



## ۱- مقدمه

در اعماق زیاد زمین، متداول ترین روش استخراج زیرزمینی لایه‌های زغال سنگ، روش جبهه کار طویل است. کنترل پایداری سقف و ساختارهای زیرزمینی و همچنین تضمین ایمنی و پایداری فرآیند استخراج در روش جبهه کار طویل، از دغدغه‌های اساسی مهندسان معدن به شمار می‌آید [۱]. در این روش، پس از برداشت لایه زغال سنگ در یک عرض پهنه مشخص، پیشروی جک‌های هیدرولیکی موجب تخریب لایه‌های بلاواسطه سقف پهنه می‌شود و به تدریج این تخریب به لایه‌های فوقانی گسترش می‌یابد. با ادامه عملیات استخراج و پیشروی بیشتر جک‌ها، این روند تا نزدیکی سطح زمین نیز امتداد می‌یابد [۲].

پیامدهای این فرآیند شامل تغییر الگوی تنش‌های زمین و توزیع مجدد آن‌ها بر پایه‌های حائل مجاور و تونل‌های دسترسی به سینه کار، و نیز بروز نشست سطح زمین است که می‌تواند آسیب‌هایی به سازه‌های سطحی و زیر سطحی که در مجاورت پهنه استخراجی قرار دارند، وارد نماید. نشست سطح زمین، مؤلفه قائم جابجایی نقاط سطح زمین است که به صورت کاهش ارتفاع و فرورفتگی در سطح زمین نسبت به وضعیت اولیه ظاهر می‌شود. در راستای تحلیل پدیده نشست سطح زمین، از روش‌های گوناگونی همچون مدل‌های تجربی، توابع پروفیل و تأثیر، مدل‌سازی فیزیکی و تحلیل‌های عددی بهره گرفته می‌شود. تمرکز این رویکردها بر درک رفتار تغییر شکل لایه‌های زمین و تعیین عوامل مؤثر بر شکل‌گیری پروفیل نشست است. این پروفیل معمولاً به صورت یک منحنی زنگ‌مانند در سطح ظاهر می‌شود که بیشترین مقدار آن، موسوم به حداکثر نشست ( $S_{max}$ )، در مرکز پروفیل نشست قرار دارد و به عنوان یکی از مهم‌ترین شاخص‌های ارزیابی اثرات استخراج زیرزمینی شناخته می‌شود. با توجه به اهمیت  $S_{max}$  در تحلیل و ارزیابی مخاطرات ناشی از نشست سطح زمین، در این مقاله تلاش شده است تا با توسعه یک مدل ترکیبی مبتنی بر روش‌های هوش مصنوعی و یک مدل آماری، پیش‌بینی دقیقی از این پارامتر ارائه شود.

## ۲- مروری بر ادبیات پژوهش

اولین مطالعات جامع در حوزه بررسی نشست سطح زمین ناشی از استخراج پهنه‌های جبهه کار طویل توسط انجمن

زغال سنگ انگلستان [۳] بین سال‌های ۱۹۵۰ تا ۱۹۷۵ انجام شد که حاصل آن تدوین نمودارهایی برای پیش‌بینی حداکثر نشست سطح زمین بر اساس پارامترهای هندسی پهنه‌های استخراجی مانند ضخامت لایه زغال سنگ ( $h_s$ )، عمق روباره ( $H$ ) و عرض پهنه ( $L_w$ ) بود. پس از آن، مانسون و ایچفُلد [۴] با بررسی داده‌های نشست سطح زمین در معدن *York Canyon* در نیومکزیکو آمریکا، روش‌های تجربی رایج در معادن اروپا برای توصیف شکل پروفیل نشست را ارزیابی کردند و دریافتند که توابع پروفیل استفاده‌شده در اروپا تطابق خوبی با داده‌های میدانی دارند.

کارمیس و همکاران [۵] براساس داده‌های میدانی از معادن انگلستان، یک رابطه تجربی مبتنی بر پارامترهای هندسی برای پیش‌بینی حداکثر نشست سطح زمین ( $S_{max}$ ) ارائه دادند. ون در مروه [۶] نیز با تحلیل داده‌های برج، مدلی معرفی کرد که افزایش ضخامت لایه زغال سنگ و نسبت عرض به عمق پهنه را با افزایش میزان نشست حداکثری سطح زمین مرتبط می‌داند. پنگ و همکاران [۷] و همچنین لیو و پنگ [۸] روابطی تجربی ارائه دادند که نقش پارامترهای عمق و ضخامت لایه‌های استخراجی را در شدت نشست به صورت غیرخطی نشان می‌دادند. در ادامه، کوی و همکاران [۹] با استفاده از تابع زمانی *Knothe* و روش انتگرال‌گیری احتمالاتی، مدلی برای پیش‌بینی نشست تدریجی سطح زمین ارائه کردند و آن را در معدن *Qianjiaying* چین اعتبارسنجی نمودند. آلواریز فرناندز و همکاران [۱۱] با توسعه تابع تأثیر  $n-k$  تابع جدید  $n-k-g$  را معرفی کردند که با در نظر گرفتن پارامترهای هندسی و گرانشی، انطباق بیشتری با شکل واقعی پروفیل نشست نشان می‌داد و با نتایج بدست آمده از نرم‌افزار *FLAC* همخوانی مناسبی داشت. اسدی و همکاران [۱۱] تابع پروفیل جدیدی را برای پیش‌بینی نشست ناشی از استخراج لایه‌های شیب‌دار معرفی کردند و سپس عملکرد مناسب آن را با داده‌های میدانی تأیید نمودند.

کیلش و همکاران [۱۲] با بهره‌گیری از نرم‌افزار *UDEC*، مدلی برای پیش‌بینی نشست در نواحی ناهموار بالا و مجاور پهنه‌های استخراجی توسعه دادند که با داده‌های تجربی سازگاری مناسبی داشت. گنزالز نیسیزا و همکاران [۱۳] با استفاده از توابع *Knothe* و *Sroka-Schobe*، تابع زمانی جدیدی مبتنی بر توزیع نرمال معرفی کردند که الگوی نشست

متفاوت نشست در معادن اندونزی با روبراه‌ی ضعیف و مرطوب را نسبت به سایر کشورها تحلیل کردند. غبرایی و همکاران [۲۵] با مدل‌سازی فیزیکی و عددی نشست حاصل از استخراج پهنه‌های چندلایه جبهه‌کار طولیل در معادن استرالیا، کارایی ترکیب دو روش را در تحلیل دقیق‌تر نشان دادند. سوخوورسکا ایوانک و همکاران [۲۶] دریافتند که استفاده از قوانین پیچیده رفتاری در روش المان محدود (*FEM*) برای پیش‌بینی نشست سطح زمین ناشی از استخراج پهنه‌های جبهه‌کار طولیل لزوماً دقت پیش‌بینی را افزایش نمی‌دهد. ژانگ و همکاران [۲۷] نشست سطح زمین و خطر فرونشست در نواحی با پوشش آبرفتی ضخیم در منطقه یونگ‌چنگ چین را ارزیابی کرده و نشست‌هایی تا ۶ متر را گزارش کردند. فتحی سلمی و همکاران [۲۸] تأثیر نشست معدن بر پایداری دامنه‌ها را با مدل‌سازی عددی بررسی کردند و به مکانیزم گسیختگی‌های برشی و کششی اشاره نمودند.

غبرایی و همکاران [۲۹] با تحلیل داده‌های میدانی نشست معادن جبهه‌کار طولیل چندلایه در استرالیا، روش اصلاح‌شده تابع اثر گسسته (*Discrete-IFM*) را توسعه دادند که قابلیت تفکیک پروفیل نشست در نواحی مختلف را داشت. پونگ‌پانیا و همکاران [۳۰] با استفاده از نرم‌افزار *FLAC3D* نشست ناشی از استخراج در شرایط ضعیف زمین در اندونزی را بررسی کردند و نشان دادند که پارامترهایی مانند عمق استخراج و عرض پهنه تأثیر زیادی بر زاویه کشش و نشست دارند. چنگ و همکاران [۳۱] یک رابطه تجربی برای پیش‌بینی حداکثر نشست سطح زمین و لایه‌های زیرسطحی براساس عمق روبراه و ضخامت لایه استخراجی ارائه دادند. هی و شو [۳۲] با مدل‌سازی لایه‌های کلیدی واقع در روبراه به‌صورت تیر قوسی، روابطی برای پیش‌بینی نشست سطح زمین ارائه کردند و نشان دادند که میزان نشست سطح زمین به موقعیت لایه کلیدی وابسته است. ژانگ و همکاران [۳۳] با پایش نشست ناشی از استخراج لایه بالایی و به‌کارگیری تحلیل معکوس و شبیه‌سازی عددی، مدلی توسعه دادند که ضمن پیش‌بینی نشست سطح زمین در استخراج دولایه‌ای با دقت قابل قبول، قابلیت کاربرد در معادن با شرایط زمین‌شناسی مشابه را داشت.

چوی و همکاران [۳۴] مدلی را توسعه دادند که به تحلیل مدت‌زمان تداوم نشست باقیمانده و تأثیر آن در طول زمان

سطح زمین را دقیق‌تر نمایش می‌داد. لو و چنگ [۱۴] نیز مدلی مبتنی بر تابع تأثیر برای پیش‌بینی پروفیل نشست سطح زمین در پهنه‌های شیب‌دار ارائه دادند. شهریار و همکاران [۱۵] با استفاده از نرم‌افزار *FLAC3D* و تحلیل پارامتریک، موقعیت نشست حداکثری سطح زمین را در سمت صعودی پهنه‌های کم‌عمق معدن پروده طبس پیش‌بینی کردند. گوتیرز [۱۶] با استفاده از داده‌های میدانی و الگوریتم ژنتیک، مدلی سه‌بعدی برای پیش‌بینی نشست سطح زمین ناشی از استخراج دو معدن جبهه‌کار طولیل که در زیر مسیر عبور بزرگراه *I-79* در پنسیلوانیا قرار داشتند، ارائه داد. نتایج یافته‌های او نشان داد که شرایط هندسی پیچیده سازه‌های سطحی، دقت روابط تجربی را محدود کرده و نیاز به استفاده از روش‌های عددی مانند *FEM* را افزایش می‌دهد.

لی و همکاران [۱۷] با استفاده از نظریه احتمال فازی و توابع عضویت نامتقارن، مدلی دوبعدی برای نشست سطح زمین ناشی از استخراج لایه‌های شیب‌دار توسعه دادند که با داده‌های میدانی تطابق مطلوبی داشت. سونگ و همکاران [۱۸] با تحلیل همبستگی خاکستری (*Grey Correlation Analysis*) در ناحیه یو-شن-فو چین، تأثیر پارامترهایی مانند ضخامت روبراه، ضریب اغتشاش و نسبت ضخامت استخراج را بر فاکتور نشست حداکثری سطح زمین بررسی کردند. لو و کیو [۱۹] نرم‌افزاری به نام *CISPM-MS* برای پیش‌بینی نشست نهایی و تغییرشکل لایه‌های فوقانی پهنه توسعه دادند و با داده‌های میدانی آن را اعتبارسنجی کردند.

شو و همکاران [۲۰] با بکارگیری روش تفاضل محدود (*FDM*) به ارزیابی اثرات نشست ناشی از استخراج پهنه‌های جبهه‌کار طولیل معدن *Wutong* بر سد مجاور آن پرداختند. گو و همکاران [۲۱] با بهره‌گیری از تئوری ارتفاع معادل استخراج، روشی برای پیش‌بینی نشست در معادن جبهه‌کار طولیل با پرشدگی پیشنهاد دادند و بر اساس اطلاعات میدانی معدن *Huayuan* چین، آن را اعتبارسنجی کردند. رن و همکاران [۲۲] نیز روش تعمیم‌یافته تابع تأثیر را برای شرایط پیچیده چندلایه ارائه دادند. هاوولدر و حسن [۲۳] با تحلیل پارامتریک در معدن *Barapukuria* بنگلادش نشان دادند که زاویه‌ی تأثیر (زاویه تعیین‌کننده محدوده نشست سطح زمین) و عمق استخراج نقش مهمی در الگوی نشست دارند.

ساسائوکا و همکاران [۲۴] با بررسی داده‌های میدانی، رفتار

*Hujierte* واقع در چین، ویژگی‌های نشست سطح زمین ناشی از استخراج لایه‌های زغال سنگ در اعماق زیاد را بررسی کردند. آن‌ها با استفاده از توزیع  $t$ ، روشی برای پیش‌بینی نشست سطح زمین ارائه دادند که در نواحی لبه گودی نشست، دقت بالاتری نسبت به روش انتگرال احتمالاتی داشت.

در ادامه، ونگ و همکاران [۴۱] با تاکید بر نقش لایه‌ی کلیدی اولیه در روباره، مدلی برای پیش‌بینی نشست سطح زمین ارائه دادند که داده‌های حاصل از آن با اطلاعات میدانی معدن تینگ‌نان چین همخوانی مناسبی داشت. آن‌ها به این نتیجه رسیدند که سختی خمشی لایه‌های کلیدی و شرایط سنگ‌های مجاور بر نحوه‌ی توزیع نشست سطح زمین تأثیر معناداری دارد. در پژوهشی دیگر، خانال و همکاران [۴۲] با بهره‌گیری از مدل‌سازی عددی، اثر عرض پهنه و ضخامت لایه استخراجی را در یک معدن با عمق یک کیلومتر مورد بررسی قرار دادند و دریافتند که افزایش این پارامترها منجر به بزرگ‌تر شدن زون تخریب در سقف پهنه و افزایش نشست در سطح زمین می‌شود. طاهر دیتو و همکاران [۴۳] از روش المان محدود برای پیش‌بینی تغییر شکل‌های سطحی در استخراج جبهه‌کار طولی استفاده کردند و نشان دادند که دقت این روش در پیش‌بینی جابه‌جایی‌ها بالا بوده و نرخ استخراج نقش کلیدی در تعیین میزان نشست دارد. دیدل و همکاران [۴۴] برای تحلیل نشست نهایی و دینامیکی از تابع تأثیر *Knothe* بهره گرفتند و با کالیبره کردن مدل بر اساس داده‌های واقعی، نشان دادند که شرایط محلی ممکن است به‌طور معناداری با پارامترهای منطقه‌ای تفاوت داشته باشد و عواملی مانند موقعیت نسبت به لبه‌ی پهنه و شرایط زمین‌شناسی نقش تعیین‌کننده دارند.

در ادامه، مالدونادو و همکاران [۴۵] نشست دینامیکی سطحی را با استفاده از نرم‌افزار *SDPS* تحلیل کرده و دریافتند که پارامترهایی همچون فاصله از لبه و زمان‌بندی استخراج، در دقت نتایج تأثیر زیادی دارند. لیو و همکاران [۴۶] با استفاده از مدل بلوک پیوندی در نرم‌افزار *3DEC*، تأثیر تنش افقی و جدایش لایه‌های فوقانی را در بازنمایی بهتر روند خمش و نشست بررسی کردند و نشان دادند که لحاظ کردن لایه‌بندی زمین نقش مهمی در شبیه‌سازی واقع‌گرایانه نشست دارد. چنگ و همکاران [۴۷] به بررسی اثر اشباع‌بودن سنگ‌های روباره بر شدت نشست سطح زمین پرداختند و نتیجه گرفتند

پس از استخراج به روش جبهه‌کار طولی می‌پردازد. یافته‌های آن‌ها حاکی از آن بود که با افزایش ضخامت لایه‌ی استخراجی و مقدار نهایی نشست، مدت‌زمانی که زمین در حالت ناپایدار باقی می‌ماند، افزایش می‌یابد. در مطالعه‌ی دیگر، ژئو و همکاران [۳۵] از رهیافت تئوریک و شبیه‌سازی عددی برای بررسی نقش خمش لایه‌های سنگی بالادست و تأثیر خصوصیات ژئومکانیکی نهشته‌های آبرفتی در نزدیکی سطح بهره‌گرفتند. آن‌ها مدلی ترکیبی ارائه دادند که مکانیزم‌های نشست ناشی از خمش سنگ بستر و تغییر شکل آبرفت را به صورت یکپارچه توصیف می‌کرد. تحلیل‌ها نشان داد که افزایش ضخامت آبرفت منجر به افزایش نشست سطح زمین می‌شود، در حالی که پارامترهایی نظیر زاویه اصطکاک داخلی و چسبندگی، اثر معکوسی بر آن دارند.

