

### استفاده از الگوریتم بهینه‌سازی گرگ خاکستری برای تخمین پارامترهای نشست سطح زمین بر اساس شرایط زمین‌شناسی، هندسه تونل و فاکتورهای عملیاتی دستگاه حفاری

#### مقاله پژوهشی

محمد رضائی<sup>۱\*</sup>؛ فریبرز متین‌پور<sup>۲</sup>؛ شادمان محمدی بلبان‌آباد<sup>۳</sup>؛ وهاب سرفرازی<sup>۴</sup>

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

۲- دانشجوی دکتری مکانیک سنگ؛ دانشکده‌ی مهندسی معدن، دانشکده فنی، دانشگاه تهران، f.gorgeh@ut.ac.ir

۳- دانشجوی دکتری استخراج معدن؛ گروه معدن، دانشکده‌ی مهندسی، دانشگاه تربیت مدرس، shadman.mohammadi@modares.ac.ir

۴- دانشیار؛ گروه مهندسی معدن، دانشگاه صنعتی همدان، sarfarazi@hut.ac.ir

دریافت دست‌نوشته: ۱۴۰۳/۰۲/۰۸؛ پذیرش دست‌نوشته: ۱۴۰۳/۰۷/۰۲

شماره صفحات: ۶۱ تا ۸۰

شناسه دیجیتال (DOI): 10.22044/tuse.2024.14468.1485

واژگان کلیدی	چکیده
تونل‌سازی حداکثر نشست سطح زمین عرض گودی پروفیل نشست بهینه‌سازی گرگ خاکستری رگرسیون خطی چندگانه	در این مقاله از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) برای پیش‌بینی حداکثر نشست سطح زمین ( $S_{max}$ ) و عرض گودی پروفیل نشست ( $i$ ) ناشی از عملیات حفاری تونل‌های شهری استفاده شده است. بدین منظور، ۲۶ دسته داده با دو پارامتر خروجی ( $S_{max}$ و $i$ ) و ۹ پارامتر ورودی شامل چسبندگی ( $C$ )، زاویه اصطکاک داخلی ( $\phi$ )، مدول تراکم‌پذیری خاک ( $E_s$ )، فاصله محور تونل از سطح زمین ( $H$ )، قطر تونل ( $D$ )، فشار تزریق گروت ( $P$ )، درصد پرشدن گروت ( $n$ )، نیروی پیشران ( $F$ ) و نرخ پیشروی ( $v$ ) دستگاه حفاری جهت مدل‌سازی الگوریتم GWO گردآوری شد. همچنین، مدل رگرسیون خطی چندگانه (MLR) جهت ارزیابی و مقایسه با الگوریتم GWO استفاده گردید. عملکرد مدل‌های GWO و MLR با استفاده از سه شاخص آماری ضریب تعیین، جذر میانگین مربعات خطا و خطای مطلق میانگین در مراحل آموزش و تست مورد بررسی قرار گرفت و با نتایج مدل‌های تجربی موجود در منابع مقایسه گردید. نتایج حاصله بیانگر خطای کمتر الگوریتم GWO و قابلیت اطمینان و دقت بالاتر آن در مقایسه با مدل MLR و سایر مدل‌های تجربی است. علاوه بر آنالیز حساسیت مدل‌ها و همبستگی داده‌ها نشان داد که پارامترهای $F$ و $n$ به‌ترتیب مهم‌ترین و کم‌اهمیت‌ترین پارامترهای تأثیرگذار بر $S_{max}$ هستند. همچنین، $C$ و $v$ به‌ترتیب دارای بیش‌ترین و کم‌ترین تأثیر بر $i$ می‌باشند. با در نظر گرفتن نتایج حاصل از این تحقیق، می‌توان نتیجه گرفت که مدل‌های پیشنهادی (به ویژه مدل GWO) از قابلیت بالایی برای تخمین پارامترهای نشست سطح زمین برخوردارند.

۱- مقدمه  
مناطق شهری می‌شود. بسیاری از سازه‌های سطحی و زیرسطحی به دلیل اثرات ناشی از تغییر شکل و نشست سطح زمین، احداث سازه‌های زیرزمینی را با چالش مواجه می‌سازد

افزایش تقاضا برای توسعه زیرساخت‌ها باعث اهمیت هر چه بیشتر صنعت تونل‌سازی در زمین‌های نرم و کم عمق در

\* کردستان؛ سنجند؛ بلوار پاسداران؛ دانشگاه کردستان؛ دانشکده‌ی مهندسی؛ ساختمان شماره ۳؛ گروه معدن؛ طبقه‌ی دوم؛ کدپستی: ۶۶۱۷۷۱۵۱۷۵؛ شماره‌ی تلفن: ۰۷۳-۳۳۶۶۰۰۷۳-۰۸۷؛ دورنگار: ۰۸۷-۳۳۶۶۸۵۱۳

تخمین عرض گودی پروفیل نشست  $i$  وابسته به دو پارامتر قطر و عمق تونل هستند. بعلاوه، روابط تحلیلی اگرچه ابزار مفیدی برای پیش‌بینی حداکثر نشست سطح زمین هستند، اما نمی‌توانند تمام پارامترهای تأثیرگذار را در مدل‌سازی نشست سطح زمین در نظر بگیرند. در نهایت، برآورد مقادیر قابل اعتماد به‌عنوان پارامترهای ورودی برای استفاده از روش‌های عددی پیچیده، کار بسیار دشواری است.

با توجه به پیشینه تحقیق می‌توان دریافت که در دو دهه گذشته استفاده از روش‌های مبتنی بر هوش مصنوعی به‌منظور پیش‌بینی حداکثر نشست سطح زمین ناشی از عملیات تونل‌سازی، بدلیل دقت و کارایی بالا مورد استقبال بسیاری از محققان قرار گرفته است. به‌طور کلی در تمامی این تحقیقات از الگوریتم‌های یادگیری ماشین از جمله شبکه عصبی مصنوعی، ماشین بردار پشتیبان، درخت تصمیم و ... به‌منظور پیش‌بینی حداکثر نشست سطح زمین استفاده شده است. هر کدام از الگوریتم‌های یادگیری ماشین دارای تعدادی آبر پارامتر هستند که عموماً با استفاده از پروسه سعی و خطا و یا تکنیک‌هایی همچون جستجوی شبکه‌ای و جستجوی تصادفی مقادیر آن‌ها به‌دست می‌آید. از طرفی، همیشه نمی‌توان با استفاده از تکنیک‌های نامبرده، مقادیر بهینه آبر پارامترها را برای یک مسئله خاص پیدا نمود. بنابراین، در بسیاری از تحقیقات انجام شده در این حوزه از الگوریتم‌های بهینه‌سازی فرا ابتکاری همچون الگوریتم ژنتیک، الگوریتم بهینه‌سازی ازدحام ذرات و ... برای دستیابی به مقادیر بهینه آبر پارامترها در الگوریتم‌های یادگیری استفاده شده است. در واقع، در این رویکرد ترکیبی، وظیفه پیش‌بینی پارامتر هدف بر عهده الگوریتم یادگیری ماشین و وظیفه تعیین آبر پارامترهای مناسب الگوریتم یادگیری ماشین بر عهده الگوریتم بهینه‌سازی است. استفاده از چنین رویکردی در تحقیقات اخیر بسیار رایج بوده و روز به روز در حال افزایش می‌باشد.


که قطعاً باید تا سطوح قابل قبول محدود و یا کنترل شوند (Ercelebi et al., 2011). هزینه‌های تونل‌سازی به‌دلیل آسیب‌های وارده به سازه‌ها ناشی از مقادیر نشست بیشتر از حد مجاز، به‌طور قابل ملاحظه‌ای افزایش می‌یابد. بنابراین، پیش‌بینی و کنترل نشست سطح زمین به‌منظور مدیریت و کاهش این هزینه‌ها امری ضروری می‌باشد. بررسی داده‌های پروژه‌های مختلف تونل‌سازی نشان می‌دهد که شکل پروفیل دو بُعدی گودی نشست سطح زمین به‌صورت منحنی توزیع نرمال گوسی زیر است (Peck, 1969):

$$S = S_{max} \exp\left(-\frac{x^2}{2i^2}\right) \quad (1)$$

در رابطه ۱،  $S$  نشست سطحی در نقطه‌ای به فاصله  $x$  از محور تونل،  $S_{max}$  حداکثر نشست سطح زمین و  $i$  عرض گودی پروفیل نشست (فاصله محل نقطه عطف یا بیش‌ترین شیب منحنی نشست از محور تونل) است.

بسیاری از مطالعات قبلی که بر مبنای روش‌های تجربی (Hamza, et al., 1999)، تحلیلی (Park, 2005)، عددی (Chakeri, et al., 2013) و (Bagheri, et al., 2020)، و هوش مصنوعی (Neaupane & Adhikari, 2006) (Ocak & Santos & Celestino, 2008)، (Seker, 2013) (Zhou, et al., 2016)، (Hasanipanah, et al., 2016) (Moghaddasi & Noorian-Bidgoli, 2018) (Zhang, et al., 2020)، (Mahmoodzadeh, et al., 2020) و (Moghtader, et al., 2023) در زمینه نشست ناشی از تونل‌سازی در محیط‌های شهری توسط دیگر محققان انجام شده است، معطوف به پیش‌بینی پارامترهای  $S_{max}$  و  $i$  هستند (Amjadi, et al., 2021) و (Rahmannejad, et al., 2014). برخی از روابط ارائه شده توسط محققین مختلف جهت پیش‌بینی  $S_{max}$  و  $i$  در جدول ۱، نشان داده شده است. از این جدول می‌توان دریافت که روابط تجربی ارائه شده بر اساس اندازه‌گیری برجا و یا نتایج آزمایشگاهی، تأثیر پارامترهای ذاتی خاک را در پیش‌بینی  $S_{max}$  در نظر نمی‌گیرند. همچنین، اکثر روابط ارائه شده برای





شکل ۱- فراوانی کاربردهای الگوریتم *GWO* (Faris, et al., 2018)

## ۲- مواد و روش‌ها

همانطور که قبلاً اشاره شد، در این تحقیق از الگوریتم بهینه‌سازی گرگ خاکستری (*GWO*) و مدل رگرسیون خطی چندگانه (*MLR*) به منظور پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین استفاده شده است که در این بخش به صورت خلاصه به معرفی این دو روش و نحوه عملکرد آنها پرداخته می‌شود.

### ۲-۱- مدل رگرسیون خطی چندگانه

رگرسیون خطی چندگانه، یک تکنیک آماری قدیمی است که به استفاده پیرسون از آن در سال ۱۹۰۸ برمی‌گردد. این تکنیک برای پیش‌بینی واریانس در یک بازه وابسته، بر اساس ترکیب‌های خطی متغیرهای مستقل بازه‌ای، دوگانه و ساختگی استفاده می‌شود. هدف کلی رگرسیون خطی چندگانه کسب اطلاعات بیشتر در مورد رابطه بین چندین متغیر مستقل یا پیش‌بینی کننده و یک متغیر وابسته یا معیار است. معادله رگرسیون خطی چندگانه به صورت رابطه ۲ می‌باشد (Yilmaz & Kaynar, 2011).

$$y = b_1x_1 + b_2x_2 + \dots + b_nx_n + c \quad (2)$$

در رابطه ۲،  $b_1, b_2, \dots, b_n$  و  $c$  ضرایب رگرسیونی هستند که مقدار تغییرات متغیر وابسته  $y$  زمانیکه متغیر مستقل مربوطه به اندازه ۱ واحد تغییر می‌کند را نشان می‌دهند. ثابت  $c$  عرض از مبدأ خط رگرسیون است که مقدار  $y$  را زمانی که متغیرهای مستقل برابر صفر هستند نشان می‌دهد (Yilmaz & Kaynar, 2011).

