل از آن تطابق بهتری با HDZ 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.
- نتایج مدل آماری نشان داد که γ دارای بیش‌ترین تأثیر و v دارای کم‌ترین تأثیر بر HDZ است.
- تحلیل اهمیت متغیر نتایج حاصل از شبکه عصبی نشان داد که متغیرهای H و v به‌ترتیب بیش‌ترین و کم‌ترین تأثیر را بر HDZ دارند.
- مهم‌ترین مزیت تحقیق فعلی نسبت به مطالعات قبلی،

استفاده قرار می‌گیرد (Rezaei et al., 2023). با توجه به اینکه مدل شبکه عصبی در این تحقیق از مدل رگرسیون آماری مطابق جدول ۶، دقیق‌تر است، لذا تحلیل اهمیت متغیرها بر روی نتایج مدل شبکه عصبی انجام می‌شود. در این تحقیق، بررسی اهمیت ورودی‌ها بر مقدار HDZ با استفاده از نرم‌افزار Statistica انجام شده است. در محیط نرم‌افزار فوق، مقادیر اهمیت ورودی‌ها در بازه ۰ و ۱ محاسبه و سازماندهی می‌شود. در این روش، هرچه مقدار به‌دست آمده برای یک پارامتر بیش‌تر و به ۱ نزدیک‌تر باشد نشان‌دهنده اهمیت بیش‌تر آن متغیر بر خروجی است. بر این اساس، مقدار اهمیت هفت متغیر ورودی بر HDZ محاسبه شده و در شکل ۱۱، نشان داده شده است. همانطور که مشاهده می‌شود، ارتفاع روباره و ضریب پواسون به‌ترتیب بیش‌ترین و کم‌ترین تأثیر را بر HDZ دارند.

پارامتر ارتفاع یا عمق روباره که بر اساس تحلیل اهمیت متغیر دارای بیش‌ترین تأثیر بر HDZ است، ذاتاً 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 تغییرات زیاد ارتفاع روباره است لذا به‌دست آمدن چنین نتیجه‌ای می‌تواند قابل قبول باشد. با این حال، این نتیجه ممکن است با نتایج حاصل از یک معدن خاص با شرایط متفاوت، همسو نباشد. از طرف دیگر، ارتفاع روباره به خودی خود پارامتر مهمی در میزان HDZ در سقف پهنه استخراجی است. به‌طور 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 تعیین‌کننده‌ای در میزان HDZ است که می‌تواند تأیید‌کننده نتیجه تحلیل اهمیت متغیر در این بخش و نشان‌دهنده نزدیک بودن نتایج حاصله به واقعیت‌های موجود در محیط معدنکاری جبهه‌کار 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.

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 تعمیم‌پذیری بیشتر مدل و استفاده عملی از آن کمک می‌نماید. علاوه، می‌توان از الگوریتم‌های هوشمند جدید به‌ویژه الگوریتم‌های ترکیبی برای تخمین HDZ استفاده و نتایج حاصل از آنها را با نتایج تحقیق فعلی و سایر تحقیقات مشابه مقایسه نمود.

در نظر گرفتن پارامترهای 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 تعمیم‌پذیری 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>
- Asadzadeh, 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 distressed 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 distressed 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 Distressed 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>

- 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 distressed 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 distressed 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 water-conducting 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>

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

M. Rezaei^{1*}; 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

Longwall mining
Height of distressed zone
Statistical regression
Artificial neural network
Variable importance analysis

Extended Abstract

Summary

To determine the height of distressed zone (*HDZ*) in this study, multivariate linear regression (*MLR*) and artificial neural network (*ANN*) models have been used and the obtained results have been compared with each other and 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 distressed 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., in-situ 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.