شو و همکاران [۳۶] با پایش میدانی نشست ناشی از استخراج جبهه‌کار طولی در معدن شن‌دوونگ چین، ویژگی‌های دینامیکی نشست سطح زمین در شرایط استخراج با سرعت پیشروی بالا را تحلیل کردند و نشان دادند که نسبت عرض پهنه به عمق استخراج، حضور فضاهای خالی در روباره و ناپایداری پایه‌های زغالی تأثیر قابل‌توجهی بر میزان و گستره‌ی نشست سطح زمین دارند. پان و همکاران [۳۷] با استفاده از نظریه لایه کلیدی، مدلی برای شناسایی آغاز نشست زیربرحانی در استخراج عمیق بدون پایه توسعه دادند که نشان می‌داد شکست یکپارچه لایه کلیدی اولیه (*PKS*) بالای دو پهنه مجاور، عامل تأثیرگذار بر نشست زیربرحانی است. یِن و همکاران [۳۸] با تحلیل داده‌های میدانی از ناحیه استخراجی *Fengfeng* در چین، یک رابطه تجربی مبتنی بر تابع بولتزمن برای پیش‌بینی حداکثر نشست سطح زمین ارائه دادند. نتایج آن‌ها نشان داد که میزان حداکثر نشست به‌طور مستقیم با ضخامت لایه زغال سنگ و نسبت عرض پهنه استخراجی به عمق روباره مرتبط است. پاراکاش و همکاران [۳۹] با تمرکز بر معدن آدریالای هند، ویژگی‌های نشست ناشی از استخراج زیرزمینی را بررسی کرده و نشان دادند که پروفیل نشست عمدتاً متقارن است، ولی در سمت شیب‌دار پهنه با زاویه کشش بالاتری ظاهر می‌شود؛ همچنین مشخص شد که این زاویه رابطه‌ی نزدیکی با سرعت پیشروی جبهه‌کار استخراجی دارد. یِن و همکاران [۴۰] با تحلیل داده‌های مشاهداتی حرکت سطحی در معدن جبهه‌کار طولی

زمین در مرکز پهنه‌های استخراجی و در فاصله حدود ۱۲۰ متری از سینه‌کار رخ می‌دهد. مرور جامع مطالعات پیشین نشان می‌دهد که تحلیل نشست سطح زمین ناشی از استخراج پهنه‌های جبهه‌کار طولیل عمدتاً از طریق رویکردهای عددی، تجربی یا روش‌های کیفی صورت گرفته است. در میان این مطالعات، روابط تجربی موجود (جدول ۱)، اغلب تنها بر اساس متغیرهای هندسی مانند ضخامت لایه استخراجی، ارتفاع روباره و عرض پهنه هستند؛ زیرا این پارامترها نقش پررنگی در شکل‌گیری نشست ایفا می‌کنند و به‌طور معمول در داده‌های میدانی ثبت می‌شوند. اگرچه مدل‌سازی عددی قابلیت‌های بالایی در شبیه‌سازی دقیق رفتار زمین دارد، اما کاربرد آن در عمل با محدودیت‌هایی نظیر نیاز به تعیین مجموعه‌ای از پارامترهای ورودی متعدد همراه است؛ پارامترهایی که در بسیاری از موارد فقط از طریق تخمین یا مفروضات قابل دسترسی‌اند، و همین موضوع می‌تواند سبب وابستگی زیاد نتایج به ویژگی‌های خاص هر پروژه شود. افزون بر این، با توجه به پیچیدگی‌های زمین‌شناختی و ساختاری در معادن جبهه‌کار طولیل، تاکنون مدل‌های تحلیلی اندکی برای پیش‌بینی دقیق نشست در این شرایط خاص توسعه یافته‌اند. همچنین، روش‌های مبتنی بر یادگیری ماشین و هوش مصنوعی، علیرغم ظرفیت بالای خود، هنوز در این زمینه به‌صورت خاص و هدفمند مورد استفاده قرار نگرفته‌اند.

که نادیده‌گرفتن اثر تضعیف‌کنندگی آب بر خواص مکانیکی لایه‌ها می‌تواند به تخمین‌های نادقیق منجر شود. رسولی و همکاران [۴۸] با استفاده از الگوریتم برنامه‌ریزی بیان ژن رابطه‌ای برای تعیین نشست سطح زمین در معادن استرالیا ارائه دادند. یافته‌های آن‌ها نشان داد که عرض پهنه و عمق روباره به ترتیب مهمترین پارامترهای تأثیرگذار بر نشست سطح زمین هستند. خطیابی و شهریار [۴۹] با بهره‌گیری از مدل‌سازی عددی در محیط نرم‌افزار *FLAC2D*، به بررسی نشست ناشی از استخراج لایه‌های کم‌عمق و شیب‌دار معدن معدنچو در منطقه زغالی پروده ۳ طبس پرداختند. نتایج حاصل از این مطالعه، بیانگر آن است که تطابق قابل‌توجهی میان مقدار حداکثر نشست پیش‌بینی شده سطح زمین توسط مدل عددی و داده‌های اندازه‌گیری شده میدانی وجود دارد. دباغ و همکاران [۵۰] نیز با به‌کارگیری روش المان مرزی به مدل‌سازی نشست ناشی از استخراج لایه‌های زغال‌سنگ شیب‌دار و افقی در سطح زمین پرداختند. یافته‌های آن‌ها نشان داد که میزان نشست سطح زمین با کسینوس زاویه شیب لایه استخراجی و عرض پهنه رابطه مستقیم دارد، در حالی که عمق روباره و مدول الاستیسیته مواد روباره تأثیری عکس بر نشست دارند. نجفی و عطایی [۵۱] با استفاده از مدل‌سازی عددی در محیط *FLAC3D* به مطالعه نشست سطح زمین ناشی از استخراج یک پهنه جبهه‌کار طولیل معدن طبس، واقع در عمق ۲۰۰ متری، پرداختند. یافته‌های آن‌ها نشان داد که حداکثر نشست سطح

جدول ۱- روابط تجربی موجود در منابع برای پیش‌بینی حداکثر نشست سطح زمین ناشی از عملیات استخراج جبهه‌کار طولیل.

رابطه	توضیحات	منبع
$S_{\max} = h_s [0.61 - 0.05(L_w/H - 0.07)]^{-1}$	-	کارمیس و همکاران [۵]
$S_{\max} = 0.39h_s (L_w/H)^{0.32}$	-	ون در مروه [۶]
$S_{\max} = 0.6815519h_s (0.9997398)^H$	$H$ برحسب فوت	پنگ و همکاران [۷]
$S_{\max} = 1.9381h_s (H + 23.4185)^{-0.1884}$	$H$ بر حسب فوت	لیوو و پنگ [۸]
$S_{\max} = 163.156h_s (H + 561.680)^{-0.857}$	-	چنگ و همکاران [۳۱]
$S_{\max} = 0.78h_s \left[ 1 - \left( 1 + e^{(L_w/H - 0.4)/0.18} \right) \right]$	-	ین و همکاران [۳۸]

داده‌های ورودی توسط یک تابع خطی که به آن تابع کرنل گفته می‌شود، از فضای اصلی به فضای با ابعاد بالاتر صورت می‌گیرد. تابع پیش‌بینی الگوریتم ماشین بردار پشتیبان، تابعی خطی است که در زیر نشان داده شده است [۵۷]:

$$f(x) = \sum (a_i - a_i^*) K(x_i, x) + b \quad (1)$$

در رابطه (۱)،  $b$  انحراف پیش‌بینی رگرسیون،  $a_i$  ضریب لاگرانژ و  $K$  تابع کرنل است. با کمینه کردن یک تابع تنظیم شده، ضرایب لاگرانژ به صورت زیر ایجاد می‌شوند:

$$R(f) = \frac{1}{2} \|w\|^2 + C \sum_{i=0}^n L(f(x_i) - y_i) \quad (2)$$

در رابطه (۲)،  $\|w\|$  تابع نرم و  $C$  متغیر منظم ساز می‌باشند. بعلاوه،  $L$  تابع هزینه است که توسط وینیک به شرح زیر پیشنهاد شده است [۶۰]:

$$L(f(x_i) - y_i) = \begin{cases} 0 & \text{if } |y - f(x)| \leq \varepsilon \\ |f(x) - y| - \varepsilon & \text{otherwise} \end{cases} \quad (3)$$

در رابطه (۳)، پارامتر  $\varepsilon$  شعاع یا حاشیه خطا در اطراف داده‌های آموزشی می‌باشد. توضیحات بیشتر در رابطه با مراحل مدل‌سازی ریاضی ماشین بردار پشتیبان را می‌توان در بسیاری از مقالات این حوزه بدست آورد.

مهمترین توابع کرنل مورد استفاده در الگوریتم ماشین بردار پشتیبان عبارتند از: خطی، چند جمله‌ای، تابع پایه شعاعی ( $RBF$ ) و سیگموئیدی [۵۲]. مطالعات انجام شده در حوزه مسائل مهندسی نشان می‌دهد که از بین توابع کرنل مذکور، استفاده از تابع کرنل پایه شعاعی ( $RBF$ ) در الگوریتم ماشین بردار پشتیبان، کارایی و نتیجه بهتری را به دنبال خواهد داشت [۵۳]. لذا در این مقاله نیز تابع کرنل  $RBF$  با معادله‌ای به صورت زیر مورد استفاده قرار می‌گیرد:

$$K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right), \sigma > 0 \quad (4)$$

در رابطه (۴)  $x_i$  و  $x_j$  بردارهای ورودی هستند. پارامتر  $\sigma$  شکل مرز تصمیم را کنترل و به علاوه انعطاف‌پذیری مدل و میزان بیش‌برازش یا کم‌برازش داده‌های آموزشی را تعیین می‌نماید. بنابراین،  $C$ ،  $\varepsilon$  و  $\sigma$  سه آبر پارامتر ( $hyperparameter$ ) اصلی در الگوریتم ماشین بردار پشتیبان هستند که در این مقاله به منظور دستیابی به مقادیر بهینه آن‌ها از الگوریتم فراابتکاری عقاب طلایی استفاده شده است.

### ۳-۲- الگوریتم فراابتکاری عقاب طلایی ( $GEO$ )

با توجه به موارد فوق‌الذکر، هدف این مطالعه بهبود دقت و قابلیت پیش‌بینی حداکثر نشست سطح زمین در معادن جبهه‌کار طویل از طریق به‌کارگیری مدل‌های داده‌محور مبتنی بر رویکردهای آماری و هوش مصنوعی است. در این راستا، دو مدل توسعه یافته‌اند: نخست، یک مدل رگرسیون چندمتغیره غیرخطی ( $NLMR$ ) به‌منظور تحلیل روابط پیچیده میان پارامترهای هندسی لایه زغال و پهنه استخراجی با میزان نشست؛ و دوم، یک مدل ترکیبی بر پایه رگرسیون ماشین بردار پشتیبان ( $SVR$ ) که با استفاده از الگوریتم فراابتکاری عقاب طلایی ( $GEO$ ) بهینه‌سازی شده است. نوآوری اصلی این پژوهش در استفاده هدفمند از مدل  $SVR-GEO$  نهفته است؛ زیرا از یک‌سو،  $SVR$  به‌عنوان یکی از روش‌های قدرتمند یادگیری ماشین، توان بالایی در مدل‌سازی روابط غیرخطی و تعمیم به داده‌های نادیده دارد، و از سوی دیگر، الگوریتم فراابتکاری  $GEO$  با توانایی جستجوی جامع در فضای پارامترها، امکان بهینه‌سازی مؤثر پارامترهای حساس  $SVR$  را فراهم می‌آورد. این ترکیب منجر به توسعه مدلی دقیق، پایدار و قابل تعمیم برای شرایط پیچیده معدنکاری جبهه‌کار طویل می‌شود، که تاکنون در مطالعات مشابه کمتر مورد توجه قرار گرفته است.

### ۳- مواد و روش‌ها

در این بخش به معرفی و نحوه عملکرد الگوریتم رگرسیون ماشین بردار پشتیبان ( $SVR$ )، الگوریتم بهینه‌ساز فراابتکاری عقاب طلایی ( $GEO$ )، روش اعتبار سنجی متقاطع  $k$ -بخشی، رگرسیون چندمتغیره غیرخطی ( $NLMR$ ) و شاخص‌های آماری ارزیابی عملکرد پرداخته می‌شود.

#### ۳-۱- ماشین بردار پشتیبان ( $SVR$ )

الگوریتم ماشین بردار پشتیبان یکی از الگوریتم‌های یادگیری ماشین بنا شده بر تئوری یادگیری آماری و مبتنی بر کرنل است که اولین بار توسط وینیک ارائه شد [۵۲]. این الگوریتم به طور گسترده‌ای برای حل مسائل رگرسیون و طبقه‌بندی در حوزه‌های مختلف مهندسی معدن از جمله انفجار، تونلسازی، پرتاب سنگ و ... مورد استفاده قرار گرفته است [۵۳-۵۷]. هدف در این الگوریتم جداسازی کلاس‌های مختلف داده در فضا با یک خط یا یک آبر صفحه است. با این وجود در بسیاری از مسائل، جداسازی داده‌ها با یک خط (یا صفحه) امکان‌پذیر نیست. بنابراین در چنین حالتی، داده‌ها به فضایی با ابعاد بالاتر نگاشت پیدا می‌کنند تا بتوان آن‌ها را در یک فضای جدید بصورت خطی جدا نمود [۵۲]. عمل نگاشت

برای دستیابی به عملکرد مطلوب هستند،  $GEO$  با ساختاری ساده‌تر و نیاز کمتر به تنظیمات پیچیده، در انواع مختلف مسائل عملکرد پایداری داشته است. این ویژگی،  $GEO$  را به گزینه‌ای مناسب برای کاربردهای واقعی مانند بهینه‌سازی مدل‌های یادگیری ماشین تبدیل می‌کند.

در مجموع، با توجه به نوآوری، سرعت، دقت و پایداری بیشتر  $GEO$  در مقایسه با الگوریتم‌های پایه‌ای مانند  $GA$  و  $PSO$ ، انتخاب این الگوریتم در راستای افزایش کیفیت بهینه‌سازی و کارایی مدل  $SVR$  انجام شده است. مدل‌سازی ریاضی الگوریتم  $GEO$ ، که رفتار شکار عقاب طلایی را تقلید می‌کند شامل مراحل زیر است [۵۹]:

### ۳-۲-۱- حمله

حمله را می‌توان برداری در نظر گرفت که بزرگی آن میزان تمایل به حمله عقاب به طعمه را نشان می‌دهد. بردار حمله از مکان فعلی عقاب (عامل جستجو) شروع می‌شود و در موقعیت شکار در حافظه عقاب به پایان می‌رسد. بردار حمله  $\bar{A}_i$  عقاب طلایی به شرح زیر است:

$$\bar{A}_i = \bar{X}_f - \bar{X}_i \quad (5)$$

در رابطه فوق  $\bar{A}_i$  و  $\bar{X}_i$  به ترتیب نشان دهنده بردار حمله و مکان فعلی  $\bar{A}_i$  عقاب طلایی است در حالی که  $\bar{X}_f$  نشان‌دهنده بهترین مکان عقاب طلایی است.

### ۳-۲-۲- گشت‌زنی

بردار گشت‌زنی بر اساس بردار حمله محاسبه می‌شود، به طوری که عمود بر بردار حمله است و در داخل آبر صفحه گشت‌زنی واقع شده است که مماس بر دایره احاطه کننده طعمه می‌باشد. اگر  $d$  معادله آبر صفحه گشت‌زنی را در فضای  $n$  بعدی نشان دهد، بردار گشت‌زنی  $\bar{A}_i$  عقاب طلایی را می‌توان به صورت زیر محاسبه کرد:

$$\bar{C}_i = (c_1 = rand, c_2 = rand, \dots, c_k, c_n = rand) \quad (6)$$

$$c_k = \left( d - \sum_{j, j \neq k}^n a_j \right) / a_k$$

در رابطه (۶)  $rand$  عددی تصادفی در بازه ۰ و ۱ است.