گرگ خاکستری (*GWO*) برای پیش‌بینی حداکثر نشست سطح زمین و عرض گودی پروفیل نشست ناشی از عملیات تونل‌سازی در محیط‌های کم عمق شهری و بررسی مهم‌ترین پارامترهای تأثیرگذار بر آن‌ها استفاده و نتایج حاصله با مدل رگرسیون خطی چندگانه (*MLR*) و مدل‌های تجربی موجود مقایسه شده است. داده‌های جمع‌آوری شده برای مدل‌سازی مربوط به ۳ پروژه مترو در چین می‌باشد. انتخاب *GWO* برای تخمین پارامترهای نشست به دلایل زیر صورت گرفته است:

(۱) سهولت استفاده و سرعت همگرایی بالا: *GWO* نسبت به دیگر الگوریتم‌های بهینه‌سازی از جمله الگوریتم ژنتیک و الگوریتم بهینه‌سازی ازدحام ذرات تعداد پارامتر کنترلی کمتری دارد و لذا دستیابی به مقدار مناسب این پارامترها، مراحل کدنویسی و درک الگوریتم آسان‌تر است. این الگوریتم به دلیل داشتن ساختار ساده و حجم فرمول‌بندی ریاضی کم از پیچیدگی محاسباتی کمتری نسبت به الگوریتم ژنتیک برخوردار است. از سوی دیگر، پیاده‌سازی آن همانند الگوریتم بهینه‌سازی ازدحام ذرات آسان بوده و می‌تواند برای پایگاه داده‌های بزرگ‌تر نیز مورد استفاده قرار گیرد. در نهایت، سرعت همگرایی بیشتری نسبت به الگوریتم ژنتیک و الگوریتم بهینه‌سازی ازدحام ذرات داشته و می‌تواند در زمان واقعی به جواب بهینه دسته یافته و مورد استفاده قرار گیرد (Emary, et al., 2015).

(۲) در مقاله مرجع الگوریتم *GWO*، تعداد زیادی مسئله بهینه‌سازی و نیز واقعی با استفاده از این الگوریتم حل و نتایج حاصله با سایر الگوریتم‌های بهینه‌سازی مقایسه شده است. نتایج حاصل از این مقایسه نشان داده است که *GWO* نسبت به سایر الگوریتم‌های مشابه عملکرد بهتری دارد.

(۳) کاربرد بیشتر این الگوریتم در حوزه مهندسی (شکل ۱) نسبت به دیگر حوزه‌ها نشان‌دهنده کارا بودن این الگوریتم در حل مسائل مهندسی است (Faris, et al., 2018).

(۴) جدید بودن الگوریتم (توسعه در سال ۲۰۱۴) نسبت به الگوریتم بهینه‌سازی ازدحام ذرات (توسعه در سال ۱۹۹۵) و الگوریتم ژنتیک (توسعه در سال ۱۹۷۰).

## ۲-۲- الگوریتم بهینه‌سازی گرگ خاکستری

ایده تقلید از سلسله مراتب رهبری اجتماعی و رفتار شکار گرگ‌های خاکستری در مسائل بهینه‌سازی منجر به تکنیک بهینه‌سازی گرگ خاکستری شده است (Mirjalili, et al., 2014). الگوریتم *GWO* که یک الگوریتم جدید در میان الگوریتم‌های بهینه‌سازی هوش ازدحامی مبتنی بر جمعیت می‌باشد، دارای چندین مزیت جذاب از جمله سادگی، انعطاف‌پذیری، مکانیسم بدون مشتق و اجتناب از بهینه محلی است. همچنین، اجرای این الگوریتم آسان بوده و پارامترهای کنترلی کمتری برای تنظیم (تعدیل) داشته و مشخصه همگرایی سریعی دارد. تاکنون عمده کاربردهای این الگوریتم در حل مسائل مهندسی بوده (شکل ۱) و به‌طور گسترده‌ای در این حوزه استفاده شده است که نشان‌دهنده کارایی بالای آن می‌باشد (Faris, et al., 2018). در ادامه، مراحل مدل‌سازی ریاضی سلسله مراتب اجتماعی و رفتار شکار گرگ‌های خاکستری به‌منظور طراحی الگوریتم *GWO* تشریح شده است (Mirjalili, et al., 2014).

### ۲-۲-۱- سلسله مراتب اجتماعی

گرگ خاکستری از خانواده *Canidae* است. گرگ‌های خاکستری به‌عنوان شکارچیان رأس در نظر گرفته می‌شوند، به این معنی که در بالای زنجیره غذایی قرار دارند و بیشتر ترجیح می‌دهند که در یک گله زندگی کنند. جالب توجه این است که آنها یک سلسله مراتب اجتماعی غالب از آلفا ( $\alpha$ )، بتا ( $\beta$ )، دلتا ( $\delta$ ) تا امگا ( $\omega$ ) دارند. به‌منظور مدل‌سازی ریاضی سلسله مراتب اجتماعی گرگ‌های خاکستری هنگام طراحی *GWO*، مناسب‌ترین راه‌حل به‌عنوان آلفا ( $\alpha$ ) در نظر گرفته می‌شود. همچنین، دومین و سومین راه‌حل برتر به‌ترتیب با بتا ( $\beta$ ) و دلتا ( $\delta$ ) نشان داده می‌شوند. بقیه راه‌حل‌های کاندید به‌عنوان امگا ( $\omega$ ) فرض می‌شوند. در الگوریتم *GWO*، شکار (بهینه‌سازی) توسط  $\alpha$ ،  $\beta$  و  $\delta$  هدایت شده و گرگ‌های  $\omega$  از این سه گرگ پیروی می‌کنند.

### ۲-۲-۲- احاطه کردن طعمه

علاوه بر سلسله مراتب اجتماعی گرگ‌های خاکستری که در مرحله قبل توضیح داده شد، شکار گروهی یکی دیگر از رفتارهای اجتماعی جالب گرگ‌های خاکستری است. مراحل اصلی شکار گرگ خاکستری شامل (۱) ردیابی، تعقیب، و

نزدیک شدن به طعمه، (۲) محاصره کردن، تعقیب و آزار شکار تا زمانی که از حرکت باز بماند و (۳) حمله به سمت طعمه می‌باشد. به‌منظور مدل‌سازی ریاضی رفتار محاصره‌ای، معادلات زیر پیشنهاد شده است (Mirjalili, et al., 2014):

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (3)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (4)$$

که در آن،  $t$  نشان‌دهنده تکرار فعلی،  $\vec{A}$  و  $\vec{C}$  بردارهای ضرایب،  $\vec{X}_p$  بردار موقعیت شکار (طعمه) و  $\vec{X}$  بردار موقعیت گرگ خاکستری می‌باشد. بردارهای  $\vec{A}$  و  $\vec{C}$  به‌صورت زیر به‌دست می‌آیند:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (5)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (6)$$

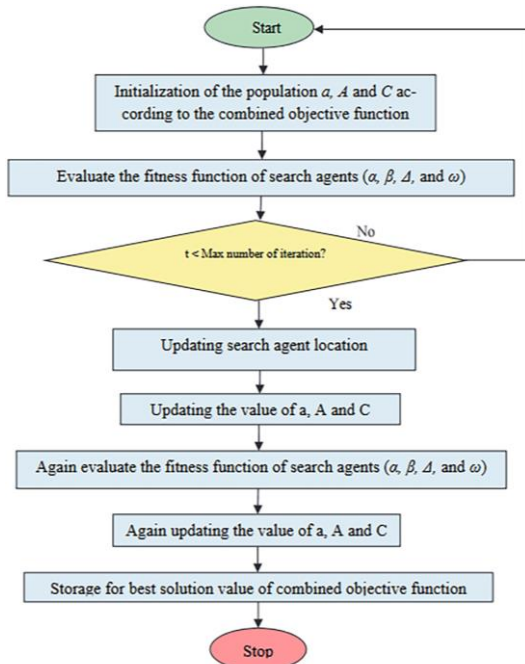
در روابط ۵ و ۶،  $\vec{a}$  مؤلفه‌های  $\vec{a}$  از ۲ تا ۰ در طول تکرارها به‌طور خطی کاهش می‌یابند و  $\vec{r}_1$  و  $\vec{r}_2$  بردارهای تصادفی در بازه [۰, ۱] هستند.

### ۲-۲-۳- جستجوی طعمه (اکتشاف)

گرگ‌های خاکستری بیشتر براساس موقعیت آلفا، بتا و دلتا جستجو می‌کنند. آنها برای جستجوی طعمه از یکدیگر جدا شده و برای حمله به طعمه همگرا می‌شوند. به‌منظور مدل‌سازی ریاضی واگرایی،  $A$  با مقادیر تصادفی بزرگ‌تر از ۱ یا کمتر از ۱- استفاده می‌شود تا عامل جستجو را وادار به واگرایی از طعمه کند. این کار بر اکتشاف تاکید می‌کند و این اجازه را به *GWO* می‌دهد تا در سطح جهانی جستجو نماید. یعنی،  $|A| \geq 1$  تعدادی از گرگ‌های خاکستری را مجبور می‌کند تا از طعمه جدا شده و شکار مناسب‌تری پیدا کنند.

یکی دیگر از اجزای *GWO* که به کاوش کمک می‌کند،  $C$  است. بردار  $C$  حاوی مقادیر تصادفی در بازه [۰, ۲] است. این مؤلفه وزن‌های تصادفی را برای طعمه به منظور تاکید تصادفی ( $C \geq 1$ ) یا تاکید کمتر ( $C < 1$ ) بر تأثیر طعمه در تعریف فاصله در معادله (۳) فراهم می‌کند. این به *GWO* برای نشان دادن یک رفتار تصادفی‌تر در طول بهینه‌سازی، اکتشاف و اجتناب از نقطه بهینه محلی کمک می‌کند. شایان ذکر است که  $C$  در مقایسه با  $A$  به‌صورت خطی کاهش نمی‌یابد. *GWO* به  $C$  نیاز دارد تا مقادیر

بهره‌برداری توسط مقادیر تطبیقی  $a$  و  $A$  تضمین می‌شود. با کاهش  $A$ ، نیمی از تکرارها به اکتشاف ( $|A| \geq 1$ ) و نیمی دیگر به بهره‌برداری ( $|A| < 1$ ) اختصاص می‌یابد. مراحل مدل‌سازی الگوریتم بهینه‌سازی گرگ خاکستری در شکل ۲، نشان داده شده است. مراحل فوق تا رسیدن الگوریتم  $GWO$  به معیار توقف جهت دستیابی به جواب بهینه نهایی، تکرار می‌شود (Chawla, et al., 2019).