### ۳-۲-۳- به‌روز رسانی موقعیت جدید عقاب طلایی

موقعیت یک عقاب طلایی در حالی که از تکرار  $t$  به تکرار  $t+1$  می‌رود، به صورت زیر به‌روز رسانی می‌شود:

$$\bar{X}_i^{t+1} = \bar{X}_i^t + \Delta \bar{X}_i^t \quad (7)$$

در رابطه فوق  $\bar{X}_i^t$  و  $\bar{X}_i^{t+1}$  به ترتیب موقعیت عقاب  $\bar{A}_i$  در تکرار  $t$  و  $t+1$  است و همچنین، بردار جابجایی  $\Delta \bar{X}_i^t$  عقاب است

الگوریتم بهینه‌ساز عقاب طلایی ( $GEO$ ) یک الگوریتم فراابتکاری مبتنی بر جمعیت برای حل مسائل بهینه‌سازی است که در سال ۲۰۲۱ توسط محمدی بالانی و همکاران ارائه شد [۵۹].  $GEO$  الهام گرفته از هر دو رفتار گشت‌زنی و حمله عقاب‌های طلایی در شکار طعمه در طبیعت است. یک عقاب طلایی با پرواز در دایره‌های بزرگ در ارتفاعات و جستجوی طعمه شروع به شکار می‌کند. پس از شناسایی طعمه، عقاب در یک مسیر فرضی دایره مانند با مرکزیت طعمه، دور آن می‌چرخد. سپس عقاب به تدریج ارتفاع خود را همزمان با کاهش شعاع دایره فرضی احاطه کننده طعمه، کاهش می‌دهد. در نهایت، زمانی که هم شعاع دایره اطراف طعمه و هم ارتفاع عقاب به اندازه کافی کاهش یافت، عقاب در موقعیتی مناسب در یک خط مستقیم به طعمه حمله می‌کند. در واقع، تمایل بیشتر به گشت‌زنی در مراحل اولیه و تغییرات تدریجی از مرحله اول به مراحل بعدی و در نهایت حمله به طعمه در مرحله پایانی، اساس الگوریتم  $GEO$  است. در مطالعه حاضر، انتخاب این الگوریتم در مقایسه با الگوریتم‌های متداول تری مانند  $PSO$  و  $GA$  به دلایل زیر انجام شده است [۵۹]:

- **جدید بودن و ساختار بهینه‌تر جستجو:**

$GA$  و  $PSO$  به‌عنوان الگوریتم‌های پایه، ساختارهای جستجوی شناخته‌شده‌ای دارند که سال‌ها در مسائل مختلف کاربرد داشته‌اند. اما  $GEO$  به‌عنوان یک الگوریتم جدید، با الهام از رفتار شکار عقاب‌های طلایی، سازوکاری متفاوت و تطبیقی را برای ایجاد تعادل میان اکتشاف و بهره‌برداری ارائه می‌دهد. این ساختار باعث می‌شود از مشکلاتی مانند گرفتار شدن در مینیمم محلی که گاه در  $PSO$  و  $GA$  رخ می‌دهد، تا حد زیادی جلوگیری شود.

- **سرعت همگرایی بالاتر:**

در مقایسه‌های انجام‌شده در مقاله مرجع [۵۹]،  $GEO$  توانسته است در بسیاری از مسائل بهینه‌سازی، پاسخ‌های بهینه را با سرعت بیشتری نسبت به  $PSO$  و  $GA$  تولید کند. دلیل این امر، استفاده از استراتژی‌های حرکتی منعطف‌تر در الگوریتم  $GEO$  است که منجر به کاهش زمان همگرایی بدون افت دقت می‌شود.

- **دقت نهایی بالاتر در نتایج بهینه‌سازی:**

در آزمون‌های تجربی انجام‌شده روی توابع محک استاندارد در مقاله مرجع،  $GEO$  معمولاً دقت بهینه‌سازی بالاتری نسبت به  $PSO$  و  $GA$  از خود نشان داده است. در اکثر موارد،  $GEO$  توانسته مقدار بهینه تابع هدف را با نوسان کمتر و واریانس پایین‌تر به دست آورد.

- **پایداری عملکرد و سهولت تنظیم پارامترها:**

در حالی که  $GA$  و  $PSO$  معمولاً نیازمند تنظیمات حساس و خاصی

است. با این حال، یک پایگاه داده با اندازه کوچک ممکن است این روش را برای استفاده کامل از نمونه‌های داده محدود کند. بنابراین، نحوه تقسیم مجموعه داده‌ها به طور قابل توجهی بر ساخت و اعتبار مدل تأثیر می‌گذارد. از سوی دیگر در کلیه روش‌های یادگیری ماشین، الگوریتم یادگیری براساس داده‌های مرحله آموزش به یادگیری روابط بین پارامترهای ورودی و پارامتر خروجی می‌پردازد و از این طریق مدلی ساخته می‌شود که با بکارگیری آن می‌توان برای دسته داده‌های جدید (داده‌های تست) مقادیر خروجی را پیش‌بینی نمود. با این حال مدل ساخته شده براساس داده‌های آموزش همیشه نمی‌تواند قابلیت تعمیم‌پذیری و اعتبار خوبی داشته باشد و عملکرد آن ممکن است برای داده‌های تست، مناسب نباشد. به همین دلیل، برای حل این مشکل از روش اعتبارسنجی متقابل مانند  $k$ -بخشی به عنوان یک ابزار قدرتمند استفاده می‌شود [۶۰]. در این روش، برای ساخت مدل، مجموعه داده‌های آموزش ابتدا به طور تصادفی به  $k$  زیر مجموعه تقسیم می‌شوند. سپس،  $k-I$  زیر مجموعه از آن برای آموزش و بقیه به عنوان داده اعتبارسنجی استفاده می‌شوند [۶۱]. در طول این روش، فرآیند اعتبارسنجی  $k$  بار تکرار می‌شود و در نهایت عملکرد مدل با میانگین خطای پیش‌بینی  $k$  زیر مجموعه، ارزیابی می‌گردد [۶۰، ۶۱]. مدل ساخته شده از این طریق دارای قابلیت تعمیم‌پذیری بیشتر بوده و می‌توان آن را با اطمینان بیشتری بکار گرفت. در این مقاله، مجموعه داده‌های آموزش به ۵ زیر مجموعه مساوی به طور تصادفی تقسیم شده و سپس هر بار ۴ زیر بخش آن برای آموزش و ۱ زیر بخش آن برای اعتبارسنجی استفاده می‌شود (شکل ۱). روش اعتبارسنجی متقابل پنج‌بخشی به عنوان یکی از روش‌های متداول و اثربخش برای مجموعه داده‌های کمتر از ۱۰۰ نمونه توصیه شده است که تعادلی مناسب بین کاهش بایاس و کنترل واریانس خطا برقرار می‌کند [۶۲]. این رویکرد همزمان با بکارگیری الگوریتم  $GEO$  به منظور تعیین آبرپارامترهای الگوریتم  $SVR$  و نیز قابلیت تعمیم‌پذیری و کارایی مدل ساخته شده، مورد استفاده قرار گرفته است.

که ترکیبی از بردارهای حمله و گشت‌زنی می‌باشد و به صورت زیر قابل محاسبه است:

$$\overrightarrow{\Delta X}_i = \vec{r}_1 P_a^t \frac{\vec{A}_i}{\|\vec{A}_i\|} + \vec{r}_2 P_c^t \frac{\vec{C}_i}{\|\vec{C}_i\|} \quad (۸)$$

در رابطه (۸)  $r_1$  و  $r_2$  بردارهای تصادفی در بازه  $[0, 1]$  هستند و  $\|\vec{A}_i\|$  و  $\|\vec{C}_i\|$  نیز به ترتیب اندازه اقلیدسی بردارهای حمله و گشت‌زنی را نشان می‌دهند.  $P_a^t$  و  $P_c^t$  نشان دهنده ضرایب حمله و گشت‌زنی در تکرار  $t$ ام هستند. در این مرحله، اگر برازندگی موقعیت جدید عقاب بهتر از برازندگی موقعیت قبلی آن باشد، موقعیت عقاب با موقعیت جدید به روز می‌شود.

### ۳-۲-۴- تغییر از فاز اکتشاف به فاز استخراج

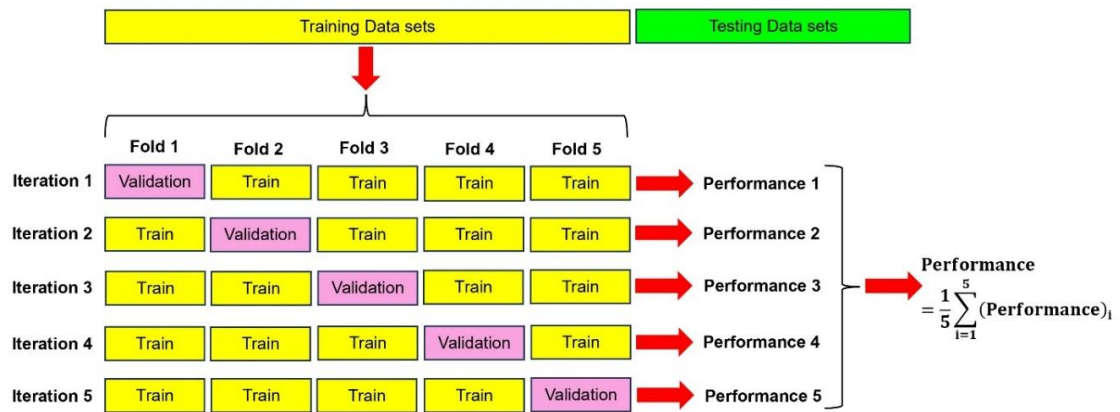
در الگوریتم  $GEO$ ، به منظور تغییر تدریجی از فاز اکتشاف به فاز استخراج، از ضرایب  $P_a^t$  و  $P_c^t$  که از روابط زیر بدست می‌آیند، استفاده می‌شود:

$$\begin{cases} P_a^t = P_a^0 + \frac{t}{T}(P_a^T - P_a^0) \\ P_c^t = P_c^0 - \frac{t}{T}(P_c^0 - P_c^T) \end{cases} \quad (۹)$$

در رابطه (۹)  $t$  و  $T$  تکرار فعلی و حداکثر تعداد تکرارها هستند.  $P_a^0$  و  $P_c^0$  به ترتیب مقادیر اولیه تمایل به حمله و گشت‌زنی را نشان می‌دهند، در حالی که  $P_a^T$  و  $P_c^T$  به ترتیب معرف مقادیر نهایی تمایل به حمله و گشت‌زنی هستند. مقادیر مناسب این پارامترها برای مسائل مختلف می‌تواند متفاوت باشد، با این حال براساس نظر محمدی بالانی و همکاران [۵۹]، مقادیر  $P_a^0 = 0.5$ ،  $P_a^T = 2$ ،  $P_c^0 = 1$  و  $P_c^T = 0.5$  می‌توانند در حل بسیاری از مسائل مناسب باشند.

### ۳-۳- اعتبارسنجی متقابل $k$ -بخشی

به طور کلی، در هر روش یادگیری ماشین کل مجموعه داده‌ها برای ساخت مدل و آزمون عملکرد آن به دو بخش آموزش و تست تقسیم می‌شود. ساده‌ترین راه برای تقسیم یک مجموعه داده بر اساس نسبت‌هایی مانند ۸۰٪-۲۰٪ برای آموزش و ۳۰٪-۷۰٪ برای تست



شکل ۱- نمایشی از نحوه پیاده‌سازی اعتبارسنجی متقابل ۵-بخشی.

به فرم درجه دوم برای پیش‌بینی حداکثر نشست سطح زمین، به صورت زیر بیان می‌شود:

$$S_{max} = \begin{pmatrix} \alpha_0 + \alpha_1 h_s + \alpha_2 H + \alpha_3 L_w + \alpha_{11} h_s^2 \\ + \alpha_{22} H^2 + \alpha_{33} L_w^2 + \alpha_{12} h_s H \\ + \alpha_{13} h_s L_w + \alpha_{23} H L_w \end{pmatrix} \quad (12)$$

### ۳-۵- شاخص‌های ارزیابی عملکرد

شاخص‌های ارزیابی عملکرد معمولاً برای بررسی دقت یک مدل و نیز مقایسه کارایی مدل‌های مختلف مورد استفاده قرار می‌گیرند. در این مقاله از دیاگرام تیلور، منحنی مشخصه خطای رگرسیون  $(REC)$  و ۶ شاخص آماری ارزیابی عملکرد شامل ضریب تعیین  $(R^2)$ ، شمول واریانس  $(VAF)$ ، شاخص  $a20$ ، جذر میانگین مربعات خطا  $(RMSE)$ ، خطای مطلق میانگین  $(MAE)$  و میانگین درصد خطای مطلق  $(MAPE)$ ، به منظور بررسی و مقایسه کارایی مدل‌های پیشنهادی استفاده شده است.

دیاگرام تیلور، تمامی مدل‌ها را در یک پلات بر اساس سه شاخص با یکدیگر مقایسه می‌کند [۶۶]: ضریب همبستگی  $(R)$ ، جذر میانگین مربعات خطا  $(RMSE)$ ، و انحراف معیار  $(SD)$ . در این دیاگرام، هر مدل به صورت یک نقطه نمایش داده می‌شود و نقطه مرجع (مشاهده‌شده) به عنوان معیار مقایسه در نظر گرفته می‌شود. لازم به ذکر است که هرچه موقعیت یک مدل پیش‌بینی‌کننده به نقطه مرجع نزدیک‌تر باشد، مقدار شاخص‌های  $R$  و  $RMSE$  آن به ترتیب بیشتر و کمتر بوده و در نتیجه مدل از دقت و عملکرد بالاتری برخوردار است.

منحنی  $REC$  ابزار مفیدی برای مقایسه کارایی مدل‌های رگرسیونی مختلف در یک پلات است [۶۷]. در منحنی  $REC$ ، محور

### ۳-۴- رگرسیون چندمتغیره غیر خطی $(NLMR)$

هدف تحلیل رگرسیون چندمتغیره  $(MR)$ ، تعیین نحوه ارتباط متغیرهای مستقل (ورودی) با متغیرهای وابسته (خروجی) است [۶۳]. این روش به دو دسته کلی تقسیم می‌شود: مدل‌های رگرسیون خطی و مدل‌های رگرسیون غیرخطی. یک مدل رگرسیون خطی با  $k$  متغیر به صورت زیر قابل نمایش است:

$$y = \alpha_0 + \sum_{i=1}^k \alpha_i x_i + \varepsilon \Rightarrow \quad (10)$$

$$y = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_k x_k + \varepsilon$$

که در آن،  $\alpha_0$  مقدار ثابت،  $\alpha_i$  ( $i = 1, 2, \dots, k$ ) ضرایب رگرسیون،  $x_i$  ( $i = 1, 2, \dots, k$ ) متغیرهای مستقل،  $\varepsilon$  خطای مدل،  $k$  تعداد متغیرهای مستقل، و  $y$  متغیر وابسته است. برخلاف رگرسیون چندمتغیره خطی  $(LMR)$  که تنها شامل عبارات خطی است، رگرسیون چندمتغیره غیرخطی  $(NLMR)$  می‌تواند مدلی با هر نوع رابطه دلخواه میان متغیرهای مستقل و وابسته ایجاد کند [۶۴]. افزون بر این، می‌توان مدل  $NLMR$  را به گونه‌ای تعریف کرد که از نظر دقت بر مدل  $LMR$  برتری داشته باشد. از این‌رو، با افزودن عبارات تعاملی و درجه دوم به مدل  $LMR$  (رابطه ۱۰)، نوعی از مدل  $NLMR$  با دقت بالاتر نسبت به مدل خطی به صورت زیر قابل ارائه است [۶۵]:

$$y = \alpha_0 + \sum_{i=1}^k \alpha_i x_i + \sum_{i=1}^k \alpha_{ii} x_i^2 + \sum_{1 \leq i < j} \alpha_{ij} x_i x_j + \varepsilon \quad (11)$$

در اینجا،  $\alpha_{ij}$  و  $\alpha_{ii}$  به ترتیب ضرایب عبارات تعاملی و درجه دوم را نشان می‌دهند. با توجه به اینکه در این مطالعه متغیرهای ضخامت لایه زغال‌سنگ  $(h_s)$ ، ارتفاع روباره  $(H)$  و عرض پهنه  $(L_w)$  به عنوان پارامترهای ورودی برای برآورد حداکثر نشست سطح زمین  $(S_{max})$  در نظر گرفته شده‌اند، بنابراین بر مبنای رابطه (۱۱)، مدل غیرخطی

#### ۴- آماده‌سازی داده‌ها (ایجاد پایگاه داده)

هدف اصلی این تحقیق پیش‌بینی حداکثر نشست سطح زمین ناشی از عملیات استخراج لایه‌های زغال‌سنگ به روش جبهه‌کار طویل با استفاده از مدل ترکیبی رگرسیون ماشین بردار پشتیبان بهینه شده با الگوریتم فراابتکاری عقاب طلایی و بررسی دقت و قابلیت کاربرد آن در مقایسه با مدل رگرسیون چندمتغیره غیرخطی (NLMR) است. برای دستیابی به این مهم، ابتدا پایگاه داده مناسبی شامل ۴۶ دسته داده موجود و گزارش شده در منابع معتبر [۴، ۱۶، ۳۲، ۳۳، ۳۶، ۳۷، ۴۰، ۴۸]، از پهنه‌های استخراجی به روش جبهه‌کار طویل جمع‌آوری شد. کلیه کارگاه‌های استخراجی در منابع فوق که داده‌های مورد نیاز از آن‌ها استخراج شد، به روش پسرو و عمدتاً به صورت مستقل و نه به صورت هم‌زمان استخراج شده‌اند. شیب گزارش شده لایه‌های زغال‌سنگ در برخی از منابع مورد استفاده حداکثر ۳ درجه و در اغلب موارد تقریباً افقی گزارش شده‌اند. اطلاعاتی مانند تعداد شیفت کاری، ضخامت اسلایس و وضعیت آب زیرزمینی در اکثر منابع مورد استفاده ارائه نشده‌اند. همچنین، سرعت پیشروی جبهه‌کار نیز به جز در پنج مورد خاص مربوط به منبع [۳۷]، در بقیه منابع گزارش نشده است. از سوی دیگر، مقادیر عددی خصوصیات ژئومکانیکی مواد روباره نیز به ندرت و در تعداد محدودی از موارد (۱۳ مورد) گزارش شده‌اند. با این وجود، در کلیه منابع مورد استفاده برای تهیه دسته داده‌های مناسب، پارامترهای هندسی لایه زغال‌سنگ و پهنه استخراجی شامل ضخامت لایه زغال‌سنگ ( $h_s$ )، عمق روباره ( $H$ ) و عرض پهنه استخراجی ( $L_w$ ) به طور دقیق گزارش شده‌اند. بنابراین، در این مطالعه تنها ۳ پارامتر هندسی  $h_s$ ،  $H$  و  $L_w$  به عنوان پارامترهای ورودی در فرآیند مدل‌سازی برای پیش‌بینی حداکثر نشست سطح زمین ( $S_{max}$ ) در نظر گرفته می‌شوند.

اطلاعات آماری پارامترهای ورودی و خروجی (حداکثر نشست اندازه‌گیری شده سطح زمین) پایگاه داده به همراه نماد و واحدهای آنها در جدول ۲ نشان داده شده است. بعلاوه، ماتریس همبستگی بین پارامترهای ورودی و خروجی پایگاه داده در شکل ۲ به تصویر کشیده شده است. با توجه به این شکل می‌توان دریافت که از بین پارامترهای ورودی، یک همبستگی قوی بین ضخامت لایه زغال‌سنگ ( $h_s$ ) و حداکثر نشست سطح زمین ( $S_{max}$ ) وجود دارد. همچنین این شکل بیانگر آن است که همبستگی ضعیفی بین ۳ پارامترها ورودی وجود دارد که این امر نشان‌دهنده استقلال پارامترهای ورودی از هم و عدم وجود همخطی بین آنها است.

$x$  نشان دهنده مقدار خطای مدل رگرسیونی و محور  $y$  نشان دهنده دقت (صحت) آن است. به عبارت دیگر، خطای مطلق به عنوان خطای مدل بر روی محور  $x$  در نظر گرفته می‌شود، در حالی که درصد نقاط پیش‌بینی شده در بازه خطا به عنوان دقت (صحت) در نظر گرفته می‌شود. هر اندازه منحنی  $REC$  یک مدل رگرسیونی به گوشه بالای سمت چپ پلات نزدیک‌تر باشد، مساحت نسبی بالای منحنی ( $AOC$ ) کوچکتر و مساحت نسبی زیر منحنی ( $AUC$ ) بزرگتر خواهد بود و در نتیجه کارایی و دقت (صحت) مدل مورد نظر بالاتر است. در واقع، نسبت  $AUC$  به  $AUC+AOC$  به عنوان معیاری برای مقایسه دقت مدل‌های مختلف مورد استفاده قرار می‌گیرد.

مقادیر  $R^2$ ،  $VAF$  و  $a20-index$  در اصل بین صفر و ۱ یا ۱۰۰٪ قرار دارند. همچنین، مقادیر  $RMSE$ ،  $MAE$  و  $MAPE$  همواره بزرگتر یا مساوی صفر هستند. با نزدیک شدن مقادیر شاخص‌های  $R^2$ ،  $VAF$  و  $a20$  به ۱ یا ۱۰۰٪ دقت مدل افزایش می‌یابد. از سوی دیگر هر اندازه مقادیر شاخص‌های  $RMSE$ ،  $MAE$  و  $MAPE$  برای یک مدل به صفر نزدیک‌تر باشند مقدار خطای آن مدل کمتر است. مقادیر شاخص‌های مورد استفاده را می‌توان با استفاده از روابط ۱۳ تا ۱۸ بدست آورد [۶۰، ۶۱]:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_{act} - y_{pre})^2}{\sum_{i=1}^N (y_{act} - y_{mean})^2} \quad (13)$$

$$VAF(\%) = 100 \times \left( 1 - \frac{\text{var}(y_{act} - y_{pre})}{\text{var}(y_{act})} \right) \quad (14)$$

$$a20-index = \frac{m20}{N} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{act} - y_{pre})^2} \quad (16)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{act} - y_{pre}| \quad (17)$$

$$MAPE(\%) = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_{act} - y_{pre}}{y_{act}} \right| \quad (18)$$


در روابط فوق،  $y_{act}$  و  $y_{pre}$  به ترتیب مقدار واقعی و پیش‌بینی شده و  $y_{mean}$  میانگین مقادیر اندازه‌گیری شده  $S_{max}$  است. همچنین  $N$  بیانگر تعداد کل دسته داده‌ها (در مرحله آموزش یا تست) و  $m20$  تعداد دسته داده‌هایی است که به ازای آن نسبت مقدار نشست واقعی به مقدار برآورد شده آن در بازه ۰/۸ تا ۱/۲ قرار می‌گیرد.

جدول ۲- اطلاعات آماری داده‌های جمع‌آوری شده برای پیش‌بینی حداکثر نشست سطح زمین.

نوع داده	پارامتر	واحد	نماد	حداقل	میانگین	حداکثر	انحراف معیار	واریانس
ورودی	ضخامت لایه زغال	m	$h_s$	۱,۴۵	۳,۶۸	۷	۱,۸۹۹	۳,۶۰۸
	عمق روباره	m	$H$	۴۸	۲۶۸,۲	۱۰۰۰	۲۲۰,۶۸	۴۸۷۰,۳۴
	عرض پهنه	m	$L_w$	۷۳	۲۵۸,۲۱	۴۴۳	۹۸,۷۵	۹۷۵۲,۶۲
خروجی	حداکثر نشست سطح زمین	m	$S_{max}$	۰,۲۶۱	۲,۰۳	۵,۱۳	۱,۱۷	۱,۳۸

نرم‌افزار *MATLAB 2022b* انجام شد تا تحلیل بر مبنای مقادیر واقعی انجام گیرد. سپس از الگوریتم فراابتکاری عقاب طلایی (*GEO*) برای دستیابی به مقادیر بهینه آبر پارامترهای الگوریتم *SVR* استفاده شد. لازم به ذکر است که اعتبارسنجی متقابل ۵- بخشی نیز در طول فرآیند بهینه‌سازی به منظور افزایش تعمیم‌پذیری مدل و کاهش احتمال بیش‌برازش (*Overfitting*) مورد استفاده قرار گرفت، که این امر به پایداری بیشتر عملکرد مدل ترکیبی *SVR-GEO* در مواجهه با داده‌های نادیده نیز کمک می‌نماید. در فرآیند بهینه‌سازی، الگوریتم *GEO* به گونه‌ای طراحی شد که مقدار خطای مدل *SVR* را بر اساس شاخص جذر میانگین مربعات خطا (*RMSE*) به عنوان تابع هدف یا برازندگی به حداقل برساند. این شاخص معیاری مناسب برای سنجش دقت مدل در مسائل پیش‌بینی پیوسته محسوب می‌شود. در ادامه برای تنظیم مؤثر پارامترهای الگوریتم *GEO*، آزمایش‌هایی اولیه جهت بررسی تأثیر تعداد عامل‌های جستجو (*Population size*) و تعداد تکرارها (*Iterations*) بر عملکرد مدل صورت گرفت. در این راستا، تعداد عامل‌های جستجو در مقادیر مختلف ۱۰، ۲۰، ۳۰، ۴۰ و ۵۰ و تعداد تکرارها تا سقف ۳۰۰ مورد بررسی قرار گرفت. نتایج این آزمایش‌ها نشان داد که افزایش تعداد عامل‌های جستجو تا مقدار ۳۰ موجب بهبود قابل توجه عملکرد مدل می‌شود، اما مقادیر بیشتر از آن بهبود چشم‌گیری در نتایج ایجاد نمی‌کنند و تنها منجر به افزایش زمان محاسباتی مدل می‌گردند. همچنین، بررسی روند تغییرات مقدار برازندگی در طول تکرارها نشان داد که پس از حدود ۱۰۰ تکرار، مقدار برازندگی مدل به پایداری نسبی رسیده و ادامه فرآیند بهینه‌سازی تأثیر قابل توجهی بر بهبود نتیجه ندارد.

بر این اساس، در اجرای نهایی مدل، تعداد عامل‌های جستجو برابر ۳۰ و تعداد تکرارها برابر ۱۰۰ در نظر گرفته شد تا توازن مناسبی میان دقت مدل و زمان محاسباتی برقرار گردد. در فرآیند بهینه‌سازی، بازه جستجوی آبر پارامترهای مدل *SVR* نیز به صورت



شکل ۲- ماتریس همبستگی بین پارامترهای ورودی و خروجی پایگاه داده.

## ۵- مدل‌سازی حداکثر نشست سطح زمین

در این بخش، هدف مدل‌سازی حداکثر نشست سطح زمین ( $S_{max}$ ) با استفاده از مدل رگرسیون ماشین بردار پشتیبان بهینه شده با الگوریتم عقاب طلایی (*SVR-GEO*) و رگرسیون چندمتغیره غیرخطی (*NLMR*) است. در زیربخش‌های ۴-۱ و ۴-۲، به نحوه‌ی مدل‌سازی با استفاده از این دو روش به تفصیل پرداخته شده است.

### ۵-۱- مدل‌سازی با استفاده از *SVR-GEO*

به منظور پیش‌بینی حداکثر نشست سطح زمین، در ابتدا ۸۰٪ داده‌ها (۳۷ دسته داده) به عنوان داده‌های آموزش و ۲۰٪ دیگر (۹ دسته داده) به عنوان داده‌های تست به صورت تصادفی در مدل‌سازی با الگوریتم *SVR* انتخاب شدند. همچنین، پیش از آموزش مدل، داده‌های ورودی و خروجی در بازه [۰، ۱] نرمال‌سازی شدند و خروجی‌های مدل پس از پیش‌بینی، مجدداً به مقیاس واقعی بازگردانده شدند. این عملیات به صورت درون‌برنامه‌ای در محیط

۱۲۹۵٫۲	متغیر منظم‌ساز (C)
۰٫۰۰۱۰	شعاع یا حاشیه خطا (ε)
۰٫۸۵۵۶	پارامتر کرنل RBF (σ)

### ۵-۲- مدل‌سازی با استفاده از NLMR

در این مرحله، با استفاده از ۳۷ دسته داده‌ی آموزشی، تحلیل رگرسیون چندمتغیره غیرخطی بر اساس رابطه (۱۲) به کمک نرم‌افزار آماری SPSS نسخه ۲۶ انجام شد و یک مدل چندمتغیره غیرخطی (NLMR) به فرم درجه دوم برای برآورد حداکثر نشست سطح زمین ( $S_{max}$ ) توسعه داده شد که در رابطه (۱۹) ارائه شده است. نتایج تحلیل واریانس (ANOVA) مدل NLMR در جدول ۴ ارائه شده است. بر اساس این نتایج، مقدار آماره‌ی فیشر ( $F$ ) محاسبه شده برابر با ۱۴٫۷۴ می‌باشد که در مقایسه با مقدار بحرانی متناظر آن از جدول توزیع  $F(۲,۲۵)$ ، بزرگتر بوده و دارای اختلاف زیادی است که نشان‌دهنده معناداری بالای مدل می‌باشد. همچنین، مقدار بسیار کوچک  $p$ -value ( $۲٫۸ \times 10^{-۸}$ )، که به مراتب کمتر از سطح خطای ۵ درصد است، مجدداً معناداری کلی مدل را تأیید مینماید. بنابراین می‌توان نتیجه گرفت که مدل توسعه‌یافته توانسته است تغییرات متغیر وابسته (حداکثر نشست سطح زمین،  $S_{max}$ ) را به‌طور قابل توجهی تبیین کند.

علاوه بر این، جدول ۵ معناداری ضرایب مدل را بر اساس مقادیر  $p$ -value نشان می‌دهد. ضرایبی که دارای مقادیر  $p$  کمتر از ۰٫۰۵ هستند، شامل  $a_3$  ( $p = 0.016$ ) و  $a_{13}$  ( $p = 6.7 \times 10^{-5}$ ) می‌باشند که به ترتیب با ترم‌های  $L_w$  و  $h_s \times L_w$  متناظرند و به عنوان ضرایب معنادار در مدل شناسایی شده‌اند. این نتایج بیانگر آن است که این ضرایب سهم بیشتری در پیش‌بینی حداکثر نشست سطح زمین در مدل NLMR دارند. در مقابل، ضرایبی با مقادیر  $p$ -value بزرگ‌تر از ۰٫۰۵ اهمیت آماری کمتری داشته و تأثیر آنها بر مدل به‌طور نسبی کمتر است.


$$S_{max} = \left( \begin{array}{l} 2.19 + 0.375h_s + 2.1 \times 10^{-4}H - 0.023L_w - 0.075h_s^2 + 1.9 \times 10^{-6}H^2 + 2.6 \times 10^{-5}L_w^2 \\ -6 \times 10^{-4}h_sH + 43 \times 10^{-4}h_sL_w - 5 \times 10^{-7}HL_w \end{array} \right) \quad (19)$$

جدول ۴- نتایج تحلیل واریانس (ANOVA) برای مدل رگرسیون چندمتغیره غیرخطی (NLMR).

مدل	منبع تغییر	درجه آزادی	مجموع مربعات	متوسط مربعات	آماره F	معناداری (p-value)
NLMR	رگرسیون	۹	۴۱٫۳۷	۴٫۵۹۷	۱۴٫۷۴	$۲٫۸ \times 10^{-۸}$
	باقیمانده	۲۷	۸٫۴۲	۰٫۳۱۲		
	کل	۳۶	۴۹٫۷۹			

زیر تعریف شد: مقدار C در بازه [۰٫۰۰۱، ۳۰۰۰]، مقدار σ در بازه [۰٫۰۰۱، ۸]، و مقدار ε در بازه [۰٫۰۰۱، ۰٫۰۶]. این بازه‌ها بر اساس آزمایش‌های اولیه و مطالعات پیشین در مسائل مشابه تعیین شدند تا ضمن پوشش طیف وسیعی از تنظیمات، از بیش‌برازش و کم‌برازش جلوگیری شود [۶۸].