شکل ۲- فلوجارت مدل‌سازی با استفاده از الگوریتم  $GWO$  (Chawla et al., 2019)

### ۳- جمع‌آوری داده‌ها

هدف اصلی این تحقیق، پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین ناشی از عملیات تونل‌سازی در محیط‌های شهری با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری و مقایسه نتایج حاصل از این روش با مدل رگرسیون خطی چندگانه می‌باشد. برای دستیابی به این مهم، ۳ دسته پارامتر شامل ۹ ورودی تأثیرگذار بر نشست ناشی از تونل‌سازی سپری از جمله (الف) شرایط زمین‌شناسی لایه‌ها (چسبندگی، زاویه اصطکاک داخلی، مدول الاستیسته خاک)، (ب) هندسه تونل (فاصله محور تونل از سطح زمین، قطر تونل)، و (ج) فاکتورهای عملیاتی دستگاه حفاری (فشار تزریق گروت، درصد پرشدن

تصادفی را در همه زمان‌ها ارائه کند تا از این طریق بر اکتشاف و بهره‌برداری نه تنها در طول تکرارهای اولیه، بلکه در تکرارهای نهایی نیز تأکید شود. این مؤلفه در رابطه با رکود نقاط بهینه محلی به‌ویژه در تکرارهای نهایی بسیار مفید است.

### ۲-۲-۴- حمله به طعمه (استثمار)

به‌منظور مدل‌سازی ریاضی نزدیک شدن به طعمه، مقدار  $a$  به‌صورت خطی کاهش می‌یابد. بنابراین،  $A$  یک مقدار تصادفی در بازه  $[-a, a]$  است. هنگامی که مقادیر تصادفی  $A$  در بازه  $[-1, 1]$  ( $|A| < 1$ ) باشد،  $GWO$  گرگ‌ها را مجبور می‌کند به سمت طعمه حمله کنند.

### ۲-۲-۵- شکار

به‌منظور شبیه‌سازی ریاضی رفتار شکار گرگ‌های خاکستری، سه راه‌حل اول (آلفا، بتا و دلتا) که تاکنون بهترین راه‌حل به‌دست آمده هستند، ذخیره می‌شوند و سایر عوامل جستجو (از جمله امگا) را موظف می‌کنند تا موقعیت‌های خود را مطابق با موقعیت بهترین عوامل جستجو به‌روز رسانی کنند. بدین منظور، روابط ۷ تا ۹ پیشنهاد شده‌اند (Mirjalili, et al., 2014).

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (7)$$

$$\vec{X}_1 = \vec{X}_\alpha - A_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - A_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - A_3 \cdot (\vec{D}_\delta) \quad (8)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (9)$$

به‌طور خلاصه، فرآیند جستجو با ایجاد یک جمعیت تصادفی از گرگ‌های خاکستری (راه‌حل‌های کاندید) در الگوریتم  $GWO$  شروع می‌شود. در طی تکرارها، گرگ‌های آلفا، بتا و دلتا موقعیت احتمالی طعمه را تخمین می‌زنند. هر راه‌حل کاندید فاصله خود را از طعمه به‌روز رسانی می‌کند. پارامتر  $a$  از ۲ به ۰ کاهش می‌یابد تا به‌ترتیب بر اکتشاف و بهره‌برداری تأکید شود. وقتی  $|A| \geq 1$  راه‌حل‌های کاندید از طعمه واگرا می‌شوند و وقتی  $|A| < 1$  به سمت طعمه همگرا می‌شوند. در نهایت، الگوریتم  $GWO$  با ارضای یک معیار نهایی خاتمه می‌یابد. الگوریتم  $GWO$  فقط یک پارامتر اصلی ( $a$ ) دارد که باید تنظیم شود. مقادیر تطبیقی پارامترهای  $a$  و  $A$  به  $GWO$  اجازه می‌دهد به آرامی بین اکتشاف و بهره‌برداری جابه‌جا شود. بنابراین، اکتشاف و

گروت، نیروی پیشران و نرخ پیشروی دستگاه حفاری) بر اساس ۲۶ دسته داده جمع‌آوری شده مربوط به ۳ پروژه تونل‌سازی خط ۱ مترو نانجینگ، خط ۲ مترو گوانگژو و خط ۲ مترو شانگهای در چین توسط (Qu, 2005)، به‌منظور پیاده‌سازی دو مدل *GWO* و *MLR*، مورد استفاده قرار گرفته است. داده‌های جمع‌آوری شده در جدول ۲ و اطلاعات آماری داده‌های مورد استفاده در این تحقیق در جدول ۳، آورده شده است.

جدول ۲- پارامترهای هندسی، ژئومکانیکی و عملیاتی مورد استفاده به‌منظور پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین (Qu, 2005)

No.	<i>C</i> (kPa)	$\phi$ (degree)	<i>E<sub>s</sub></i> (MPa)	<i>H</i> (m)	<i>D</i> (m)	<i>P</i> (MPa)	<i>n</i> (%)	<i>F</i> (MN)	<i>v</i> (mm/min)	<i>i</i> (m)	<i>S<sub>max</sub></i> (mm)
۱	۳۲,۴۰	۱۰,۷	۱۱,۱۷	۱۴,۵	۶,۴۰	۰,۲۵	۱,۷	۳۱,۶۵	۶۰	۵,۳۷	۲۲
۲	۶۵۰	۲۹,۸	۲۱,۸۳	۲۳	۶,۲۵	۰,۲۰	۱,۱	۳۳	۴۰	۱۴,۵۴	۳۸
۳	۱۲	۱۳,۷	۵,۲۱	۱۲	۶,۳۴	۰,۳۵	۱,۵	۱۴	۳۰	۷,۴۸	۵۷
*۴	۱۱,۸	۱۴,۷	۵,۶۷	۱۰,۴	۶,۳۴	۰,۴۰	۱,۸	۱۴	۲۰	۵,۳۹	۴۰,۶
۵	۱۲	۱۳,۷	۵,۲۰	۱۱,۸	۶,۳۴	۰,۳۵	۱,۴	۱,۴	۴۰	۷,۵۱	۷۹,۶
۶	۱۱,۹	۱۳,۸	۵,۲۲	۱۱,۲	۶,۳۴	۰,۳۰	۱,۷	۱۴	۳۰	۷,۳۲	۶۲,۵
۷	۱۱,۲	۱۹,۵	۸,۲۶	۶,۱	۶,۳۴	۰,۳۰	۱,۴	۱۴	۴۰	۴,۳۵	۸۴,۵
۸	۳۴,۲	۱۴,۵	۷,۲۶	۱۴,۵	۶,۴	۰,۲۵	۱,۷	۳۱,۶۵	۵۰	۷,۱۱	۱۶,۴
*۹	۱۱,۸	۱۵,۲	۵,۹۱	۹,۷۸	۶,۳۴	۰,۳۵	۱,۷	۱۴	۲۰	۴,۷۷	۴۳,۳
*۱۰	۱۱,۸	۱۴,۴	۵,۵۳	۱۰,۹۰	۶,۳۴	۰,۴۰	۲	۱۴	۲۰	۵,۸۱	۲۷,۱
۱۱	۱۲,۱	۱۳,۷	۵,۲۱	۱۲	۶,۳۴	۰,۳۵	۱,۷	۳۱,۶۵	۳۰	۷,۴۶	۵۵,۳
۱۲	۱۱,۹	۱۳,۸	۵,۲۲	۱۱,۹	۶,۳۴	۰,۴	۲	۱۴	۲۰	۷,۲۵	۲۱,۲
۱۳	۴۳,۶	۳۰	۹,۱۲	۱۴,۵	۶,۴	۰,۲۵	۱,۵	۳۱,۶۵	۶۰	۱۰	۸,۹
۱۴	۳۶,۷	۲۰,۷	۷,۲۶	۱۳,۸	۶,۴	۰,۲۵	۱,۷	۳۱,۶۵	۶۰	۷,۰۴	۷,۵
۱۵	۱۲	۱۳,۴	۵,۰۱	۱۲,۷	۶,۳۴	۰,۴	۲	۱۴	۲۰	۹,۳۴	۳۲,۸
*۱۶	۱۱,۹	۱۳,۸	۵,۲۲	۱۰,۵	۶,۳۴	۰,۲۵	۱,۴	۱۴	۴۰	۷,۵۳	۸۹,۹
۱۷	۳۴,۲	۹,۲	۷,۲۶	۱۴,۵	۶,۴۰	۰,۲۵	۱,۷	۳۱,۶۵	۶۰	۵,۲۲	۲۲,۸
۱۸	۳۲,۴	۱۲,۴	۱۱,۱۷	۱۴,۲	۶,۴۰	۰,۲۵	۱,۷	۳۱,۶۵	۶۰	۶,۳۹	۱۴,۸
۱۹	۳۱۰	۴۴,۱	۴۰,۷۵	۲۰	۶,۲۵	۰,۳۰	۱,۳	۳۳	۳۰	۹,۷۷	۴,۳
*۲۰	۱۵,۳	۲۳,۹	۳,۸۷	۱۲	۶,۴۰	۰,۳۰	۱,۵	۳۱,۶۵	۴۰	۶,۸۴	۷,۶
۲۱	۱۱,۹	۱۴,۱	۵,۳۵	۱۱,۴	۶,۳۴	۰,۴۰	۱,۸	۱۴	۲۰	۶,۴	۳۸,۱
*۲۲	۲۳۴	۴۴,۹	۳۵,۰۲	۱۲	۶,۲۵	۰,۲۰	۰,۹	۳۳	۳۰	۸,۹۱	۹,۲
۲۳	۱۱,۷	۱۶,۴	۶,۴۸	۸,۴	۶,۳۴	۰,۳۰	۱,۷	۱۴	۳۰	۴,۶۴	۶۳,۳
۲۴	۲۸,۱	۱۲,۸	۵,۴۲	۱۳,۳۰	۶,۴	۰,۲۵	۱,۵	۳۱,۶۵	۴۰	۹,۷۱	۹,۶
۲۵	۱۱,۹	۱۳,۸	۵,۲۲	۱۱,۹	۶,۳۴	۰,۴۰	۱,۸	۱۴	۲۰	۷,۲۷	۳۸,۶
۲۶	۶۸۰	۳۰,۳	۲۳,۵۷	۲۴	۶,۲۵	۰,۳۰	۱,۲	۳۳	۳۰	۱۶,۳۲	۱۶,۸

\* نمونه‌هایی که توسط الگوریتم *GWO* به‌صورت تصادفی به‌عنوان نمونه تست انتخاب شده‌اند.