شکل ۳ نمودار تغییرات مقدار برازندگی مدل در طول تکرارها را برای این حالت نمایش می‌دهد که نشان‌دهنده روند همگرایی مطلوب مدل است. در پایان فرآیند بهینه‌سازی، مقادیر بهینه آبرپارامترهای مدل SVR استخراج شد که در جدول ۳ ارائه شده‌اند. مدل ترکیبی SVR-GEO با این تنظیمات به‌عنوان بهترین پیکربندی انتخاب شد و در مراحل بعدی تحلیل مورد استفاده قرار گرفت. لازم به ذکر است که پیش از اجرای فرآیند آموزش مدل SVR، تمامی داده‌های ورودی و خروجی در بازه [۰، ۱] نرمال‌سازی شده‌اند و خروجی‌های مدل پس از پیش‌بینی به مقیاس واقعی بازگردانده شده‌اند. این فرآیند به‌صورت درون‌برنامه‌ای در محیط نرم‌افزار MATLAB انجام شده است.



شکل ۳- نمودار تغییرات مقدار برازندگی (RMSE) در تکرارهای مختلف.

جدول ۳- مقادیر بهینه آبر پارامترهای SVR بدست آمده با استفاده از الگوریتم فرا ابتکاری GEO.

آبر پارامتر	مقدار بهینه
-------------	-------------

جدول ۵- معناداری ضرایب مدل رگرسیون چندمتغیره غیر خطی (مقادیر  $p$ -value).

ضرایب	$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_{11}$	$\alpha_{22}$	$\alpha_{33}$	$\alpha_{12}$	$\alpha_{13}$	$\alpha_{23}$
مقدار $p$ -value	۰٫۱۲۸	۰٫۶۱۱	۰٫۹۵۴	۰٫۰۱۶	۰٫۲۲۶	۰٫۳۱۲	۰٫۱۱۲	۰٫۳۷۶	۶٫۷×۱۰ <sup>-۵</sup>	۰٫۹۴۸

## ۶- اعتبارسنجی مدل‌های پیشنهادی

به منظور ارزیابی دقت و قابلیت اطمینان مدل‌های پیشنهادی در پیش‌بینی حداکثر نشست سطح زمین، عملکرد مدل‌های ترکیبی  $SVR$ - $GEO$  و رگرسیون چندمتغیره غیرخطی ( $NLMR$ ) مورد بررسی و مقایسه قرار گرفت. در این راستا، شاخص‌های آماری  $R^2$ ،  $VAF$ ،  $a20$ ،  $RMSE$ ،  $MAE$  و  $MAPE$  که در زیربخش ۳-۵ معرفی شدند، استفاده گردید. مقادیر این شاخص‌ها برای مدل‌های مختلف در مراحل آموزش و تست محاسبه و در جدول ۶ ارائه شده است. نتایج جدول ۶ نشان می‌دهد که مدل  $SVR$ - $GEO$  در مرحله آموزش با مقادیر  $R^2$ ،  $VAF$  و  $a20$ -index به ترتیب برابر با ۰٫۹۸۸، ۹۸٫۸٪ و ۰٫۹۴۶ بالاترین میزان دقت را در میان مدل‌ها به خود اختصاص داده است. در همین مرحله، مقادیر  $RMSE$ ،  $MAE$  و  $MAPE$  برای این مدل به ترتیب برابر با ۰٫۱۳۴، ۰٫۰۵۳ و ۵٫۷٪ بوده که بسیار کمتر از مقادیر متناظر در مدل  $NLMR$  و روابط تجربی می‌باشد. همچنین در مرحله تست، مدل  $SVR$ - $GEO$  مقادیر  $R^2$ ،  $VAF$  و  $a20$ -index برابر با ۰٫۹۴۲، ۹۳٫۹٪ و ۰٫۷۷۸ را ثبت نموده است که مجدداً بیانگر دقت بالا است، در حالی که مقادیر  $RMSE$ ،  $MAE$  و  $MAPE$  آن به ترتیب ۰٫۲۹۲، ۰٫۲۳۵ و ۱۹٫۷۱٪ به دست آمده است.

در مقایسه، مدل  $NLMR$  در هر دو مرحله آموزش و تست، اگرچه عملکرد قابل قبولی از خود نشان داده است، اما در تمامی شاخص‌های آماری، نتایجی ضعیف‌تر از مدل  $SVR$ - $GEO$  ارائه نموده است. مقادیر  $R^2$ ،  $VAF$  و  $a20$ -index در مدل  $NLMR$  نسبت به مدل  $SVR$ - $GEO$  پایین‌تر بوده و همچنین مقادیر شاخص‌های خطایی نظیر  $RMSE$ ،  $MAE$  و  $MAPE$  در این مدل بالاتر ثبت شده‌اند. این موضوع نشان‌دهنده دقت کمتر و خطای پیش‌بینی بیشتر در مدل  $NLMR$  نسبت به مدل ترکیبی  $SVR$ - $GEO$  می‌باشد.

افزون بر این، مقایسه مدل‌های پیشنهادی با شش رابطه تجربی موجود (شامل مدل‌های کارمیس و همکاران [۵]، ون در مروه [۶]، پنگ و همکاران [۷]، لیوو و پنگ [۸]، چنگ و همکاران [۳۷] و یِن و همکاران [۳۸]) نیز برتری قابل توجه مدل‌های  $SVR$ - $GEO$  و  $NLMR$  را نشان می‌دهد. در هر دو مرحله آموزش و تست، مقادیر

شاخص‌های آماری مدل‌های پیشنهادی به مراتب بهتر از روابط تجربی می‌باشند. به طور نمونه، مقادیر  $R^2$  برای روابط تجربی عمدتاً بین ۰٫۵۷۹ تا ۰٫۶۶۷ در مرحله آموزش و بین ۰٫۸۲۳ تا ۰٫۸۵۵ در مرحله تست بوده که به وضوح کمتر از مقادیر مربوط به مدل‌های پیشنهادی است. همچنین مقادیر  $RMSE$  و  $MAPE$  در روابط تجربی بالاتر از مدل‌های پیشنهادی ثبت شده است، که نشان‌دهنده خطای پیش‌بینی بیشتر در روابط تجربی می‌باشد.

دیگرام تیلور (شکل ۴) با هدف فراهم‌سازی مقایسه‌ای گرافیکی و جامع بین مدل‌های مختلف از منظر سه شاخص  $R$ ،  $RMSE$  و  $SD$  مورد استفاده قرار گرفته است. در این نمودار، مدل  $SVR$ - $GEO$  در هر دو مرحله آموزش و تست، به نقطه مرجع (نقطه داده‌های واقعی) بسیار نزدیک‌تر بوده و این مسئله دلالت بر انطباق بهتر نتایج پیش‌بینی با داده‌های واقعی دارد. فاصله کمتر از نقطه مرجع نشان‌دهنده مقدار بیشتر ضریب همبستگی و مقدار کمتر  $RMSE$  مدل  $SVR$ - $GEO$  است، که تأییدی بر دقت بالاتر و پایداری عملکرد آن نسبت به مدل  $NLMR$  و نیز روابط تجربی می‌باشد. در مقابل، سایر روابط از جمله روابط تجربی، موقعیت دورتری نسبت به نقطه مرجع داشته و بدین ترتیب از دقت کمتر و خطای بیشتری برخوردار بوده‌اند. بنابراین، نمودار تیلور به عنوان یک ابزار گرافیکی مؤثر، برتری عملکرد مدل پیشنهادی  $SVR$ - $GEO$  را به وضوح به تصویر کشیده است.

به منظور ارزیابی دقیق‌تر عملکرد مدل‌ها، از منحنی مشخصه خطای رگرسیون ( $REC$ ) نیز استفاده شد که در شکل ۵ به تصویر کشیده شده است. بر اساس مقادیر مساحت نسبی زیر منحنی ( $AUC$ )، مدل  $SVR$ - $GEO$  با مقدار نسبی  $AUC$  برابر با ۰٫۹۸۵ در مرحله آموزش و ۰٫۹۲۳ در مرحله تست، بهترین عملکرد را داشته است. این در حالی است که مدل  $NLMR$  در هر دو مرحله آموزش و تست مقدار  $AUC$  نسبی برابر با ۰٫۸۸۳ را به ثبت رسانده است. این نتایج بیانگر دقت بالاتر و نرخ خطای پایین‌تر مدل  $SVR$ - $GEO$  نسبت به مدل  $NLMR$  و روابط تجربی است.

برای تحلیل گرافیکی عملکرد مدل  $SVR$ - $GEO$ ، در شکل‌های ۶ و ۷ خروجی‌های مدل در مراحل آموزش و تست به تفصیل ارائه شده‌اند. هر یک از این شکل‌ها شامل سه نمودار به ترتیب: (۱) مقایسه

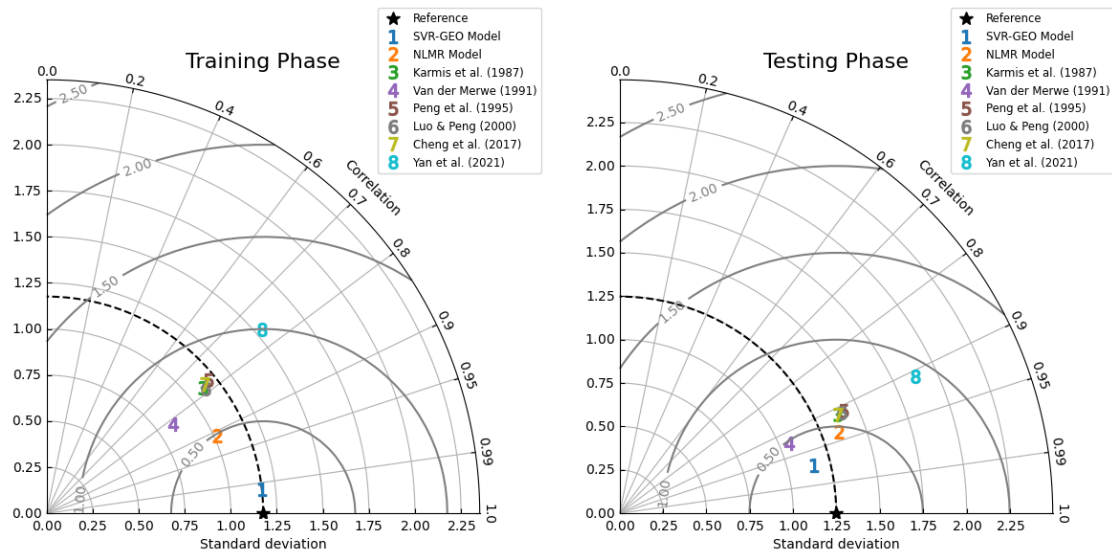
شکل ۸ با شکل‌های ۶ و ۷ تأیید می‌کند که گرچه مدل *NLMR* نیز عملکرد مطلوبی دارد، اما مدل ترکیبی *SVR-GEO* با اختلاف معنی‌داری دقت بالاتر و قابلیت اعتماد بیشتری ارائه نموده است. به طور خلاصه، با استناد به شاخص‌های آماری، نتایج گرافیکی و تحلیل‌های انجام شده، می‌توان نتیجه گرفت که مدل ترکیبی *SVR-GEO* در مقایسه با مدل *NLMR* و نیز در قیاس با روابط تجربی رایج، از دقت، کارایی و قابلیت اطمینان بالاتری برخوردار بوده و به عنوان یک ابزار قدرتمند برای پیش‌بینی حداکثر نشست سطح زمین ناشی از استخراج پهنه‌های جبهه‌کار طویل پیشنهاد می‌شود.

مقدار پیش‌بینی شده با مقدار واقعی، (۲) انطباق خروجی مدل با داده‌های واقعی بر حسب شماره دسته داده‌ها و (۳) هیستوگرام فراوانی خطاها می‌باشند. مشاهده این نمودارها نشان می‌دهد که مدل *SVR-GEO* در هر دو مرحله آموزش و تست توانسته است مقادیر پیش‌بینی شده را با دقت بالا بر داده‌های واقعی منطبق نماید و پراکندگی خطا در آن بسیار محدود می‌باشد.

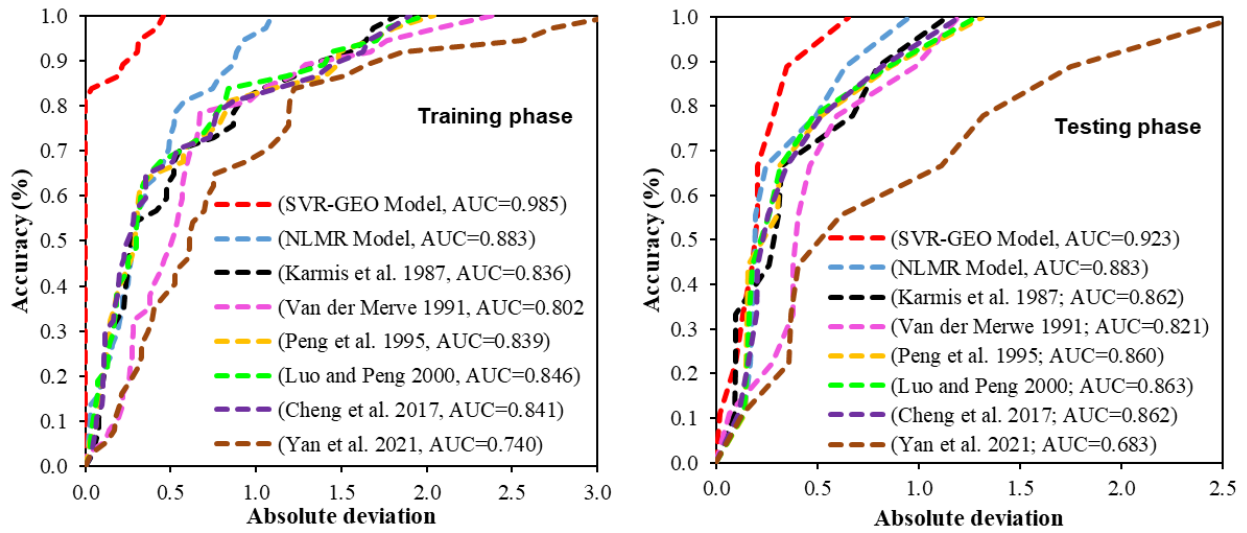
در نهایت، عملکرد مدل *NLMR* نیز در شکل ۸ به صورت مقایسه مقدار پیش‌بینی شده در برابر مقدار واقعی برای مراحل آموزش و تست به تصویر کشیده شده است. نتایج به دست آمده از مقایسه

جدول ۶- مقادیر شاخص‌های آماری بدست آمده برای مدل‌های *SVR-GEO* و *NLMR* و روابط تجربی در مراحل آموزش و تست.


شاخص آماری						مدل	مرحله
<i>MAPE (%)</i>	<i>MAE</i>	<i>RMSE</i>	<i>a20-index</i>	<i>VAF (%)</i>	<i>R<sup>2</sup></i>		
۵,۷۰	۰,۰۵۳	۰,۱۳۴	۰,۹۴۶	۹۸,۸۰	۰,۹۸۸	<i>SVR-GEO</i>	آموزش
۲۵,۴۹	۰,۳۷۹	۰,۴۸۵	۰,۶۲۲	۸۲,۵۵	۰,۸۲۷	<i>NLMR</i>	
۳۶,۴۰	۰,۳۷۹	۰,۷۴۷	۰,۵۴۱	۵۸,۷۴	۰,۶۰۸	کارمیس و همکاران [۵]	
۳۴,۰۲	۰,۶۴۹	۰,۸۴۸	۰,۱۸۹	۶۵,۶۷	۰,۶۶۷	ون در مروه [۶]	
۳۳,۳۷	۰,۵۲۹	۰,۷۷۰	۰,۶۱۱	۵۵,۹۱	۰,۵۹۷	پنگ و همکاران [۷]	
۳۳,۵۰	۰,۵۰۶	۰,۷۳۵	۰,۶۴۹	۶۰,۰۷	۰,۶۲۱	لیوو و پنگ [۸]	
۳۱,۷۱	۰,۵۲۱	۰,۷۶۰	۰,۵۱۴	۵۷,۳۰	۰,۶۰۱	چنگ و همکاران [۳۱]	
۵۸,۰۵	۰,۸۵۴	۱,۱۲۴	۰,۲۷۰	۲۷,۸۷	۰,۵۷۹	ین و همکاران [۳۸]	
۱۹,۷۱	۰,۲۳۵	۰,۲۹۲	۰,۷۷۸	۹۳,۹۰	۰,۹۴۲	<i>SVR-GEO</i>	تست
۲۰,۹۳	۰,۳۵۴	۰,۴۴۳	۰,۷۷۸	۸۵,۸۵	۰,۸۷۸	<i>NLMR</i>	
۲۸,۹۹	۰,۴۲۰	۰,۵۴۵	۰,۶۶۷	۷۹,۳۷	۰,۸۳۱	کارمیس و همکاران [۵]	
۳۰,۷۸	۰,۵۲۶	۰,۶۲۲	۰,۲۲۲	۸۴,۹۱	۰,۸۵۵	ون در مروه [۶]	
۳۰,۸۶	۰,۴۳۳	۰,۵۷۸	۰,۵۵۶	۷۷,۶۰	۰,۸۲۷	پنگ و همکاران [۷]	
۳۰,۳۹	۰,۴۲۳	۰,۵۶۳	۰,۵۵۶	۷۸,۵۳	۰,۸۳۰	لیوو و پنگ [۸]	
۳۰,۴۲	۰,۴۲۳	۰,۵۴۵	۰,۵۵۶	۷۹,۰۹۹	۰,۸۲۸	چنگ و همکاران [۳۱]	
۵۵,۷۷	۰,۹۵۸	۱,۲۲۳	۰,۱۱۱	۴۶,۵۰	۰,۸۲۳	ین و همکاران [۳۸]	




شکل ۴- مقایسه عملکرد مدل‌های پیشنهادی و روابط تجربی بر اساس دیاگرام تیلور در مراحل آموزش و تست.




شکل ۵- مقایسه عملکرد مدل‌های پیشنهادی و روابط تجربی بر اساس منحنی *REC* در مراحل آموزش و تست.



شکل ۶- عملکرد مدل SVR-GEO در مرحله آموزش.



شکل ۷- عملکرد مدل SVR-GEO در مرحله تست.



شکل ۸- عملکرد مدل NLMR در مراحل آموزش و تست.

## ۷- بحث و تحلیل مقایسه‌ای مدل‌های پیشنهادی

### با مطالعات پیشین

مرور جامع منابع موجود نشان می‌دهد که استفاده از رویکردهای هوش مصنوعی در پیش‌بینی حداکثر نشست سطح زمین ناشی از استخراج جبهه‌کار طویل، تاکنون کمتر مورد توجه قرار گرفته است. عمده‌ی تحقیقات پیشین یا به سراغ روابط تجربی نسبتاً ساده رفته‌اند یا از روش‌های عددی کلاسیک استفاده کرده‌اند؛ روش‌هایی که گرچه در نوع خود ارزشمندند، اما توانایی محدودی در شناسایی الگوهای پنهان و غیرخطی پدیده‌های ژئومکانیکی دارند.

در این پژوهش، دو مدل داده‌محور به‌عنوان جایگزینی برای روش‌های کلاسیک معرفی شده‌اند: *SVR-GEO* به‌عنوان مدل اصلی مبتنی بر یادگیری ماشین، و مدل رگرسیون چندمتغیره غیرخطی (*NLMR*) که رویکردی آماری ولی منعطف برای بازسازی روابط غیرخطی دارد. مدل ترکیبی معرفی شده در این پژوهش، یعنی *SVR-GEO*، نخستین تلاش جدی برای تلفیق الگوریتم‌های یادگیری ماشین با داده‌های واقعی از معدن‌کاری زیرزمینی است. در این مدل، از الگوریتم بردار پشتیبان (*SVR*) به‌عنوان هسته‌ی پیش‌بینی و از الگوریتم فراابتکاری عقاب طلایی (*GEO*) برای بهینه‌سازی آبرپارامترهای آن استفاده شده است. انتخاب این ترکیب صرفاً بر پایه‌ی پیچیدگی الگوریتم‌ها نبوده، بلکه بر اساس تعادلی هوشمندانه میان دقت، پایداری، سادگی پیاده‌سازی و توان تعمیم به داده‌های جدید صورت گرفته است.

در کنار مدل *SVR-GEO*، مدل آماری *NLMR* نیز توسعه داده شد تا بتوان با استفاده از روشی مبتنی بر ساختارهای غیرخطی اما کلاسیک، عملکرد مدل *SVR-GEO* را از منظر دقت و سادگی با یک چارچوب متفاوت مقایسه کند. هرچند نتایج نشان داد که *SVR-GEO* دقت بالاتری نسبت به *NLMR* دارد، اما مدل *NLMR* نیز توانست در اغلب شاخص‌ها عملکردی بهتر از روابط تجربی رایج ارائه دهد و به‌عنوان یک مدل مکمل، نقش مهمی در اعتبارسنجی و ارزیابی میزان بهبود مدل ترکیبی ایفا کند.

در مقایسه با شش رابطه تجربی معتبر که سال‌ها در این حوزه مورد استفاده بوده‌اند، *SVR-GEO* توانسته عملکردی چشمگیر از خود نشان دهد. شاخص‌هایی مانند *RMSE* پایین‌تر، ضریب تعیین ( $R^2$ ) بالاتر و درصد خطای مطلق میانگین کمتر (*MAPE*) تنها بخشی از این برتری‌اند. افزون بر این، بررسی نمودارهای خطای پیش‌بینی و تحلیل‌های تصویری نیز نشان می‌دهند که مدل ترکیبی نه تنها به نتایج دقیق‌تری می‌رسد، بلکه رفتارهای نامعمول داده را نیز بهتر درک می‌کند.

نکته‌ی مهم‌تر شاید این باشد که مدل ارائه‌شده علی‌رغم استفاده از تکنیک‌های هوش مصنوعی، پیچیدگی بی‌مورد ندارد. برخلاف شبکه‌های عصبی عمیق یا مدل‌های مبتنی بر الگوریتم‌های چندلایه و تنظیمات حساس، *SVR-GEO* قابل پیاده‌سازی در شرایط عملیاتی و حتی برای تیم‌های مهندسی با منابع محدود است. همین ویژگی می‌تواند آن را به گزینه‌ای عملی و کاربردی برای آینده‌ی پایش نشست در معادن زغال‌سنگ تبدیل نماید.

### ۸- تحلیل اهمیت متغیر

آخرین مرحله در فرآیند مدل‌سازی، ارزیابی میزان حساسیت خروجی مدل نسبت به پارامترهای ورودی آن است. این تحلیل به درک بهتر از تأثیر نسبی هر یک از پارامترهای ورودی بر متغیر هدف کمک می‌کند و امکان بهینه‌سازی مدل و تمرکز بر عوامل کلیدی را فراهم می‌سازد. یکی از روش‌های رایج و پرکاربرد در این زمینه، روش تحلیل حساسیت دامنه کسینوسی (*Cosine*) (*Amplitude Method, CAM*) است. این روش نخستین بار در حوزه مهندسی سنگ توسط یانگ و ژانگ [۶۹] در سال ۱۹۹۷ معرفی و به‌کار گرفته شد، که با بهره‌گیری از شبکه‌های عصبی مصنوعی، چارچوبی نوین برای تحلیل سلسله‌مراتبی سیستم‌های پیچیده ارائه دادند. به دلیل سادگی محاسبات، عدم وابستگی به ساختار مدل، و قابلیت کاربرد در سیستم‌های غیرخطی، *CAM* به‌سرعت به یکی از روش‌های محبوب در تحلیل حساسیت مدل‌های مهندسی ژئوتکنیک و زمین‌شناسی بدل شده است. در این تحقیق نیز از این روش به‌منظور ارزیابی اثر نسبی پارامترهای ورودی شامل ضخامت لایه زغال‌سنگ ( $h_s$ )، عمق روباره ( $H$ ) و عرض پهنه ( $L_w$ ) بر خروجی مدل، یعنی حداکثر نشست سطح زمین ( $S_{max}$ ) استفاده شده است. در روش *CAM*، یک فضای  $m$ -بعدی، که در آن  $m$  نشان‌دهنده تعداد پارامترهای ورودی است، مطابق رابطه زیر تعریف می‌شود:

$$X = \{X_1, X_2, \dots, X_m\} \quad (18)$$

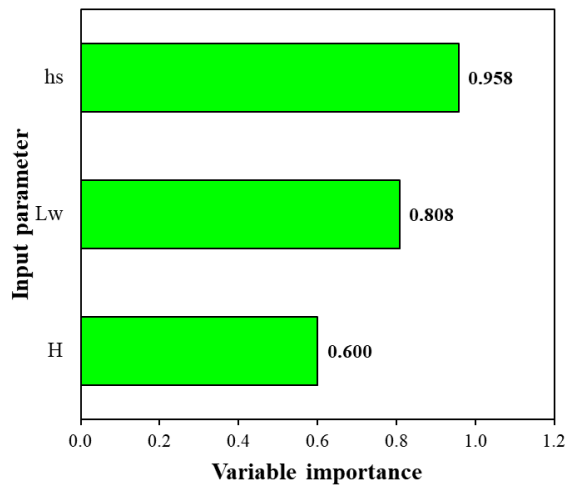
هر یک از عناصر  $X_i$  در آرایه داده  $X$ ، توسط یک بردار طول به صورت زیر تعریف می‌شود:

$$X_i = \{x_{i1}, x_{i2}, \dots, x_{im}\} \quad (19)$$

در نهایت، اثر هر یک از پارامترهای ورودی بر پارامتر خروجی را می‌توان با استفاده از رابطه زیر بدست آورد:

$$r_{ij} = \frac{\sum_{k=1}^m x_{ik} x_{jk}}{\sqrt{\left(\sum_{k=1}^m x_{ik}^2\right) \left(\sum_{k=1}^m x_{jk}^2\right)}} \quad (20)$$

مقدار  $r_{ij}$  بین ۰ و ۱ قرار دارد. هر اندازه اثر یک پارامتر ورودی بر



شکل ۹- اهمیت پارامترهای ورودی تأثیرگذار بر حداکثر نشست سطح زمین در مدل SVR-GEO

#### ۹- مزایا، محدودیت‌ها و مطالعات آینده

در این پژوهش، دو مدل جدید شامل رگرسیون ماشین بردار پشتیبان بهینه‌شده با الگوریتم عقاب طلایی (SVR-GEO) و رگرسیون چندمتغیره غیرخطی (NLMR) برای پیش‌بینی حداکثر نشست سطح زمین ( $S_{max}$ ) ناشی از استخراج پهنه‌های جبهه‌کار طویل، توسعه داده شدند. نتایج حاصل از اعتبارسنجی آماری و تحلیل‌های گرافیکی نشان داد که مدل SVR-GEO به‌واسطه ترکیب قدرت یادگیری ماشین با الگوریتم‌های بهینه‌سازی فراابتکاری، عملکردی بسیار دقیق و قابل اعتماد در هر دو مرحله آموزش و تست از خود نشان داده و به‌عنوان گزینه‌ای مؤثر برای پیش‌بینی  $S_{max}$  قابل توصیه است. همچنین، مدل NLMR نیز با وجود ساختار تحلیلی ساده‌تر نسبت به مدل SVR-GEO، در مقایسه با روابط تجربی سنتی، دقت قابل قبولی داشته و پتانسیل استفاده در شرایط داده‌ای خاص را داراست.

از مهم‌ترین مزایای این پژوهش می‌توان به طراحی و پیاده‌سازی چارچوبی برای توسعه و ارزیابی مدل‌های ترکیبی و غیرخطی، استفاده از شاخص‌های متنوع آماری برای تحلیل عملکرد مدل‌ها، و بهره‌گیری از روش‌های بهینه‌سازی نوین برای تعیین آبرپارامترهای بهینه اشاره کرد. همچنین تحلیل جامع نتایج به کمک نمودارهای تخصصی نظیر نمودار تیلور و منحنی مشخصه خطای رگرسیون (REC)، امکان ارزیابی چندبُعدی دقت پیش‌بینی را فراهم نموده است. با این حال، این تحقیق با برخی محدودیت‌ها نیز همراه است که می‌توان آن‌ها را به‌عنوان مسیرهای توسعه در مطالعات آینده در نظر گرفت:

پارامتر خروجی بیشتر باشد، مقدار  $r_{ij}$  به ۱ نزدیک‌تر است. از آنجایی که دقت مدل‌های دیگر در مقایسه با مدل SVR-GEO بسیار پایین‌تر است، لذا در این مطالعه فقط به بررسی اهمیت پارامترهای ورودی  $h_s$ ،  $H$  و  $L_w$  در مدل‌سازی حداکثر نشست سطح زمین ( $S_{max}$ ) با استفاده از مدل SVR-GEO پرداخته شد. در شکل ۹، نتایج تحلیل حساسیت انجام شده به ترتیب اهمیت پارامترهای ورودی در برآورد پارامتر خروجی، به تصویر کشیده شده است. با توجه به این شکل می‌توان دریافت که ضخامت لایه زغال‌سنگ ( $h_s$ ) و عرض پهنه استخراجی ( $L_w$ ) به ترتیب مهمترین پارامترهای تأثیرگذار بر حداکثر نشست سطح زمین ( $S_{max}$ ) هستند، در حالی که، عمق روباره ( $H$ ) کمترین تأثیر را بر حداکثر نشست سطح زمین ( $S_{max}$ ) دارد.

اگرچه در بسیاری از روابط تجربی کلاسیک موجود در منابع، عمق روباره به‌عنوان یکی از پارامترهای کلیدی در کاهش حداکثر نشست سطح زمین در نظر گرفته می‌شود، اما تحلیل حساسیت مبتنی بر روش دامنه کسینوسی (CAM) تفاوت‌های بنیادینی با این نوع روابط دارد. در روش CAM، تأثیر نسبی هر پارامتر بر خروجی مدل بر اساس میزان جهت‌گیری تغییرات آن پارامتر با تغییرات خروجی در کل فضای داده ارزیابی می‌شود، نه صرفاً بر اساس فرم تابعی خاص.

از سوی دیگر، در پایگاه داده مورد استفاده در این تحقیق، اگرچه بازه تغییرات عمق روباره وسیع است (۴۸ تا ۱۰۰۰ متر)، اما پراکندگی داده‌های مربوط به عمق‌های بالا نسبتاً کم و غیریکپارچه بوده و عمده داده‌ها در محدوده عمق‌های کم تا متوسط (زیر ۳۰۰ متر) متمرکز هستند. این نوع توزیع داده موجب شده است تا تغییرات عمق در مقایسه با ضخامت لایه زغال‌سنگ و عرض پهنه استخراجی، همبستگی کمتری با تغییرات حداکثر نشست نشان دهد. از سوی دیگر، پارامترهایی مانند ضخامت لایه زغال‌سنگ و عرض پهنه دارای روندهای پیوسته‌تر و اثرات مستقیم‌تری بر خروجی بوده‌اند، که این موضوع در افزایش تأثیر آن‌ها در تحلیل CAM منعکس شده است. بنابراین، نتایج تحلیل حساسیت را باید در چارچوب آماری داده‌های موجود و روش‌شناسی خاص CAM تفسیر نمود، نه لزوماً در تقابل با روابط تجربی سنتی.

## ۱) محدودیت در تنوع پارامترهای ورودی

به دلیل عدم دسترسی به اطلاعات زمین‌شناسی و ژئومکانیکی دقیق، پارامترهای ورودی مدل‌ها عمدتاً محدود به ویژگی‌های هندسی بودند. این محدودیت عمدتاً ناشی از آن است که در منابع موجود در این زمینه، اغلب تنها برخی از خواص ژئومکانیکی گزارش می‌شوند و داده‌های کامل و جامع در این خصوص به‌ندرت در دسترس قرار دارند. در نتیجه، در این مطالعه ناگزیر فرض شد که روبراه دارای ویژگی‌های نسبتاً یکنواخت ژئومکانیکی است، در حالی که در واقعیت ممکن است این ویژگی‌ها در نقاط مختلف تغییرات قابل توجهی داشته باشند. در حالی که پارامترهایی نظیر مقاومت لایه‌ها، زاویه اصطکاک داخلی، چسبندگی و ... می‌توانند تأثیر بسزایی در دقت پیش‌بینی داشته باشند. گسترش دامنه داده‌ها به پارامترهای زمین‌شناسی می‌تواند دقت و پایداری مدل‌ها را به شکل چشمگیری ارتقاء دهد.