جدول ۳- اطلاعات آماری داده‌های مورد استفاده برای پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین

نوع داده	پارامتر	واحد	نماد	حداقل	میانگین	حداکثر	انحراف معیار	واریانس
	مقاومت چسبندگی	kPa	C	۱۱,۲۰	۸۸,۳۴	۶۸۰	۱۸۰,۱۲	۳۲۴۴۳,۷۳
	زاویه اصطکاک داخلی	Degree	$\Phi$	۹,۲۰	۱۸,۷۴	۴۴,۹۰	۹,۳۴	۸۷,۲۱
	مدول الاستیسیته خاک	MPa	$E_s$	۳,۸۷	۱۰,۰۹	۴۰,۷۵	۹,۳۲	۸۶,۸۴
	عمق تونل	m	H	۶,۱۰	۱۳,۱۳	۲۴	۳,۸۸	۱۵,۰۴
ورودی	قطر تونل	m	D	۶,۲۵	۶,۳۴	۶,۴۰	۰,۰۵	۰
	فشار تزریق گروت	MPa	P	۰,۲	۰,۳۱	۰,۴۰	۰,۰۶	۰
	درصد پرکنندگی گروت	%	n	۰,۹	۱,۵۹	۲	۰,۲۷	۰,۰۷
	نیروی پیشران	MN	F	۱,۴۰	۲۲,۵۵	۳۳	۹,۸۲	۹۶,۴۱
	نرخ پیشروی	mm/min	v	۲۰	۳۶,۱۵	۶۰	۱۴,۱۶	۲۰۰,۵۹
خروجی	عرض گودی پروفیل نشست	mm	i	۴,۳۵	۷,۶۸	۱۶,۳۲	۲,۷۳	۷,۴۷
	حداکثر نشست سطح زمین	m	$S_{max}$	۴,۳۰	۳۵,۰۷	۸۹,۹۰	۲۴,۹۲	۶۲۰,۷۹

محسوب می‌شود. برای پارامتر  $S_{max}$  از آنجاییکه مقادیر ماکزیمم و مینیمم داده‌ها در محدوده حد بالا و پایین قرار دارند، لذا هیچگونه داده پرتی وجود ندارد. بالعکس، ماکزیمم مقدار  $i$  بیشتر از حد بالا می‌باشد که نشان‌دهنده وجود داده پرت است. با توجه به جدول داده‌ها (جدول ۲)، دو داده پرت با مقادیر  $i$  برابر با ۱۴,۵۴ و ۱۶,۳۲ وجود دارد. در چنین مواردی می‌توان داده‌های مربوطه را حذف کرد و یا با یک مقدار دلخواه نزدیک به حد بالا یا حد پایین (به هر کدام که نزدیک‌تر باشد)، آن را جایگزین نمود. با این حال در این مطالعه، به دلیل کم بودن تعداد داده‌های پرت در مقایسه با تعداد کل داده‌ها (۲ از ۲۶) و اختلاف کم آن‌ها با حد بالا، از حذف و یا جایگزین نمودن این دو داده صرف نظر شد.

در شکل ۳، ماتریس همبستگی بین پارامترهای مختلف ورودی و خروجی نشان داده شده است. معمولاً در صورت وجود همبستگی بالا بین هر جفت پارامتر، بهتر است یکی از آن‌ها به منظور کاهش تعداد پارامترهای ورودی مدل، ساده‌تر شدن آن و نیز کاهش زمان اجرای آن حذف شود. با این حال، در اکثر مقالات موجود برای پیش‌بینی  $S_{max}$  مبتنی بر روش‌های هوش مصنوعی (بخش مقدمه) این کار صورت نگرفته است. از سوی دیگر، با وجود همبستگی بالا بین دو پارامتر، همیشه نمی‌توان یکی از آن‌ها را حذف نمود چرا که ممکن است نوع پارامترهای مورد نظر با هم متفاوت باشند. به عنوان مثال، با توجه به ماتریس همبستگی در شکل ۳، می‌توان دریافت که بین پارامتر  $C$  (یکی از خصوصیات ژئومکانیکی) و پارامترهای  $H$  و  $D$  (خصوصیات هندسی) و نیز بین پارامتر  $\Phi$  (یکی از خصوصیات ژئومکانیکی) و دو پارامتر  $D$  (خصوصیات هندسی) و  $n$  (مربوط به دستگاه حفاری) همبستگی بالایی وجود دارد. با این حال، نمی‌توان برای هر جفت از پارامترهای مذکور یکی از آن‌ها را حذف نمود زیرا ماهیت این پارامترها متفاوت بوده و در عمل به هم وابسته نیستند.

به منظور بررسی وجود داده‌های پرت در پایگاه داده، از توابع ربع (چارک) در محیط اکسل استفاده شد. زمانیکه مقادیر پارامترهای  $S_{max}$  و  $i$  در محدوده حد بالا و پایین قرار گیرند داده‌های پرت در پایگاه داده وجود ندارد. از طرف دیگر، هر داده‌ای که در بازه مذکور قرار نگیرد داده پرت



شکل ۳- ماتریس همبستگی بین پارامترهای ورودی و خروجی پایگاه داده

#### ۴- پیش‌بینی $S_{max}$ و $i$

##### ۴-۱- الگوریتم بهینه‌سازی گرگ خاکستری

به‌منظور پیش‌بینی حداکثر نشست و عرض گودی نشست سطح زمین، ۸۰٪ داده‌ها (۲۰ دسته داده) به‌عنوان داده‌های آموزش و ۲۰٪ دیگر (۶ دسته داده) به‌عنوان داده‌های تست در مدل‌سازی الگوریتم بهینه‌سازی گرگ خاکستری در نظر گرفته شده است. همچنین، به‌منظور یکسان نمودن اهمیت ورودی‌ها و نیز جلوگیری از کاهش دقت و سرعت الگوریتم گرگ خاکستری در مراحل مدل‌سازی، با استفاده از معادله  $x_{nor} = (x_i - x_{min}) / (x_{max} - x_{min})$  نرمالایز گردید. سپس، مدلی مطابق رابطه ۱۰ جهت پیش‌بینی  $S_{max}$  و  $i$  در نظر گرفته شد. در نهایت، تابع هدفی (Objective or cost function) به‌صورت رابطه ۱۱ تعریف شده است.

$$Y_{pred} = \alpha_0 + \sum_{i=1}^9 \alpha_i X_i^{\beta_i} \quad (10)$$

Minimize:  $F(\alpha_i, \beta_i)$

$$F(\alpha_i, \beta_i) = \sqrt{\frac{\sum_{j=1}^N (Y_{pred} - Y_{actual})^2}{N}} \quad (11)$$

در روابط ۱۰ و ۱۱،  $Y_{pred}$  و  $Y_{actual}$  بیانگر مقادیر پیش‌بینی شده و واقعی پارامترهای  $S_{max}$  و  $i$ ؛  $N$  تعداد دسته داده‌های آموزش، متغیر  $X_i$  ( $i$  از ۱ تا ۹) بیانگر پارامترهای ورودی مدل پیش‌بینی کننده، و  $\alpha_0$ ،  $\alpha_i$  و  $\beta_i$  ضرایب وزنی هستند.

پس از معرفی تابع هدف (که همان  $RMSE$  است) به الگوریتم  $GWO$ ، الگوریتم در هر تکرار به جستجوی مقادیر بهینه ضرایب وزنی به ازای مقادیر مختلف اندازه جمعیت می‌پردازد. مدل مربوط به حالتی که مقدار  $F(\alpha_i, \beta_i)$  آن نسبت به بقیه مدل‌ها کمتر باشد به‌عنوان بهترین مدل پیش‌بینی کننده در نظر گرفته شد. در مقاله حاضر با توجه به وجود دو پارامتر  $S_{max}$  و  $i$ ، هر بار یکی از آن‌ها به‌عنوان پارامتر هدف انتخاب و سپس مقدار مناسب اندازه جمعیت و تعداد تکرارها در مدل‌سازی هر کدام از پارامترهای هدف با توجه به کمترین مقدار  $RMSE$  در مرحله آموزش بدست آمد. به‌منظور دستیابی به پارامترهای بهینه در الگوریتم  $GWO$ ، از تکنیک جستجوی شبکه‌ای استفاده شده است. اندازه جمعیت در محدوده ۶ تا ۳۰ و تعداد تکرارهای

الگوریتم تا ۳۰۰ تکرار مورد ارزیابی قرار گرفته است. لازم به ذکر است که به ازای یک اندازه جمعیت ثابت، پس از یک تعداد تکرار مشخص، کاهش چشمگیری در مقدار  $RMSE$  (تابع هدف) دیده نشده و فقط مدت زمان لازم برای توقف الگوریتم افزایش یافته است. بنابراین، تعداد تکرار مورد نظر به‌عنوان تعداد تکرار مناسب به ازای یک اندازه جمعیت ثابت، در نظر گرفته می‌شود. با انتخاب مقادیر متفاوت پارامترهای اندازه جمعیت و تعداد تکرارها، مدل‌های مختلفی اجرا و در نهایت مقادیر بهینه آن‌ها در پیش‌بینی  $S_{max}$  به‌ترتیب ۱۵ و ۷۰ و در پیش‌بینی  $i$  به‌ترتیب برابر با ۱۲ و ۸۰ به‌دست آمد. سپس، مدل بدست آمده بر روی داده‌های تست به‌منظور ارزیابی آن، اعمال گردید.

به‌طور کلی، مدل‌های ارائه شده برای پیش‌بینی  $S_{max}$  و  $i$  بر مبنای الگوریتم  $GWO$ ، مدل‌هایی غیر خطی هستند. به‌عبارت دیگر، خروجی مدل‌ها تابعی غیر خطی از ورودی‌ها است. الگوریتم  $GWO$  به‌طور خودکار ضرایب مدل را بگونه‌ای تعیین می‌کند که بیشترین همبستگی بین ورودی‌ها و خروجی مدل ایجاد شود (مدیریت روابط بین ورودی و خروجی). در واقع تعیین و مدیریت روابط بین ورودی‌ها و خروجی مدل طی یک پروسه جستجوی تکراری و به‌روز رسانی موقعیت عامل‌های جستجو در فضای جستجو صورت می‌گیرد که نتیجه آن دستیابی به مقادیر بهینه ضرایب وزنی مدل و پیدا کردن مناسب‌ترین رابطه غیر خطی بین ورودی‌ها و خروجی مدل است.

الگوریتم  $GWO$ ، مشابه بسیاری از الگوریتم‌های هوش ازدحامی ممکن است به پارامترهای اولیه مدل حساس باشد و این حساسیت بر نتایج نهایی تأثیر بگذارد. در این الگوریتم، مقادیر بردارهای ضرایب  $A$  و  $C$  به‌طور تصادفی در بازه  $[2, -2]$  و  $[0, 2]$  انتخاب می‌شوند. با این حال، پارامتر  $A$  به‌وسیله مقدار عددی  $a$  (که مقدار آن در ابتدا ۲ و سپس مقدار آن به‌صورت خطی تا رسیدن به صفر کاهش می‌یابد) محدود می‌شود. در ابتدا الگوریتم سهم بیشتری را به فاز اکتشاف ( $A$  بیشتر از ۱ یا کمتر از -۱) اختصاص می‌دهد و به‌تدریج با افزایش تعداد تکرارها، از فاز اکتشاف کم شده و الگوریتم به استخراج جواب می‌پردازد ( $A$  بین -۱ و ۱). علاوه، وجود ضرایب برداری  $A$  و  $C$  موقعیت عامل‌های جستجو (گرگ‌ها) را در هر مرحله تغییر می‌دهد و در نتیجه

فوق را می‌توان با استفاده از روابط ۱۴ تا ۱۶ بدست آورد  
(Zhou, et al., 2016; Zhang, et al., 2020)

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y_i')^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (14)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i')^2} \quad (15)$$

$$MAE = \frac{\sum_{i=1}^N |y_i - y_i'|}{N} \quad (16)$$

در روابط فوق،  $y_i$  و  $y_i'$  به ترتیب مقادیر  $S_{max}$  و  $i$  واقعی و پیش‌بینی شده و  $\bar{y}$  میانگین مقادیر اندازه‌گیری شده  $S_{max}$  و  $i$  است. همچنین  $N$  بیانگر تعداد دسته داده‌ها در مرحله آموزش و یا تست است. با اعمال روابط ۱۴ تا ۱۶ بر داده‌های آموزش و تست، مقادیر این شاخص‌ها برای دو روش  $MLR$  و  $GWO$  در پیش‌بینی  $S_{max}$  و  $i$  مطابق جدول ۴، بدست آمد.