## ۲) محدودیت در اندازه پایگاه داده

گرچه داده‌های مورد استفاده شامل نمونه‌هایی واقعی و قابل استناد هستند، اما اندازه نسبتاً متوسط پایگاه داده (۴۶ دسته داده) می‌تواند قابلیت تعمیم‌پذیری مدل‌ها در مقیاس‌های گسترده‌تر را محدود سازد. در حوزه یادگیری ماشین، پایگاه‌های داده کوچک ممکن است منجر به بیش‌برازش (*overfitting*) شده و توانایی مدل در پیش‌بینی شرایط جدید را کاهش دهند. از این رو، بهره‌گیری از پایگاه‌های داده بزرگ‌تر و متنوع‌تر در مطالعات آینده، عاملی کلیدی در تقویت توان مدل‌سازی و افزایش پایداری عملکرد مدل در مواجهه با شرایط نادیده خواهد بود.

## ۳) ملاحظات مربوط به الگوریتم بهینه‌سازی *GEO*

اگرچه الگوریتم *GEO* به دلیل ساختار جستجوی تطبیقی، توانایی بالا در تعادل میان اکتشاف و بهره‌برداری، و عملکرد برتر نسبت به الگوریتم‌های متداولی مانند *GA* و *PSO*، در این پژوهش انتخاب شده است، اما مانند بسیاری از الگوریتم‌های فراابتکاری، دارای برخی ملاحظات و محدودیت‌های ذاتی نیز می‌باشد. نخست آنکه در مسائل با ابعاد بسیار بالا یا تابع هدف پیچیده، در صورت عدم تنظیم مناسب پارامترهای الگوریتم، احتمال گرفتار شدن در مینیمم‌های محلی وجود دارد، هرچند این احتمال در *GEO* نسبت به *GA* و *PSO* به‌طور قابل توجهی کاهش یافته است. دوم آنکه ساختار جستجوی مرحله‌ای *GEO* و استفاده از بردارهای ترکیبی حمله و گشت‌زنی، به‌ویژه در تکرارهای بالا و جمعیت‌های

بزرگ، ممکن است منجر به افزایش هزینه محاسباتی نسبت به برخی الگوریتم‌های سبک‌تر شود. بنابراین، در کاربردهای با محدودیت زمانی یا منابع پردازشی محدود، نیاز به طراحی بهینه پارامترهای کنترل‌کننده و کاهش پیچیدگی محاسباتی وجود دارد. این کاهش می‌تواند از طریق به‌کارگیری روش‌هایی نظیر انتخاب ویژگی‌های کلیدی، کاهش ابعاد داده‌ها با حفظ اطلاعات مؤثر، یا تنظیم تطبیقی پارامترهای الگوریتم در طول فرآیند بهینه‌سازی صورت گیرد. این راهکارها موجب می‌شوند حجم محاسبات کاهش یافته و الگوریتم در فضای جستجوی فشرده‌تری به دنبال پاسخ بهینه بگردد، بدون آنکه دقت نهایی مدل به‌طور معنادار آفت کند. در نهایت، توسعه مدل‌های ترکیبی که از مزایای یادگیری ماشین، ساختارهای غیرخطی و تفسیرپذیری آماری بهره‌مند باشند، در کنار غنی‌سازی پایگاه داده‌ها با ویژگی‌های زمین‌شناسی و عملیاتی، می‌تواند گامی مؤثر در راستای افزایش دقت پیش‌بینی و کاربردپذیری مدل‌ها در شرایط واقعی عملیات معدن‌کاری تلقی گردد. همچنین، به‌کارگیری الگوریتم‌های بهینه‌سازی نوین مانند *GEO* در ترکیب با روش‌های کاهش پیچیدگی محاسباتی (نظیر انتخاب ورودی مهم‌تر، کاهش ابعاد یا تنظیم تطبیقی پارامترها) می‌تواند به بهبود کارایی زمانی و پایداری الگوریتم در مسائل با ابعاد بالا کمک نماید. در مطالعات آتی، بررسی مقایسه‌ای عملکرد الگوریتم‌های مختلف فراابتکاری در حوزه پیش‌بینی پدیده‌های ژئوتکنیکی، با در نظر گرفتن هزینه محاسباتی و پتانسیل گرفتار شدن در مینیمم‌های محلی، می‌تواند در انتخاب راهکارهای بهینه نقشی کلیدی ایفا نماید.

## ۱۰- نتیجه‌گیری

پیش‌بینی دقیق حداکثر نشست سطح زمین ناشی از استخراج زغال‌سنگ به روش جبهه‌کار طویل، نقش بسزایی در ایمن‌سازی سازه‌های سطحی و زیرسطحی و طراحی بهینه پروژه‌های معدنی ایفا می‌کند. در این پژوهش، با هدف ارتقاء دقت پیش‌بینی‌ها، دو مدل داده‌محور شامل مدل رگرسیون ماشین بردار پشتیبان بهینه‌شده با الگوریتم فراابتکاری عقاب طلایی (*SVR-GEO*) و مدل رگرسیون چندمتغیره غیرخطی (*NLMR*) توسعه یافته و عملکرد آن‌ها با یکدیگر و نیز با شش رابطه تجربی رایج و معتبر مقایسه گردید. برای اعتبارسنجی مدل‌ها، از شش شاخص آماری کلیدی شامل  $MAE$ ،  $RMSE$ ،  $a20$ -index،  $VAF$ ،  $R^2$  و  $MAPE$  استفاده شد. نتایج به‌دست آمده نشان داد که مدل *SVR-GEO* در هر دو مرحله آموزش و تست، عملکرد بسیار بهتری نسبت به مدل

عمق روباره ( $H$ ) کمترین اثر را بر مقدار حداکثر نشست دارند. این یافته می‌تواند در تنظیم اولویت‌های طراحی و انتخاب استراتژی‌های استخراج مؤثر باشد.

در مجموع، مدل  $SVR-GEO$  به عنوان مدلی پیشرفته، دقیق و قابل اعتماد، توانست پیچیدگی‌های غیرخطی موجود در داده‌ها را به خوبی درک نموده و عملکردی به مراتب بهتر از مدل‌های کلاسیک و تجربی ارائه دهد. این مدل در هر دو مرحله آموزش و تست، دقت بالایی از خود نشان داده است؛ با این حال، باید در تفسیر نتایج، به محدودیت اندازه پایگاه داده، به ویژه در مرحله تست (شامل ۹ نمونه)، توجه داشت. اگرچه نتایج مرحله تست نیز از پایداری مناسب عملکرد مدل حکایت دارد، اما جهت تعمیم‌پذیری بیشتر و افزایش اطمینان در شرایط گوناگون، لازم است ارزیابی‌های تکمیلی با حجم داده‌های بیشتر انجام شود. بنابراین، هرچند نتایج به دست آمده نشان‌دهنده پتانسیل بالای مدل  $SVR-GEO$  حتی در مواجهه با داده‌های پیچیده هستند، ولی اظهار نظر قطعی در خصوص کارایی آن در سناریوهای بسیار پیچیده نیازمند داده‌های میدانی گسترده‌تر و آزمون‌های بیشتر در آینده خواهد بود.

$NLMR$  و سایر روابط تجربی داشته و دقت پیش‌بینی آن در تمامی شاخص‌ها بالاتر بوده است. در مرحله آموزش، این مدل با  $R^2$  معادل ۰٫۹۸۸ و  $MAPE$  برابر با ۰٫۵۷٪، توانست دقت بسیار بالایی را از خود نشان دهد. همچنین در مرحله تست نیز با حفظ دقت مطلوب، مقادیر قابل توجهی برای شاخص‌ها ثبت کرد. مدل  $NLMR$  نیز علیرغم عملکرد قلیل قبول، در تمامی معیارهای آماری نسبت به مدل  $SVR-GEO$  ضعیف‌تر عمل کرد.

در مقایسه با روابط تجربی موجود، نتایج مدل‌های پیشنهادی برتری آشکاری را نشان دادند. مقادیر  $R^2$  برای روابط تجربی بین ۰٫۵۷۹ تا ۰٫۶۶۷ (در مرحله آموزش) و ۰٫۸۲۳ تا ۰٫۸۵۵ (در مرحله تست) متغیر بوده که نسبت به مدل‌های  $SVR-GEO$  و  $NLMR$  به مراتب پایین‌تر هستند. این موضوع، همراه با مقادیر بالاتر  $RMSE$  و  $MAPE$  در روابط تجربی، گویای دقت کمتر آن‌ها در پیش‌بینی حداکثر نشست سطح زمین می‌باشد. تحلیل‌های گرافیکی از طریق دیاگرام تیلور، منحنی  $REC$  و هیستوگرام‌های خطا نیز، عملکرد برتر مدل  $SVR-GEO$  را به وضوح نمایان ساختند. همچنین، تحلیل حساسیت پارامترهای ورودی با استفاده از روش دامنه کسینوسی، نشان داد که ضخامت لایه زغال سنگ ( $h_s$ ) بیشترین و

## ۸- منابع

- [1] Rezaei, M., Habibi, H., & Asadizadeh, M. (2024). 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. <https://doi.org/10.1007/s12145-024-01476-3>
- [2] Majdi, A., Hassani, F. P., & Nasiri, M. Y. (2012). Prediction of the height of distressed zone above the mined panel roof in longwall coal mining. *International Journal of Coal Geology*, 98, 62-72. <https://doi.org/10.1016/j.coal.2012.04.005>
- [3] National Coal Board. (1975). Subsidence Engineering Handbook. National Coal Board Mining Department.
- [4] Munson, D. E., & Eichfeld, W. F., 1980. European empirical methods applied to subsidence in US coal fields (No. SAND-80-1920). Sandia National Labs., Albuquerque, NM (USA).
- [5] Karmis, M., Jarosz, A., Schilizzi, P., & Agioutantis, Z. (1987). Surface deformation characteristics above undermined areas: Experience from the Eastern United States. *Civil Engineering Transactions*, 29(2), 106-114.
- [6] Van der Merwe, J. N. (1991). Subsidence caused by high extraction coal mining in the Sasolburg and Secunda areas: prediction thereof and the mitigation of its effects (Doctoral dissertation, PhD thesis, University of the Witwatersrand).
- [7] Peng, S. S., Luo, Y., & Zhang, Z. M. (1995). Subsidence parameters-their definitions and determination. PREPRINTS-SOCIETY OF MINING ENGINEERS OF AIME.
- [8] Luo, Y., & Peng, S. S. (2000). Prediction of subsurface subsidence for longwall mining operations. In Proceedings of the 19th international conference on ground control in mining (pp. 163-170). West Virginia University, WV.
- [9] Cui, X., Wang, J., & Liu, Y. (2001). Prediction of progressive surface subsidence above longwall coal mining using a time function. *International journal of Rock Mechanics and Mining Sciences*, (38), 1057-1063. [https://doi.org/10.1016/S1365-1609\(01\)00061-2](https://doi.org/10.1016/S1365-1609(01)00061-2)
- [10] Alvarez-Fernandez, M., Gonzalez-Nicieza, C., Menendez-Diaz, A., & Alvarez-Vigil, A. (2005). Generalization of the n-k influence function to predict mining subsidence. *Engineering Geology*, (80), 1-36. <https://doi.org/10.1016/j.enggeo.2005.02.004>
- [11] Asadi, A., Shahriar, K., Goshtasbi, K., & Najm, K. (2005, January). Development of a new mathematical model for prediction of surface subsidence due to inclined coal-seam mining. *The Journal of The South African Institute of Mining and Metallurgy*.

- [12] Keilich, W., Seedsman, R., & Aziz, N. (2006). Numerical Modelling of Mining Induced Subsidence. Coal Operators' Conference, University of Wollongong and the Australasian Institute of Mining and Metallurgy, (pp. 313-326).
- [13] Gonzalez-Nicieza, C., Alvarez-Fernandez, M., Menendez-Diaz, A., & Alvarez-Vigil, A. (2007). The influence of time on subsidence in the Central Asturian Coalfield. *Bull Eng Geol Environ*, (66), 319-329. doi:10.1007/s10064-007-0085-2
- [14] Luo, Y., & Cheng, J. (2009). An influence function method-based subsidence prediction program for longwall mining operations in inclined coal seams. *Mining Science and Technology (China)*, 19(5), 592-598. [https://doi.org/10.1016/S1674-5264\(09\)60110-1](https://doi.org/10.1016/S1674-5264(09)60110-1)
- [15] Shahriar, K., Amoushahi, S., & Arabzadeh, M. (2009). Prediction of Surface Subsidence Due to Inclined Very Shallow Coal Seam Mining Using FDM. Coal Operators Conference.
- [16] Gutierrez, J. J. (2010). Estimating Highway Subsidence due to Longwall Mining. Doctoral dissertation, University of Pittsburgh.
- [17] Li, W.-X., Liu, L., & Dai, L.-F. (2010). Fuzzy probability measures (FPM) based non-symmetric membership function: Engineering examples of ground subsidence due to underground mining. *Engineering Application of Artificial Intelligence*, (23), 420-431. <https://doi.org/10.1016/j.engappai.2010.01.003>
- [18] Song, S., Zhao, X., Xie, J., & Guan, Y. (2011). Grey Correlation Analysis and Regression Estimation of Mining Subsidence in Yu-Shen-Fu Mining Area. *Procedia Environmental Sciences*, (10), 1747-1752. <https://doi.org/10.1016/j.proenv.2011.09.274>
- [19] Luo, Y., & Qiu, B. (2012). CISPM-MS, a Tool to Predict Surface Subsidence and to Study Interactions Associated with Multi-Seam Mining Operations. In Proceedings of the 31st International Conference on Ground Control in Mining (pp. 56-62). West Virginia University.
- [20] Xu, N., Kulatilake, P., Tian, H., Wu, X., Nan, Y., & Wei, T. (2013). Surface subsidence prediction for the WUTONG mine using a 3-D finite difference method. *Computers and Geotechnics*, (48), 134-145. <https://doi.org/10.1016/j.compgeo.2012.09.014>
- [21] Guo, G., Zhu, X., Zha, J., & Wang, Q. (2014). Subsidence prediction method based on equivalent mining height theory for solid backfilling mining. *Trans. Nonferrous Met. Soc. China*, (24), 3302-3308. [https://doi.org/10.1016/s1003-6326\(14\)63470-1](https://doi.org/10.1016/s1003-6326(14)63470-1)
- [22] Ren, G., Li, G., & Kulesa, M. (2014). Application of a Generalised Influence Function Method for Subsidence Prediction in Multi-seam Longwall Extraction. *Geotech Geol Eng*, (32), 1123-1131. <https://doi.org/10.1007/s10706-014-9787-y>
- [23] Howladar, M. F., & Hasan, K. (2014). A study on the development of subsidence due to the extraction of 1203 slice with its associated factors around barapukuria underground coal mining industrial area, Dinajpur, Bangladesh. *Environmental Earth Sciences*, 72(9), 3699-3713. <https://doi.org/10.1007/s12665-014-3419-y>
- [24] Sasaoka, T., Takamoto, H., Shimada, H., Oya, J., Hamanaka, A., & Matsui, K. (2015). Surface subsidence due to underground mining operation under weak geological condition in Indonesia. *Journal of Rock Mechanics and Geotechnical Engineering*, 7, 337-344. <https://doi.org/10.1016/j.jrmge.2015.01.007>
- [25] Ghabraie, B., Ren, G., Zhang, X., & Smith, J. (2015). Physical modelling of subsidence from sequential extraction of partially overlapping longwall panels and study of substrata movement characteristics. *International Journal of Coal Geology*, (140), 71-83. <https://doi.org/10.1016/j.coal.2015.01.004>
- [26] Suchowerska Iwanec, A. M., Carter, J. P., & Hambleton, J. P. (2016). Geomechanics of subsidence above single and multi-seam coal mining. *Journal of Rock Mechanics and Geotechnical Engineering*, 8(3), 304-313. <https://doi.org/10.1016/j.jrmge.2015.11.007>
- [27] Zhang, B., Zhang, L., Yang, H., Yang, Z., & Tao, J. (2016). Subsidence prediction and susceptibility zonation for collapse above goaf with thick alluvial cover: a case study of the Yongcheng coalfield, Henan Province, China. *Bull Eng Geol Environ*, 75, 1117-1132. <https://doi.org/10.1007/s10064-015-0834-6>
- [28] Fathi Salmi, E., Nazem, M., & Karakus, M. (2017). Numerical analysis of a large landslide induced by coal mining subsidence. *Engineering Geology*, (217), 141-152. <https://doi.org/10.1016/j.enggeo.2016.12.021>
- [29] Ghabraie, B., Ren, G., Barbato, J., & V. Smith, J. (2017). A predictive methodology for multi-seam mining induced subsidence. *International Journal of Rock Mechanics & Mining Sciences*, 93, 280-294. <https://doi.org/10.1016/j.ijrmms.2017.02.003>
- [30] Pongpanya, P., Sasaoka, T., Shimada, T., & Wahyudi, S. (2017). Study of Characteristics of Surface Subsidence in Longwall Coal Mine under Poor Ground Conditions in Indonesia. *Earth Science Research*, 6(1). <https://doi.org/10.5539/esr.v6n1p129>

- [31] Cheng, J., Liu, F., & Li, S. (2017). Model for the prediction of subsurface strata movement due to underground mining. *Journal of Geophysics and Engineering*, 14(6), 1608-1623. <https://doi.org/10.1088/1742-2140/aa8238>
- [32] He, C., & Xu, J., (2018). Subsidence prediction of overburden strata and surface based on the voussoir beam structure theory. *Advances in Civil Engineering*. <https://doi.org/10.1155/2018/2606108>
- [33] Zhang, B., Ye, J., Zhang, Z., Xu, L., & Xu, N., (2019). A comprehensive method for subsidence prediction on two-seam longwall mining. *Energies*, 12(16), 3139. <https://doi.org/10.3390/en12163139>
- [34] Cui, X., Zhao, Y., Wang, G., Zhang, B., & Li, C. (2020). Calculation of residual surface subsidence above abandoned longwall coal mining. *Sustainability*, 12(4), 1528. <https://doi.org/10.3390/su12041528>
- [35] Guo, W., Zhao, G., Bai, E., Guo, M., & Wang, Y. (2021). Effect of overburden bending deformation and alluvium mechanical parameters on surface subsidence due to longwall mining. *Bulletin of Engineering Geology and the Environment*, 80, 2751-2764. <https://doi.org/10.1007/s10064-020-02091-4>
- [36] Pan, R., Li, Y., Wang, H., Chen, J., Xu, Y., Yang, H., & Cao, S., 2021. A new model for the identification of subcritical surface subsidence in deep pillarless mining. *Engineering Failure Analysis*, 129, 105631. <https://doi.org/10.1016/j.engfailanal.2021.105631>
- [37] Xu, J., Zhu, W., Xu, J., Wu, J., & Li, Y., 2021. High-intensity longwall mining-induced ground subsidence in Shendong coalfield, China. *International Journal of Rock Mechanics and Mining Sciences*, 141, 104730. <https://doi.org/10.1016/j.ijrmms.2021.104730>
- [38] Yan, Y., Li, M., Liu, J., Yan, W., Zhang, J., & Zhou, B. (2021). Ground subsidence evolution from 1000 m deep mining: a case study in Fengfeng mining area. *Shock and Vibration*, 2021, 1-9. <https://doi.org/10.1155/2021/9942968>
- [39] Prakash, A., Kumar, A., Verma, A., Mandal, S. K., & Singh, P. K. (2021). Trait of subsidence under high rate of coal extraction by longwall mining: Some inferences. *Sādhanā*, 46, 1-8. <https://doi.org/10.1007/s12046-021-01747-5>
- [40] Yin, H., Guo, G., Li, H., Wang, T., & Yuan, Y., (2022). Prediction method and research on characteristics of surface subsidence due to mining deeply buried Jurassic coal seams. *Bulletin of Engineering Geology and the Environment*, 81(10), 449. <https://doi.org/10.1007/s10064-022-02946-y>
- [41] Wang, K., Li, J., & Jin, Z. (2022). Influence of the primary key stratum on surface subsidence during longwall mining. *Sustainability*, 14(22), 15027. <https://doi.org/10.3390/su142215027>
- [42] Khanal, M., Qu, Q., Zhu, Y., Xie, J., Zhu, W., Hou, T., & Song, S. (2022). Characterization of overburden deformation and subsidence behavior in a kilometer deep longwall mine. *Minerals*, 12(5), 543. <https://doi.org/10.3390/min12050543>
- [43] Taherdito, A. H., Sulistianto, B., Karian, T., & Widodo, N. P. (2023). Surface Subsidence Prediction Using Numerical Method, Cased Study of Longwall Mining in Indonesia.
- [44] Diddle, B., Agioutantis, Z., Maldonado Esguerra, E., Romero Benitez, J. D., & Parra Valencia, M. (2024). Prediction of Dynamic and Final Vertical and Horizontal Movements Due to Longwall Mining. *Rock Mechanics and Rock Engineering*, 1-18. <https://doi.org/10.1007/s00603-024-04262-1>
- [45] Maldonado, E., Benitez, J. R., & Agioutantis, Z. (2024, June). Sensitivity analysis of a dynamic subsidence prediction model for longwall extraction. In *ARMA US Rock Mechanics/Geomechanics Symposium* (p. D042S056R001). ARMA. <https://doi.org/10.56952/ARMA-2024-0064>
- [46] Liu, X., Zhang, Y., Zhang, J., Yang, T., Jia, P., & Guo, R. (2024). Modelling surface subsidence of coal mines using a bonded block numerical method. *Geomatics, Natural Hazards and Risk*, 15(1), 2336017. <https://doi.org/10.1080/19475705.2024.2336017>
- [47] Cheng, G., Liu, H., Li, F., Nie, T., Wang, Q., & Peng, C. (2025). Study on subsidence evolution induced by coal mining under highway based on finite element simulation. *Energy Exploration & Exploitation*, 01445987241312703. <https://doi.org/10.1177/01445987241312703>
- [48] Rasouli, H., Shahriar, K., & Madani, S. H. (2021). Mine subsidence prediction using gene expression programming based on multivariable symbolic regression. *ITEGAM-JETIA*, 7(29), 13-24.
- [۴۹] خطیبی، ا.، شهریار، ک. (۱۳۸۷). تحلیل نشست سطح زمین در اثر استخراج زغال به روش جبهه کار طولانی-مطالعه موردی منطقه زغالدار طبس. *دومین کنفرانس مهندسی معدن/ایران، دانشگاه تهران، ۷ تا ۹ آبان ماه.*
- [۵۰] دباغ، ع.، فاتحی مرجی، م.، فرقانی، ح. (۱۳۸۸). شبیه سازی نشست سطح زمین در معادن لایه ای شیب دار با استفاده از روش المان مرزی ناپیوستگی در جابجایی. *نشریه علمی-پژوهشی مهندسی معدن، دوره ۴، شماره ۷، صفحه ۵۳ تا ۶۲.*
- [۵۱] نجفی، م.، عطائی، م. (۱۳۹۱). تخمین میزان نشست سطح زمین در روش جبهه کار بلند مکانیزه با استفاده از مدل سازی عددی،

مطالعه موردی: معدن زغال‌سنگ طبس. اولین کنگره ملی زغال‌سنگ ایران، دانشگاه شاهرود، ۸ تا ۱۰ شهریورماه.

- [52] Vapnik, V. N. (1995). The nature of statistical learning theory, New York: Springer.
- [53] Armaghani, D. J., Koopialipoor, M., Bahri, M., Hasanipanah, M., Tahir, M. M. (2020). A SVR-GWO technique to minimize flyrock distance resulting from blasting. *Bulletin of Engineering Geology and the Environment*, 79(8): 4369-4385. <https://doi.org/10.1007/s10064-020-01834-7>
- [54] Shi, X. Z., Jian, Z. H. O. U., Wu, B. B., Huang, D., Wei, W. E. I. (2012). Support vector machines approach to mean particle size of rock fragmentation due to bench blasting prediction. *Transactions of Nonferrous Metals Society of China*, 22(2): 432-441. [https://doi.org/10.1016/S1003-6326\(11\)61195-3](https://doi.org/10.1016/S1003-6326(11)61195-3)
- [55] Zhou, J., Li, X., Shi, X. (2012). Long-term prediction model of rockburst in underground openings using heuristic algorithms and support vector machines. *Safety science*, 50(4): 629-644. <https://doi.org/10.1016/j.ssci.2011.08.065>
- [56] Zhou, J., Qiu, Y., Zhu, S., Armaghani, D. J., Li, C., Nguyen, H., Yagiz, S. (2021). Optimization of support vector machine through the use of metaheuristic algorithms in forecasting TBM advance rate. *Engineering Applications of Artificial Intelligence*, 97: 104015. <https://doi.org/10.1016/j.engappai.2020.104015>
- [57] Rad, H. N., Hasanipanah, M., Rezaei, M., Eghlim, A. L. (2018). Developing a least squares support vector machine for estimating the blast-induced flyrock. *Engineering with Computers*, 34: 709-717. <https://doi.org/10.1007/s00366-017-0568-0>
- [58] Vapnik, V. (1999). The nature of statistical learning theory, Springer, Berlin.
- [59] Mohammadi-Balani, A., Nayeri, M.D., Azar, A., Taghizadeh-Yazdi, M. (2021). Golden eagle optimizer: A nature-inspired metaheuristic algorithm. *Computers & Industrial Engineering*, 152, 107050. <https://doi.org/10.1016/j.cie.2020.107050>
- [60] Zhang, P., Wu, H.N., Chen, R.P. and Chan, T.H. (2020). Hybrid meta-heuristic and machine learning algorithms for tunneling-induced settlement prediction: A comparative study. *Tunnelling and Underground Space Technology*, 99, 103383. <https://doi.org/10.1016/j.tust.2020.103383>
- [61]. Tang, L. and Na, S. (2021). Comparison of machine learning methods for ground settlement prediction with different tunneling datasets. *Journal of Rock Mechanics and Geotechnical Engineering*, 13(6), 1274-1289. <https://doi.org/10.1016/j.jrmge.2021.08.006>
- [62] Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: data mining, inference, and prediction (Vol. 2, pp. 1-758). New York: springer.
- [63] Draper, N. R., & Smith, H. (1998). Applied regression analysis (Vol. 326). John Wiley & Sons. <https://doi.org/10.1002/9781118625590>
- [64] Yagiz, S., Gokceoglu, C., Sezer, E., & Iplikci, S. (2009). Application of two non-linear prediction tools to the estimation of tunnel boring machine performance. *Engineering Applications of Artificial Intelligence*, 22(4-5), 808-814. <https://doi.org/10.1016/j.engappai.2009.03.007>
- [65] Bezerra, M. A., Santelli, R. E., Oliveira, E. P., Villar, L. S., & Escalera, L. A. (2008). Response surface methodology (RSM) as a tool for optimization in analytical chemistry. *Talanta*, 76(5), 965-977. <https://doi.org/10.1016/j.talanta.2008.05.019>
- [66] Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of geophysical research: atmospheres*, 106(D7), 7183-7192. <https://doi.org/10.1029/2000JD900719>
- [67] Bi, J., & Bennett, K. P. (2003). Regression error characteristic curves. In Proceedings of the 20th international conference on machine learning (ICML-03) (pp. 43-50).
- [68] Fattahi, H., & Babanouri, N. (2017). Applying optimized support vector regression models for prediction of tunnel boring machine performance. *Geotechnical and Geological Engineering*, 35(5), 2205-2217. <https://doi.org/10.1007/s10706-017-0238-4>
- [69] Yang, Y., & Zhang, Q. (1997). A hierarchical analysis for rock engineering using artificial neural networks. *Rock mechanics and rock engineering*, 30, 207-222. <https://doi.org/10.1007/BF01045717>



## Prediction of maximum ground surface subsidence induced by longwall mining using a hybrid support vector regression model optimized by golden eagle algorithm

Fariborz Matinpour<sup>1</sup>, Abbas Majdi<sup>2\*</sup>

<sup>1</sup>PhD Candidate, School of Mining Engineering, College of Engineering, University of Tehran, Tehran, Iran.

<sup>2</sup>Professor, School of Mining Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Received: 25. December. 2024      Accepted: 15. March. 2025  
(\*Corresponding author: amajdi@ut.ac.ir)

### Keywords

Longwall mining  
maximum ground surface subsidence  
Support vector regression (SVR)  
Golden eagle optimizer (GEO)  
Nonlinear multivariate regression (NLMR)

### Final English Extended Abstract

This study aims to develop accurate data-driven models for predicting the maximum ground surface subsidence ( $S_{max}$ ) induced by longwall coal mining, one of the key challenges in mining engineering. Accurate prediction of  $S_{max}$  is crucial for minimizing damage to surface and subsurface structures and enhancing operational safety. A total of 46 datasets from literature, involving three influential parameters including coal seam thickness ( $h_s$ ), depth of cover ( $H$ ), and panel width ( $L_w$ ), were collected. Two predictive models were developed: a support vector regression (SVR) model optimized using the Golden Eagle Optimization (GEO) algorithm (SVR-GEO), and a nonlinear multivariate regression model (NLMR). The generalization ability of SVR-GEO was validated using 5-fold cross-validation. Models' performance in both training and testing phases was evaluated using Taylor diagrams, regression error characteristic (REC) curves, and six statistical indices ( $R^2$ , VAF,  $a20$ , RMSE, MAE, and MAPE), and compared against six empirical equations. Results showed that SVR-GEO outperformed both NLMR and empirical models, achieving  $R^2$  values of 0.988 (training) and 0.942 (testing). Sensitivity analysis revealed that coal seam thickness ( $h_s$ ) had the greatest impact on  $S_{max}$ , followed by panel width ( $L_w$ ) and depth of cover ( $H$ ). The SVR-GEO model is proposed as a robust and reliable tool for predicting  $S_{max}$  in longwall mining projects.

### Introduction

Longwall mining often causes ground surface subsidence due to stress redistribution and roof collapse in the mined-out area. Accurate prediction of maximum subsidence ( $S_{max}$ ) is essential for protecting surface and subsurface structures and ensuring operational safety. Current empirical equations have attempted to estimate  $S_{max}$  using key parameters such as coal seam thickness ( $h_s$ ), depth of cover ( $H$ ), and panel width ( $L_w$ ), but they often fall short in accuracy and generalizability. This study develops and compares two predictive models: a Support Vector Regression (SVR) model optimized via the Golden Eagle Optimization (GEO) algorithm (SVR-GEO), and a Nonlinear Multivariate Regression (NLMR) model. Using validated in-situ datasets, the models are assessed against current empirical equations based on statistical indices and visual diagnostic tools to identify the most robust approach for predicting  $S_{max}$  due to longwall mining operations.

### Methodology and Approaches

In this study, two new data-driven models of SVR-GEO and NLMR were developed to predict the maximum ground surface subsidence ( $S_{max}$ ) caused by longwall coal mining. A database of 46 reliable in situ cases including  $h_s$ ,  $H$ , and  $L_w$  was compiled. The SVR-GEO model was trained and validated using 5-fold cross-validation to ensure generalization and robustness. Both models were evaluated and compared with six current empirical equations using Taylor diagrams,



Regression Error Characteristic (*REC*) curves, and six statistical indicators:  $R^2$ , *VAF*, *a20*, *RMSE*, *MAE*, and *MAPE*. Sensitivity analysis was also conducted to determine the relative importance of input parameters.

### Results and Conclusions

The *SVR-GEO* and *NLMR* models were evaluated for predicting  $S_{max}$  and compared with current empirical equations using six statistical indices. *SVR-GEO* achieved the highest accuracy in both training ( $R^2 = 0.988$ , *MAPE* = 5.7%) and testing ( $R^2 = 0.942$ , *MAPE* = 19.71%) phases, significantly outperforming *NLMR* and all empirical equations, whose  $R^2$  values ranged between 0.579–0.667 (training) and 0.823–0.855 (testing). Moreover, Taylor diagrams and *REC* curves confirmed the superior performance of *SVR-GEO* model. Sensitivity analysis showed coal seam thickness ( $h_s$ ) had the greatest impact on  $S_{max}$ , followed by panel width ( $L_w$ ) and overburden depth ( $H$ ). These results establish *SVR-GEO* model as a robust and reliable tool for more accurate prediction of  $S_{max}$  in longwall mining.

---