شکل ۴ و شکل ۵، به ترتیب نتایج نشست حداکثر پیش‌بینی شده در مقابل مقادیر اندازه‌گیری شده و نتایج عرض گودی پروفیل نشست پیش‌بینی شده در مقابل مقادیر اندازه‌گیری شده با استفاده از روش‌های  $GWO$  و  $MLR$  برای داده‌های آموزش و تست را نشان می‌دهند. با توجه به شکل ۴ و شکل ۵ و ردیف اول و چهارم جدول ۴، بر اساس شاخص  $R^2$  می‌توان گفت که الگوریتم  $GWO$  با قابلیت اطمینان بالاتر و دقت بیشتری نسبت به روش  $MLR$  توانسته است حداکثر نشست و عرض گودی پروفیل نشست سطح زمین را پیش‌بینی نماید. بعلاوه مطابق جدول ۴، مقادیر شاخص‌های  $RMSE$  و  $MAE$  به دست آمده برای الگوریتم  $GWO$  در هر دو مرحله آموزش و تست در مقایسه با مقادیر متناظر آنها برای روش  $MLR$  بسیار کمتر بوده و به صفر نزدیک‌تر است که نشان‌دهنده خطای کمتر الگوریتم  $GWO$  و دقت و کارایی بالاتر آن نسبت به  $MLR$  می‌باشد.

به دلیل عدم وجود برخی از پارامترهای ورودی در مدل‌های تجربی و تحلیلی ارائه شده در جدول ۱، مقادیر حداکثر نشست ( $S_{max}$ ) را نمی‌توان با استفاده از این مدل‌ها بدست آورد. بعلاوه، اکثر این مدل‌ها از تعداد پارامتر ورودی کمتری جهت برآورد  $S_{max}$  استفاده می‌کنند (به غیر از مدل  $Unver \& Chakeri, 2014$ ). با این حال پس از جایگذاری داده‌های جدول ۱، در رابطه  $Unver \& Chakeri 2014$  فرض نسبت پواسون ۰٫۲۵، مشاهده شد که مدل  $Chakeri$

ممکن است بر موقعیت نهایی گرگ  $\alpha$  که همان جواب مسئله مورد نظر است، تأثیر بگذارد. با افزایش تعداد عامل‌های جستجو (اندازه جمعیت) و تعداد تکرارها، ممکن است در اجراهای مختلف به جواب‌های نزدیک به هم رسید که در این حالت می‌توان گفت (جواب) الگوریتم به پارامترهای اولیه حساسیت زیادی نداشته است. با این حال، چنین رویکردی هزینه‌های محاسباتی و زمان اجرای الگوریتم را نیز به تبع افزایش خواهد داد.

#### ۲-۴- مدل رگرسیون خطی چندگانه

بر اساس داده‌های آموزش (۲۰ دسته داده) و با بکارگیری نرم‌افزار  $SPSS 22$ ، دو مدل رگرسیون خطی چندگانه مطابق روابط ۱۲ و ۱۳ به ترتیب برای پیش‌بینی  $S_{max}$  و  $i$  ارائه شد.

$$S_{max} = 5984.27 - 0.0769(C) - 1.2225(\varphi) - 2.3826(E_s) - 1.3627(H) - 925.637(D) + 11.8288(P) - 31.658(n) - 0.4194(F) + 1.4238(V) \quad (12)$$

$$i = 96.637 - 0.00237(C) + 0.1247(\varphi) - 0.236(E_s) + 0.7426(H) - 14.109(D) - 9.0687(P) - 2.455(n) - 0.006(F) - 0.058(V) \quad (13)$$

روابط ارائه شده بین ورودی‌ها و خروجی در مدل‌های رگرسیون خطی چندگانه در اصل روابطی خطی هستند. به عبارت دیگر، اساس این روش در نظر گرفتن یک رابطه خطی بین پارامتر(های) ورودی و خروجی (در حالت یک متغیره یک خط و در حالت چند متغیره یک فوق صفحه) و سپس استخراج ضرایب وزنی مدل به گونه‌ای است که بتواند مجموع مربعات خطا را تا حد ممکن کاهش دهد. این مورد یکی از ضعف‌های مدل‌های رگرسیون خطی چندگانه است که خارج از کنترل کاربر می‌باشد.

#### ۳-۴- مقایسه و اعتبارسنجی مدل‌های پیشنهادی

به منظور مقایسه و اعتبارسنجی مدل‌های ارائه شده بر مبنای الگوریتم بهینه‌سازی گرگ خاکستری و مدل رگرسیون خطی چندگانه، از سه شاخص ارزیابی عملکرد شامل ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا ( $RMSE$ ) و خطای مطلق میانگین ( $MAE$ ) استفاده شده است. مقدار  $R^2$  در اصل بین صفر و ۱ قرار دارد. همچنین، مقادیر  $RMSE$  و  $MAE$  همواره بزرگتر یا مساوی صفر هستند. با نزدیک شدن مقادیر شاخص‌های  $R^2$ ،  $RMSE$  و  $MAE$  به ترتیب به ۱، صفر و صفر دقت مدل‌ها افزایش می‌یابد. مقادیر شاخص‌های

کلیه دسته داده‌ها انجام شد. در نهایت با استفاده از ۳ شاخص آماری  $R^2$ ،  $RMSE$  و  $MAE$  دقت و میزان خطای کلیه مدل‌های تجربی در مرحله آموزش و تست محاسبه شد (جدول ۵). با توجه به نتایج به دست آمده، می‌توان دریافت که کلیه مدل‌های تجربی دارای دقت پایین‌تر ( $R^2$  کم‌تر) و خطای بیشتری (مقدار  $RMSE$  و  $MAE$  بزرگ‌تر) نسبت به دو مدل  $GWO$  و  $MLR$  در برآورد پارامتر  $i$  هستند.

در شکل ۶ و شکل ۷، به ترتیب مقایسه‌ای بین مقادیر حداکثر نشست و عرض گودی پروفیل نشست اندازه‌گیری شده و مقادیر پیش‌بینی شده با استفاده از مدل‌های  $GWO$  و  $MLR$  مربوط به فرآیند تست صورت گرفته است. نتایج حاصله نشان‌دهنده دقت بالای روش  $GWO$  در مقایسه با روش  $MLR$  می‌باشد. بنابراین، می‌توان نتیجه گرفت که الگوریتم  $GWO$  می‌تواند به‌عنوان ابزاری مناسب برای پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین ناشی از عملیات تونل‌سازی در محیط‌های شهری مورد استفاده قرار گیرد.

$Unver \& 2014$  مقدار  $S_{max}$  را برای برخی از دسته داده‌ها منفی برآورد می‌نماید. این امر به این دلیل است که رابطه مذکور برای رنج پارامترهای ورودی محدودتری می‌تواند مقدار  $S_{max}$  را برآورد نماید. علاوه، نتایج مطالعات مقایسه‌ای  $Unver \& Chakeri 2014$  به‌منظور بررسی دقت دیگر روابط تجربی بیانگر آن است که سایر روابط تجربی مقدار  $S_{max}$  را چندین برابر مقدار واقعی آن پیش‌بینی نموده و عملکرد مناسبی ندارند (رجوع به جدول ۱۰، در مقاله  $Unver \& Chakeri, 2014$ ). از سوی دیگر، در اکثر کارهای تحقیقاتی مبتنی بر روش‌های هوش مصنوعی جهت برآورد  $S_{max}$ ، مقایسه نتایج حاصله با نتایج روش‌های تجربی به دلیل عدم وجود برخی از پارامترها در داده‌های ورودی صورت نگرفته است. از طرف دیگر، کلیه روش‌های تجربی جهت برآورد پارامتر  $i$  وابسته به عمق روباره ( $H$ ) و قطر تونل ( $D$ ) هستند. بنابراین، با جایگذاری مقادیر دو پارامتر ورودی مربوط به هر دسته داده در روابط تجربی، مقدار  $i$  برآورد شده مربوط به هر دسته داده بدست آمد که این کار برای

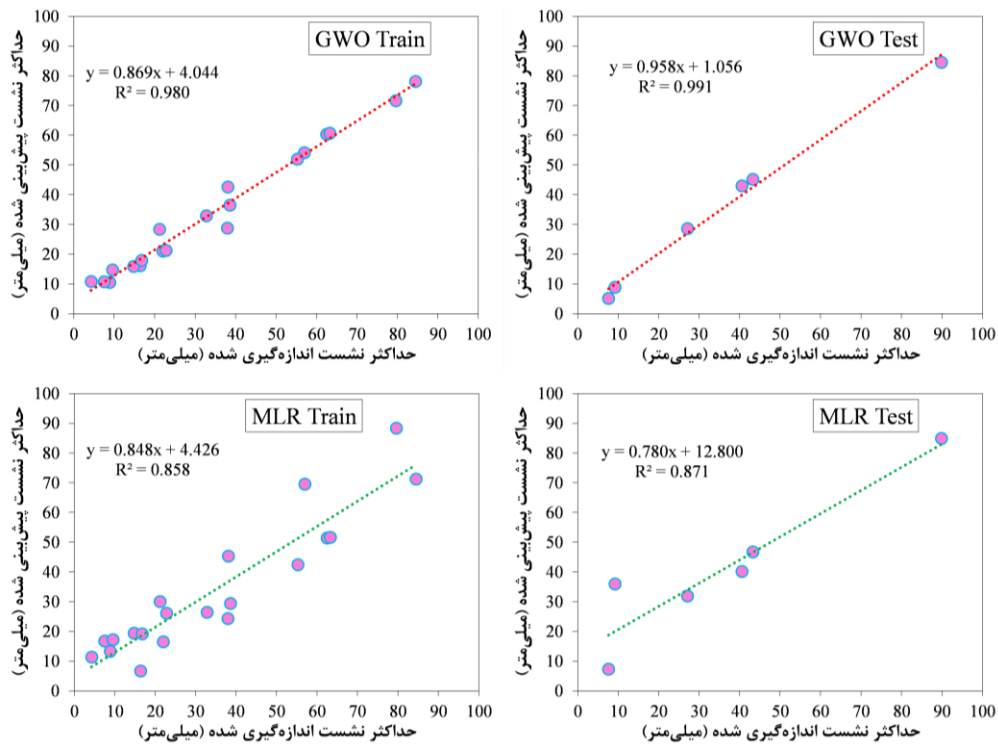
جدول ۴- مقادیر شاخص‌های آماری در مراحل آموزش و تست برای مدل‌های  $MLR$  و  $GWO$  در پیش‌بینی  $S_{max}$  و  $i$

مرحله تست	مرحله آموزش		شاخص آماری	خروجی		
	$GWO$	$MLR$			$GWO$	$MLR$
	۰٫۹۹۱	۰٫۸۷۱	۰٫۹۸۰	۰٫۸۵۸	$R^2$	$S_{max}$
	۲٫۷۹	۱۱٫۳۶	۴٫۳۷	۹٫۰۸	$RMSE$	
	۲٫۳۳	۶٫۷۸	۳٫۴۸	۸٫۴۶	$MAE$	
	۰٫۹۸۹	۰٫۸۹۲	۰٫۹۷۵	۰٫۸۸۴	$R^2$	$i$
	۰٫۱۴۶	۰٫۴۸۵	۰٫۵۱	۱٫۰۷۸	$RMSE$	
	۰٫۱۳	۰٫۴۲۸	۰٫۳۹۱	۱	$MAE$	

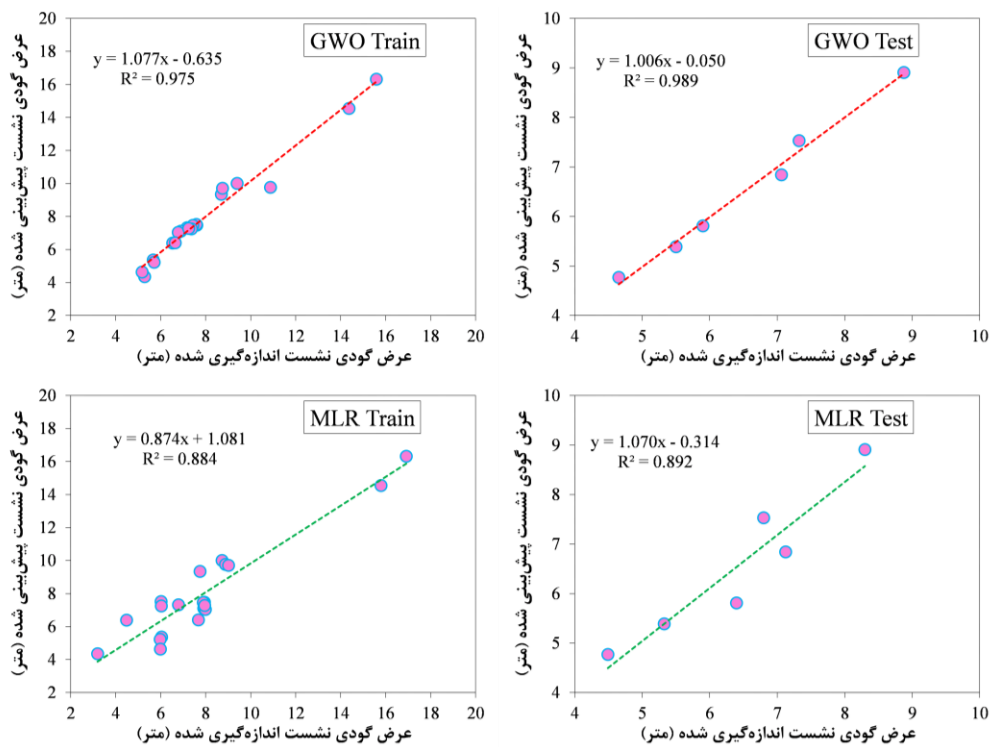
جدول ۵- مقادیر شاخص‌های آماری به دست آمده در مراحل آموزش و تست برای مدل‌های تجربی در پیش‌بینی  $i$

مرحله	شاخص آماری	روابط تجربی					
		<i>Hamza et al. (1999)</i>	<i>Arioglu (1992)</i>	<i>Herzog (1985)</i>	<i>O'Reilly (1982)</i>	<i>Glossop (1978)</i>	<i>Schmidt (1969)</i>
آموزش	$R^2$	۰٫۷۰۹۳	۰٫۷۰۳۸	۰٫۷۱۵۸	۰٫۷۱۵۸	۰٫۷۱۵۸	۰٫۷۱۵۸
	$RMSE$	۴٫۳۰۷۹	۲٫۰۴۸۵	۲٫۵۹۹۵	۱٫۹۷۸۲	۱٫۹۷۱۰	۱٫۸۵۹۰
	$MAE$	۳٫۷۸۱۵	۱٫۵۱۲۲	۲٫۱۳۱۵	۱٫۵۱۶۳	۱٫۶۳۱۰	۱٫۳۸۵۵
تست	$R^2$	۰٫۵۴۷۵	۰٫۵۳۴۲	۰٫۵۴۵۸	۰٫۵۴۵۸	۰٫۵۴۵۸	۰٫۵۴۵۸
	$RMSE$	۳٫۳۱۹۲	۰٫۲۸۰۹	۱٫۹۵۹۳	۱٫۳۷۵۲	۱٫۵۵۷۴	۱٫۱۹۸۸
	$MAE$	۳٫۰۸۲۰	۰٫۹۹۶۳	۱٫۵۶۹۷	۰٫۹۸۰۹	۱٫۱۱۶۷	۰٫۹۹۰۳

استفاده از الگوریتم بهینه‌سازی گرگ خاکستری برای تخمین پارامترهای نشست سطح زمین ...، محمد رضائی و ...، ص ۶۱-۸۰



شکل ۴- عملکرد *GWO* و *MLR* در فرآیند آموزش و تست به منظور پیش‌بینی  $S_{max}$



شکل ۵- عملکرد *GWO* و *MLR* در فرآیند آموزش و تست به منظور پیش‌بینی  $i$


شده است. همانطور که مشاهده می‌شود، از بین پارامترهای ورودی، مهم‌ترین پارامترهای تأثیرگذار بر  $S_{max}$  به ترتیب فشار تزریق گروت ( $P$ ) و قطر تونل ( $D$ ) است، درحالی‌که مهم‌ترین پارامترهای تأثیرگذار بر  $i$  به ترتیب فاصله محور تونل از سطح زمین ( $H$ ) و قطر تونل ( $D$ ) هستند. همچنین، مقاومت چسبندگی خاک ( $C$ ) کم اهمیت‌ترین پارامتر تأثیرگذار بر  $S_{max}$  و  $i$  است.

علاوه بر روش فوق، در این مقاله از رویکرد دیگری هم برای انجام آنالیز حساسیت و تعیین اهمیت پارامترهای ورودی تأثیرگذار بر دو پارامتر خروجی ( $S_{max}$  و  $i$ )، استفاده و نتایج حاصله با نتایج روش میدان کسینوسی مقایسه شده است. در این روش اهمیت پارامترهای ورودی را می‌توان با استفاده از رابطه ۱۷ محاسبه نمود که مقدار آن عددی بین ۱- و ۱ می‌باشد (Bastami, et al., 2020):


$$r = \frac{\sum_{i=1}^N (x_i - x_{mean})(y_i - y_{mean})}{\sqrt{\sum_{i=1}^N (x_i - x_{mean})^2 \sum_{i=1}^N (y_i - y_{mean})^2}} \quad (17)$$

در رابطه فوق  $x_i$  مقدار پارامتر ورودی،  $x_{mean}$  میانگین مقادیر پارامتر ورودی،  $y_i$  مقدار پیش‌بینی شده پارامتر خروجی،  $y_{mean}$  میانگین مقادیر پیش‌بینی شده پارامتر خروجی و  $N$  تعداد دسته داده‌ها است. علامت مثبت و منفی مقدار  $r$  بیانگر همبستگی مستقیم و معکوس آن پارامتر ورودی با پارامتر خروجی است. بعلاوه، کم و زیاد بودن مقدار  $r$  برای یک پارامتر بیانگر آن است که پارامتر مذکور به ترتیب اهمیت زیاد و یا اهمیت کمی در برآورد پارامتر هدف دارد. با توجه به شکل ۱۰، پارامترهای  $F$  و  $n$  به ترتیب مهم‌ترین و کم اهمیت‌ترین پارامترهای تأثیرگذار بر  $S_{max}$  هستند. همچنین،  $C$  و  $H$  مهم‌ترین پارامترهای تأثیرگذار بر  $i$  هستند، در حالی که  $v$  کم اهمیت‌ترین پارامتر تأثیرگذار بر  $i$  است. با توجه به شکل ۸ تا شکل ۱۰ و با مقایسه دو روش تحلیل حساسیت مورد استفاده در این مقاله، می‌توان دریافت که استفاده از روش‌های مختلف در آنالیز حساسیت پارامترهای ورودی، ممکن است نتایج مختلفی داشته باشد که بسته به شرایط مسئله مورد بررسی و داده‌های موجود، هر کدام از آنها می‌تواند نتیجه مناسب‌تری در بر داشته و مورد استفاده قرار گیرد.

به‌طور کلی، بررسی تأثیر همزمان چندین پارامتر بر نشست زمین به‌صورت ذاتی در مدل‌های پیشنهادی در این



شکل ۶- مقایسه  $S_{max}$  اندازه‌گیری شده و پیش‌بینی شده با استفاده از مدل‌های  $GWO$  و  $MLR$  در فرآیند تست

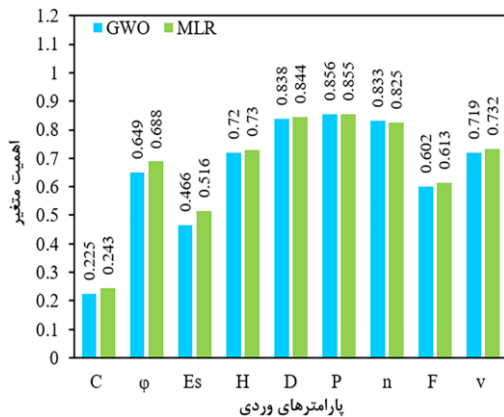


شکل ۷- مقایسه  $i$  اندازه‌گیری شده و پیش‌بینی شده با استفاده از مدل‌های  $GWO$  و  $MLR$  در فرآیند تست


## ۵- تحلیل اهمیت متغیر

مطالعه پارامتریک معمولاً برای ارزیابی اهمیت و تأثیر متغیرهای ورودی بر روی یک متغیر هدف انجام می‌شود. یکی از روش‌های معمول در تعیین میزان اهمیت و تأثیر متغیرهای ورودی یک مدل بر خروجی آن، روش میدان کسینوسی است که به‌طور گسترده‌ای در تحقیقات مختلف مورد استفاده قرار گرفته است. در این تحقیق، تحلیل اهمیت متغیرهای ورودی  $GWO$  و  $MLR$  بر روی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین با استفاده از نرم‌افزار  $STATISTICA 12$  که رویکردی مشابه با روش  $CAM$  دارد، در طول توسعه و آزمایش مدل‌ها انجام شده است. بر اساس این تحلیل، مقادیر اهمیت متغیرهای ورودی محاسبه شده و بین ۰ و ۱ مرتب می‌شوند. با استفاده از این روش، مقادیر اهمیت ۹ پارامتر ورودی در نظر گرفته شده در پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین با استفاده از الگوریتم  $GWO$  و مدل  $MLR$  محاسبه شده و به ترتیب در شکل ۸ و شکل ۹، نشان داده

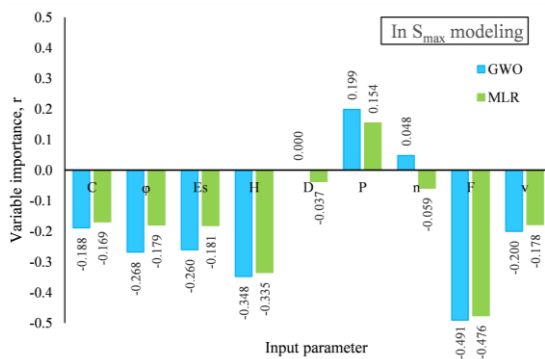
استفاده از الگوریتم بهینه‌سازی گرگ خاکستری برای تخمین پارامترهای نشست سطح زمین ...، محمد رضائی و ...، ص ۶۱-۸۰



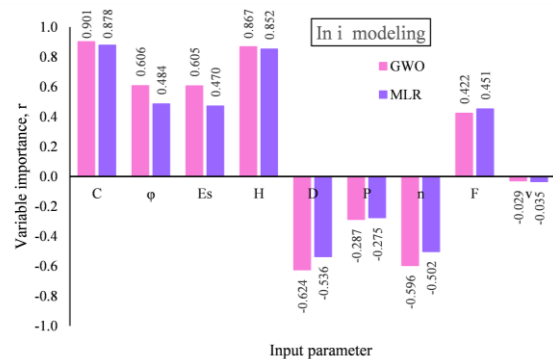
شکل ۸- اهمیت متغیرهای ورودی در پیش‌بینی  $S_{max}$  با استفاده از مدل‌های  $GWO$  و  $MLR$



شکل ۹- اهمیت متغیرهای ورودی در پیش‌بینی  $i$  با استفاده از مدل‌های  $GWO$  و  $MLR$



تحقیق انجام گرفته است. در روش  $MLR$ ، روابطی جهت برآورد  $S_{max}$  و  $i$  استخراج شده است که در این روابط، می‌توان اثرات همزمان چند پارامتر را بر روی پارامتر هدف بررسی نمود. همچنین، الگوریتم  $GWO$  مدلی غیر خطی ارائه می‌کند که در آن، خروجی(ها) تابعی غیر خطی از ورودی‌ها بوده و تأثیر همزمان پارامترهای ورودی بر خروجی با بیش‌ترین همبستگی در نظر گرفته می‌شود. به منظور اثبات این مورد، می‌توان از مقایسه ماتریس همبستگی (شکل ۳) با آنالیز حساسیت نتایج مدل‌های  $MLR$  و  $GWO$  (شکل ۱۰) استفاده نمود. با توجه به ماتریس همبستگی (شکل ۳)، ارتباط بالایی بین دو پارامتر ورودی  $F$  و  $H$  و پارامتر  $S_{max}$  وجود دارد. اهمیت دو پارامتر مذکور در تحلیل حساسیت انجام شده در شکل ۱۰، نیز مشاهده می‌شود. از سوی دیگر، با توجه به ماتریس همبستگی (شکل ۳)، ارتباط بالایی بین دو پارامتر ورودی  $C$  و  $H$  و پارامتر خروجی  $i$  وجود دارد که این اهمیت در تحلیل حساسیت انجام شده در شکل ۱۰، نیز قابل مشاهده است. انطباق آنالیز حساسیت نتایج مدل‌های  $MLR$  و  $GWO$  با نتایج ماتریس همبستگی نشان می‌دهد که تأثیر همزمان پارامترهای ورودی بر خروجی‌ها ( $S_{max}$  و  $i$ ) در مدل‌های پیشنهادی به خوبی در نظر گرفته شده و نتایج حاصله از اعتبار قابل قبولی برخوردار هستند. همچنین بر اساس مقایسه فوق، می‌توان نتیجه گرفت که استفاده از رابطه ۱۷ برای آنالیز حساسیت نتایج مدل‌های پیشنهادی در این تحقیق مناسب‌تر بوده و از اعتبار بیش‌تری نسبت به روش میدان کسینوسی برخوردار است.



شکل ۱۰- اهمیت متغیرهای ورودی در پیش‌بینی  $S_{max}$  و  $i$  با استفاده از الگوریتم  $GWO$  و مدل  $MLR$

## ۶- مزیت‌ها، محدودیت‌ها و مطالعات آتی

در این مقاله، از الگوریتم بهینه‌سازی گرگ خاکستری برای تخمین حداکثر نشست سطح زمین و عرض گودی پروفیل نشست ناشی از عملیات حفاری تونل‌های شهری استفاده شده است. با توجه به دقت بالای نتایج حاصله، استفاده از این مدل می‌تواند در عمل به تعیین دقیق نشست حاصل از عملیات تونل‌سازی و کاهش مخاطرات مربوطه کمک شایانی نماید. همچنین، در نظر گرفتن اکثر پارامترهای تأثیرگذار ممکن بر نشست سطح زمین از جمله شرایط زمین‌شناسی لایه‌ها، هندسه تونل و فاکتورهای عملیاتی دستگاه حفاری از دیگر مزیت‌های این تحقیق است که در بیشتر مطالعات قبلی نادیده گرفته شده است. بعلاوه، به‌روز رسانی مدل‌های پیشنهادی *GWO* و *MLR* به ترتیب در محیط پایتون و اکسل برای مطالعات آتی امکان‌پذیر است. مدل‌های مذکور را می‌توان در صورت تغییر تعداد دسته داده‌های مربوط به پایگاه داده، کم شدن پارامترهای ورودی و یا اضافه شدن پارامترهای ورودی جدید، به‌منظور تعیین پارامترهای بهینه مدل *GWO* (اندازه جمعیت و تعداد تکرار الگوریتم) و نیز ضرایب مدل *MLR* مجدداً اجرا نموده و پارامترها و ضرایب مربوط به آن‌ها را به‌دست آورد. با وجود مزیت‌های فوق‌الذکر، این تحقیق دارای محدودیت‌ها و چالش‌هایی به شرح زیر است که می‌تواند در مطالعات آتی پوشش داده شود:

۱- کم بودن تعداد داده‌های مورد استفاده در این تحقیق یکی از محدودیت‌های اصلی آن است. اگرچه این محدودیت با توجه به تعداد زیاد پارامترهای ورودی، محدودیت اندازه‌گیری برجا از لحاظ زمان و هزینه و شرایط پیچیده در زیر زمین توجیه‌پذیر است ولی می‌تواند در مطالعات آتی مورد توجه قرار گیرد.

۲- مشابه سایر مدل‌های پیش‌بینی، مدل‌های ارائه شده در این مقاله نیز ممکن است در صورت عدم گزارش برخی از پارامترهای ورودی در پروژه‌های واقعی تونل‌سازی و یا متفاوت بودن پارامترهای ورودی اندازه‌گیری شده با پارامترهای ورودی مدل، با چالش‌هایی در پیاده‌سازی عملی مواجه شوند. خروجی‌ها در این تحقیق بر حسب ۹ پارامتر ورودی برآورد شده است که ممکن است در یک پروژه جدید برخی از پارامترهای ورودی مانند پارامترهای مربوط به دستگاه حفاری و یا خصوصیات زمین‌شناسی به‌دلیل هزینه‌بر

بودن در برخی از پروژه‌های تونل‌سازی اندازه‌گیری نشده باشند. این امر استفاده از مدل‌های توسعه یافته در این تحقیق را محدود نموده و نیاز به توسعه مدل‌های جدید بر اساس پارامترهای موجود خواهد بود.

۳- جنبه دیگری از چالش‌های احتمالی در پیاده‌سازی مدل‌های پیشنهادی، به عدم قطعیت احتمالی در پارامترهای ورودی و عدم اندازه‌گیری دقیق آن‌ها بر می‌گردد. با این حال، علیرغم وجود همیشگی این چالش‌ها در پروژه‌های تونل‌سازی، هدف کلیه مطالعاتی که در این زمینه انجام شده‌اند، ارائه مدل‌هایی با توجه به اطلاعات موجود بوده است تا از این طریق بتوانند با پیش‌بینی هر چه دقیق‌تر  $S_{max}$  و  $i$ ، تحلیلی جامع‌تر از اثرات نشست ناشی از عملیات تونل‌سازی داشته باشند.

۴- مدل‌های *GWO* و *MLR* ارائه شده در این تحقیق ممکن است فقط برای داده‌هایی که دامنه ورودی و خروجی آن‌ها در محدوده دامنه داده‌های مورد استفاده در این مقاله قرار دارد نتیجه مناسبی ارائه دهند. البته این یک محدودیت کلی است که نه تنها برای مدل‌های ارائه شده در این تحقیق بلکه برای کلیه مدل‌های تجربی و هوش مصنوعی که با رویکردی مشابه به پیش‌بینی پارامتر هدف در یک مسئله خاص بر اساس داده‌های موجود می‌پردازند، وجود دارد.

## ۷- نتیجه‌گیری

در این مقاله، با استفاده از الگوریتم *GWO* و مدل *MLR* به پیش‌بینی حداکثر نشست و عرض گودی پروفیل نشست سطح زمین ناشی از عملیات تونل‌سازی در محیط‌های شهری پرداخته شده است. بر اساس ۲۶ دسته داده مربوط به ۳ پروژه تونل‌سازی و انتخاب ۹ متغیر به‌عنوان پارامترهای ورودی تأثیرگذار بر دو پارامتر خروجی (حداکثر نشست و عرض گودی پروفیل نشست سطح زمین)، مدل‌سازی *GWO* و *MLR* انجام گردید. در مرحله نخست، ۸۰٪ داده‌ها به‌عنوان داده‌های آموزش و ۲۰٪ دیگر به‌عنوان داده‌های تست جهت اجرای دو روش مورد استفاده قرار گرفت. سپس، به‌منظور ارزیابی عملکرد مدل‌های مورد استفاده از ۳ شاخص آماری ضریب تعیین ( $R^2$ )، جذر میانگین مربعات خطا ( $RMSE$ ) و خطای مطلق میانگین ( $MAE$ ) برای داده‌های آموزش و تست استفاده شد و نتایج حاصل با روابط تجربی موجود مقایسه

پارامترهای تأثیرگذار بر  $S_{max}$  و  $i$  هستند. بالعکس،  $H$  و  $v$  به ترتیب مهمترین و کم اهمیت‌ترین پارامترهای تأثیرگذار بر  $S_{max}$  و  $i$  می‌باشند. با در نظر گرفتن نتایج فوق‌الذکر، می‌توان نتیجه گرفت که الگوریتم  $GWO$  می‌تواند به‌عنوان یک روش قابل اطمینان با کارایی و دقت بالا در پیش‌بینی پارامترهای نشست سطح زمین مورد استفاده قرار گیرد. از آنجاییکه مقدار خروجی مدل‌های ارائه شده وابسته به سه دسته پارامتر ورودی مختلف هستند، لذا قابلیت تعمیم و استفاده از آنها در شرایط زمین‌شناسی و ژئوتکنیکی مختلف وجود دارد. در صورت تغییر شرایط، می‌توان ضرایب وزنی مدل‌ها را با توجه به داده‌های موجود به‌روز رسانی و مدل‌ها را برای شرایط جدید تعمیم داد. با وجود نتایج قابل قبول این تحقیق، تعیین دقیق پارامترهای نشست و استفاده عملی از مدل‌های پیشنهادی نیاز به مطالعات بیشتر دارد.

شد. مقادیر  $R^2$  برای روش‌های  $MLR$  و  $GWO$  در پیش‌بینی حداکثر نشست برای داده‌های آموزش به ترتیب برابر با ۰٫۸۵۸ و ۰٫۹۸ و برای داده‌های تست به ترتیب برابر با ۰٫۸۷۱ و ۰٫۹۹۱ و در پیش‌بینی عرض گودی پروفیل نشست برای داده‌های آموزش به ترتیب برابر با ۰٫۸۸۴ و ۰٫۹۷۵ و برای داده‌های تست به ترتیب برابر با ۰٫۸۹۲ و ۰٫۹۸۹ به دست آمد. به‌علاوه، نتایج حاصله نشان داد که مقادیر شاخص‌های  $MAE$  و  $RMSE$  در هر دو مرحله آموزش و تست برای الگوریتم  $GWO$  کمتر از روش  $MLR$  و روابط تجربی موجود است. این نتایج بیانگر خطای کمتر الگوریتم  $GWO$  و قابلیت اطمینان، کارایی و دقت بالاتر آن نسبت به روش  $MLR$  و روابط تجربی موجود در پیش‌بینی حداکثر نشست و عرض گودی نشست سطح می‌باشد. در نهایت، نتایج آنالیز حساسیت نشان داد که پارامترهای  $F$  و  $C$  به ترتیب مهمترین

## ۸- مراجع

- Addenbrooke, T. I., & Potts, D. M. (2001). Finite element analysis of St James's Park greenfield reference site. In *Building response to tunnelling: Case studies from construction of the Jubilee Line Extension, London* (pp. 177-184). Thomas Telford Publishing.
- Amjadi, R., Samimi Namin, F., Chakeri, H., & Rouhani, M. M. (2021). Evaluation of the effect of injection pressure on surface settlement in excavation with earth pressure balanced shield machine, A case study: Tabriz metro line 2. *Tunneling & Underground Space Engineering (TUSE)*, 10(2), 167-181.
- Bagheri, E., Dehghan, A.N., & Ahangari, K. (2020). The Effect of Operational Parameters Affecting Ground Surface in Excavation with Earth Pressure Balance Shield Machine - EPBM (the Case of Southern Extension Tunnel of Line 6 of Tehran Subway). *Tunneling & Underground Space Engineering (TUSE)*, 9(1), 83-98.
- Bastami, R., Bazzazi, A. A., Shoormasti, H. H., & Ahangari, K. (2020). Predicting and minimizing the blasting cost in limestone mines using a combination of gene expression programming and particle swarm optimization. *Archives of Mining Sciences*, 65(4).
- Chakeri, H., Ozcelik, Y., & Ünver, B. (2013). Effects of important factors on surface settlement prediction for metro tunnel excavated by EPB. *Tunnelling and Underground Space Technology*, 36, 14-23.
- Chakeri, H., & Ünver, B. (2014). A new equation for estimating the maximum surface settlement above tunnels excavated in soft ground. *Environmental earth sciences*, 71, 3195-3210.
- Chawla, V., Chanda, A., & Angra, S. (2019). The scheduling of automatic guided vehicles for the workload balancing and travel time minimization in the flexible manufacturing system by the nature-inspired algorithm. *Journal of Project Management*, 4(1), 19-30.

- Chou, W. I., & Bobet, A. (2002). Predictions of ground deformations in shallow tunnels in clay. *Tunnelling and underground space technology*, 17(1), 3-19.
- Emary, E., Zawbaa, H. M., Grosan, C., & Hassenian, A. E. (2015). Feature subset selection approach by gray-wolf optimization. In *Afro-European Conference for Industrial Advancement: Proceedings of the First International Afro-European Conference for Industrial Advancement AECIA 2014* (pp. 1-13). Springer International Publishing.
- Ercelebi, S. G., Çopur, H., & Ocak, I. (2011). Surface settlement predictions for Istanbul Metro tunnels excavated by EPB-TBM. *Environmental Earth Sciences*, 62, 357-365.
- Faris, H., Aljarah, I., Al-Betar, M. A., & Mirjalili, S. (2018). Grey wolf optimizer: a review of recent variants and applications. *Neural computing and applications*, 30, 413-435.
- Fattahi, H., Ghaedi, H., & Armaghani, D. J. (2024). Optimizing fracture toughness estimation for rock structures: A soft computing approach with GWO and IWO algorithms. *Measurement*, 238, 115306.
- Fouladgar, N., Hasanipanah, M., & Bakhshandeh Amnieh, H. (2017). Application of cuckoo search algorithm to estimate peak particle velocity in mine blasting. *Engineering with Computers*, 33, 181-189.
- Hamza, M., Ata, A., & Roussin, A. (1999). Ground movements due to the construction of cut-and-cover structures and slurry shield tunnel of the Cairo Metro. *Tunnelling and Underground Space Technology*, 14(3), 281-289.
- Hasanipanah, M., Noorian-Bidgoli, M., Jahed Armaghani, D., & Khamesi, H. (2016). Feasibility of PSO-ANN model for predicting surface settlement caused by tunneling. *Engineering with Computers*, 32, 705-715.
- Herzog, M. (1985). Surface subsidence above shallow tunnels. *Bautechnik*, 62(11), 375-377.
- Mahmoodzadeh, A., Mohammadi, M., Daraei, A., Ali, H. F. H., Al-Salihi, N. K., & Omer, R. M. D. (2020). Forecasting maximum surface settlement caused by urban tunneling. *Automation in Construction*, 120, 103375.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- Moghaddasi, M. R., & Noorian-Bidgoli, M. (2018). ICA-ANN, ANN and multiple regression models for prediction of surface settlement caused by tunneling. *Tunnelling and Underground Space Technology*, 79, 197-209.
- Moghtader, T., Sharafati, A., Naderpour, H., & Gharouni Nik, M. (2023). Estimating maximum surface settlement caused by EPB shield tunneling utilizing an intelligent approach. *Buildings*, 13(4), 1051.
- Neaupane, K. M., & Adhikari, N. R. (2006). Prediction of tunneling-induced ground movement with the multi-layer perceptron. *Tunnelling and underground space technology*, 21(2), 151-159.
- Ocak, I., & Seker, S. E. (2013). Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, and Gaussian processes. *Environmental earth sciences*, 70,

استفاده از الگوریتم بهینه‌سازی گرگ خاکستری برای تخمین پارامترهای نشست سطح زمین ... محمد رضائی و ... ص ۶۱-۸۰

1263-1276.

O'reilly, M. P., & New, B. M. (1982). *Settlements above tunnels in the United Kingdom-their magnitude and prediction* (No. Monograph).

Loganathan, N., & Poulos, H. G. (1998). Analytical prediction for tunneling-induced ground movements in clays. *Journal of Geotechnical and geoenvironmental engineering*, 124(9), 846-856.

Peck, B. B. (1969). Deep excavation and tunnelling in soft ground, State of the art volume. In *7th ICSMFE* (Vol. 4, pp. 225-290).

Park, K. H. (2005). Analytical solution for tunnelling-induced ground movement in clays. *Tunnelling and underground space technology*, 20(3), 249-261.

Qu, Y. L. (2005). Neural network prediction of ground deformation caused by urban underground engineering. *Nanjing University of Technology*.

Rahmannejad, R., Esfandiary, M., Namazi, E., & Jamshidi, H. (2014). Numerical Analysis of Longitudinal and Transverse Surface Settlement Induced by EPB Tunneling- A Case Study: Shiraz Subway Tunnels. *Tunneling & Underground Space Engineering (TUSE)*, 2(2), 87-100.

Santos Jr, O. J., & Celestino, T. B. (2008). Artificial neural networks analysis of Sao Paulo subway tunnel settlement data. *Tunnelling and underground space technology*, 23(5), 481-491.

Schmidt, B. (1983). A method of estimating surface settlement above tunnels constructed in soft ground. *Canadian geotechnical journal*, 20(1), 11-22.

Shakeri, J., Bascompta, M., Alimoradjazi, M., & Dehghani, H. (2023). Application of artificial intelligence techniques for predicting the flyrock, Sungun mine, Iran. *Arabian Journal of Geosciences*, 16(8), 488.

Sorabi, P., Ataei, M., Jazi, M. R. A., Dehghani, H., Shakeri, J., & Habibi, M. H. (2024). Utilizing heuristic strategies for predicting the backbreak occurrences in open-pit mines, Gol Gohar Mine, Iran. *Soft Computing*, 1-16.

Verruijt, A., & Booker, J. R. (1998). Surface settlements due to deformation of a tunnel in an elastic half plane. *Geotechnique*, 48(5), 709-713.

Vermeer, P. A. (1991). Pile settlements due to tunneling. In *Proc. 10th European Conf. on Soil Mechanics and Foundation Engrg., Florence, 1991* (Vol. 2, pp. 869-872). Balkema.

Yilmaz, I., & Kaynar, O. (2011). Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert systems with applications*, 38(5), 5958-5966.

Zhang, K., Lyu, H. M., Shen, S. L., Zhou, A., & Yin, Z. Y. (2020). Evolutionary hybrid neural network approach to predict shield tunneling-induced ground settlements. *Tunnelling and Underground Space Technology*, 106, 103594.

Zhou, J., Shi, X., Du, K., Qiu, X., Li, X., & Mitri, H. S. (2017). Feasibility of random-forest approach for prediction of ground settlements induced by the construction of a shield-driven tunnel. *International Journal of Geomechanics*, 17(6), 04016129.

## Application of the grey wolf optimizer to estimate the ground surface settlement parameters based on geological conditions, tunnel geometry, and practical factors of boring machine

M. Rezaei<sup>1\*</sup>; F. Matinpour<sup>2</sup>; S. Mohammadi Bolbanabad<sup>3</sup>; V. Sarfarazi<sup>4</sup>

1- Associate Professor; Department of Mining Engineering, Faculty of Eng., University of Kurdistan, m.rezaei@uok.ac.ir

2- PhD Candidate; School of Mining Engineering, University College of Engineering, University of Tehran, f.gorgeh@ut.ac.ir

3- PhD Candidate; Department of Mining Engineering, Faculty of Engineering, Tarbiat Modares University, shadman.mohammadi@modares.ac.ir

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

Received: 27 Apr 2024; Accepted: 23 Sep 2024  
DOI: 10.22044/tuse.2024.14468.1485

### Keywords

**Tunneling**  
**Maximum surface settlement**  
**Trough width of settlement**  
**Grey wolf optimizer**  
**Multiple linear regression**

### Extended Abstract

#### Summary

In this paper, grey wolf optimization (GWO) and multiple linear regression (MLR) models have been utilized to estimate the maximum surface settlement ( $S_{max}$ ) and trough width ( $i$ ) of settlement profile due to the tunnel excavation. The results show the superiority of the GWO algorithm compared to the MLR model and similar empirical models. Moreover, the importance study and the correlation matrix of the datasets reveal that thrust force and cohesion are the most important variables on  $S_{max}$  and  $i$ , respectively. On the other hand, the tunnel diameter and Poisson ratio are the least important variables on  $S_{max}$  and  $i$ , respectively.

### Introduction

The tunneling operation usually causes the ground settlement, which is challenging both in terms of cost and safety. Therefore, it is necessary to estimate and control the settlement to reduce these costs and satisfy the safety standards. Many studies have been conducted to estimate the settlement parameters using empirical, analytical, numerical and intelligent methods. To cover the weaknesses of available approaches, intelligent models have been used to predict  $S_{max}$  and  $i$  due to their high accuracy. Thus, the  $S_{max}$  and  $i$  are estimated using the GWO and MLR models in this paper.

### Methodology and Approaches

In this study, the GWO and MLR models are used to predict the occurred  $S_{max}$  and  $i$  due to the tunneling operations. To do this, 26 datasets related to three tunneling projects were collected and randomly divided into training (20 series) and testing (6 series) datasets. Optimum GWO and MLR models are developed using training datasets to predict  $S_{max}$  and  $i$ . The developed models are evaluated and verified using the testing datasets and compared to each other, and also, to the previous similar empirical models. Finally, sensitivity analysis was conducted to evaluate the impact of the inputs on the outputs.

### Results and Conclusions

To achieve the optimum GWO and MLR models in  $S_{max}$  and  $i$  predicting, the models performances are evaluated during the training and testing phases using the performance evaluation indices. The obtained results show the higher accuracy of the GWO algorithm compared to the MLR model. Moreover, the comparative analysis of the results proves the

superiority of the GWO method compared to the similar empirical models. Finally, the importance study and correlation matrix confirm that thrust force and tunnel diameter are the most and least important variables on the  $S_{\max}$ , while cohesion and Poisson ratio are most and least important variables on  $i$ , respectively.

---